

Patrones espaciotemporales de las observaciones de Sentinel-2 a nivel de imagen y píxel sobre el territorio mexicano entre 2015 y 2019

Solórzano, J.V.¹, Mas, J.F.^{2*}, Gao, Y.², Gallardo-Cruz, J.A.³

¹ Posgrado en Geografía, Centro de Investigaciones en Geografía Ambiental – Universidad Nacional Autónoma de México, Antigua Carretera a Pátzcuaro No. 8701, Col. Ex-Hacienda de San José de la Huerta. C.P. 58190, Morelia, México.

² Laboratorio de Análisis Espacial, Centro de Investigaciones en Geografía Ambiental – Universidad Nacional Autónoma de México, Antigua Carretera a Pátzcuaro No. 8701, Col. Ex-Hacienda de San José de la Huerta. C.P. 58190, Morelia, México.

³ Centro Transdisciplinario Universitario para la Sustentabilidad, Universidad Iberoamericana Ciudad de México, Prolongación Paseo de la Reforma 880, Lomas de Santa Fe. C.P. 01219, Ciudad de México, México.

Resumen: Actualmente, las imágenes Sentinel-2 son uno de los acervos multispectrales y gratuitos de mayor resolución temporal, espectral y espacial para monitorear la superficie terrestre. Sin embargo, la posibilidad de utilizar este acervo para distintas aplicaciones está condicionada por el número de observaciones sin nubes disponibles para una ventana espacio-temporal determinada. Por ello, este artículo tiene el objetivo de analizar el número de observaciones de Sentinel-2 disponibles para el territorio mexicano a nivel de imagen y de píxel. En el primer caso, se contabilizó el total de imágenes disponibles por año y su porcentaje de nubosidad; mientras que, en el segundo, se calculó el número de observaciones despejadas por píxel. Además, para tomar en cuenta la diversidad del territorio, se evaluó el promedio mensual de las observaciones por píxel de cada una de las siete ecorregiones del país, así como la proporción de su superficie con, por lo menos, una observación despejada en intervalos mensuales, bimestrales, trimestrales y anuales. Los resultados mostraron que el número de observaciones válidas por píxel varían entre 0 y 121 observaciones al año y entre 0 y 6,58 al mes. Adicionalmente, se observó que en el periodo 2017-2019 se pueden obtener observaciones de todo el país en ventanas anuales, mientras que en el periodo 2018-2019, se pueden obtener observaciones en intervalos mensuales o trimestrales, dependiendo de la ecorregión. Finalmente, consideramos que los resultados de este trabajo servirán de guía para los usuarios interesados en utilizar estas imágenes para distintos estudios.

Palabras clave: México, ecorregiones, observaciones sin nubes, Sentinel-2, imágenes satelitales ópticas.

Spatiotemporal patterns of Sentinel-2 observations at image- and pixel-level of the Mexican territory between 2015 and 2019

Abstract: Sentinel-2 imagery has the highest temporal, spectral and spatial resolution to monitor land surface among the freely available multispectral collections. However, the possibility to use these images in different applications is conditioned by the number of cloudless observations available for a certain spatiotemporal window. Thus, the objective of this article is to analyze the number of Sentinel-2 observations available for the Mexican territory at image and pixel level. In the first case, the total number of available images and its cloud cover

To cite this article: Solórzano, J.V., Mas, J.F., Gao, Y., Gallardo-Cruz, J.A. 2020. Spatiotemporal patterns of Sentinel-2 observations at image- and pixel-level of the Mexican territory between 2015 and 2019. *Revista de Teledetección*, 56, 103-115. <https://doi.org/10.4995/raet.2020.14044>

* Corresponding author: jfmas@ciga.unam.mx

percentage was calculated; while in the second case, the number of cloudless observations was estimated for each pixel. Additionally, in order to take into account the territory diversity, the monthly mean number of cloudless observations, as well as the proportion of its surface with at least one cloudless observation in monthly, bimonthly, trimonthly and annual intervals, was computed for each one of the seven ecoregions of the country. The results show that annually, the number of valid observations per pixel is between 0 and 121 observations, while in monthly evaluations, between 0 and 6.58 observations. Additionally, in the 2017-2019 period annual observations can be obtained for the entire Mexican land surface, while in 2018-2019, monthly or trimonthly evaluations can be achieved, depending on the ecoregion. We consider that these results will provide useful information for researchers that are interested in using Sentinel-2 imagery for different applications.

Key words: Mexico, ecoregions, cloudless observations, Sentinel-2, optical satellite imagery.

1. Introducción

El estudio de la superficie terrestre mediante imágenes satelitales se ha consolidado como un área de continua investigación y desarrollo durante el siglo XXI (Boyd y Danson, 2005; Melesse et al., 2007). Por ello, hoy en día se puede encontrar una diversidad enorme de estudios que utilizan la teledetección en aplicaciones forestales, urbanas, biológicas, geológicas, arqueológicas, entre otras (Agapiou et al., 2014; Van der Meer et al., 2014; Ramoelo et al., 2015; Pesaresi et al., 2016; Caballero et al., 2020).

Actualmente, uno de los proyectos de obtención de imágenes satelitales gratuitas más importantes es el programa Copernicus y su constelación de satélites Sentinel que incluyen sensores radar (Sentinel 1 y 3) y multiespectrales (Sentinel 2, 3, 4 y 5; Berger et al., 2012; Malenovsky et al., 2012). Entre ellos, la constelación Sentinel-2 está destinada a monitorear la superficie terrestre y de mares interiores mediante sensores multiespectrales (ESA, 2018). En comparación con misiones multiespectrales gratuitas anteriores, ésta destaca por tres aspectos principales (Berger et al., 2012; Drusch et al., 2012): 1) su alta resolución temporal (tiempo de revisita de 3-5 días en su periodo de máxima capacidad de funcionamiento), 2) su alta resolución espectral (cuenta con 13 bandas en el espectro visible, borde del rojo e infrarrojo) y 3) su alta resolución espacial (bandas con tamaño de píxel de 10 m, 20 m y 60 m). Por ello, Sentinel-2 se perfila como uno de los programas más utilizados en un futuro.

Un factor clave para poder estudiar un fenómeno mediante teledetección radica en la compatibilidad

entre las escalas espacio-temporales del fenómeno de interés y de la información remota (Li y Roy, 2017; Comber y Wulder, 2019). En el caso de las imágenes multiespectrales, uno de los principales fenómenos meteorológicos que dificultan el registro de información de la superficie terrestre es la presencia de nubes (Wilson y Jetz, 2016; Main-Knorn et al., 2017; Coluzzi et al., 2018). Por ello, el conocer el número de observaciones válidas disponibles (*i.e.*, observaciones en condiciones despejadas o sin nubes) de un acervo de imágenes determinado para un área y periodo de tiempo particular permitirá: 1) conocer su distribución espacio-temporal, 2) determinar el mejor periodo para obtener mediciones válidas, 3) determinar la resolución temporal en la que se podría realizar algún tipo de monitoreo y 4) finalmente, evaluar la factibilidad de utilizar estas imágenes para un tipo de estudio en particular (Whitcraft et al., 2015; Wulder et al., 2016).

Previamente, se han realizado trabajos de revisión y descripción de los acervos de imágenes Landsat para determinados países (*e.g.*, White y Wulder, 2014; Solórzano et al., 2020). A pesar de la información valiosa que proveen estos esfuerzos, la mayoría se ha limitado a hacer caracterizaciones a nivel de imagen; por lo tanto, no permiten identificar las diferencias de condiciones de nubosidad entre regiones de un territorio (aunque ver Wilson y Jetz, 2016; Zhou et al., 2019). Además, la posibilidad de realizar descripciones a nivel de píxel había estado restringida por el enorme poder de cómputo requerido para realizarlas, pero el desarrollo de plataformas de computación en la nube como Google Earth Engine (Gorelick et al., 2017), es posible realizarlas.

En este contexto, el objetivo de este trabajo es caracterizar el acervo de observaciones Sentinel-2 disponibles para la superficie terrestre mexicana y sus principales ecorregiones, a nivel de escena y de píxel en el periodo 2015-2019. Esta caracterización permitirá identificar los principales patrones temporales y espaciales de las observaciones despejadas y servirán para guiar estudios futuros interesados en utilizar este acervo de imágenes.

2. Materiales y métodos

2.1. Sitio de estudio

México es un país que presenta una enorme heterogeneidad de condiciones climáticas y edafológicas, producto de su compleja fisiografía y ubicación intertropical (Espinosa et al., 2008). Esta heterogeneidad se ve reflejada en la diversidad de ecosistemas terrestres presentes en el país, la cual incluye desde desiertos hasta selvas

húmedas (Espinosa et al., 2008). Cada uno de estos ecosistemas presenta un régimen de precipitación distinto, lo cual, a su vez, determina los principales patrones temporales de la presencia de nubes sobre su superficie (Wilson and Jetz, 2016; Sudmanns et al., 2019). Para caracterizar con mayor detalle el número de observaciones válidas por píxel en cada tipo de ecosistema, se utilizó la ecorregionalización en nivel I propuesta por INEGI-CONABIO-INE (2008). De esta manera, se dividió al país en siete ecorregiones: *California Mediterránea*, *Desiertos de América del Norte*, *Elevaciones Semiáridas Meridionales*, *Grandes Planicies*, *Selvas Cálido Húmedas*, *Selvas Cálidos Secas* y *Sierras templadas* (Figura 1; ver Tabla 1 para consultar la superficie abarcada por cada ecorregión).

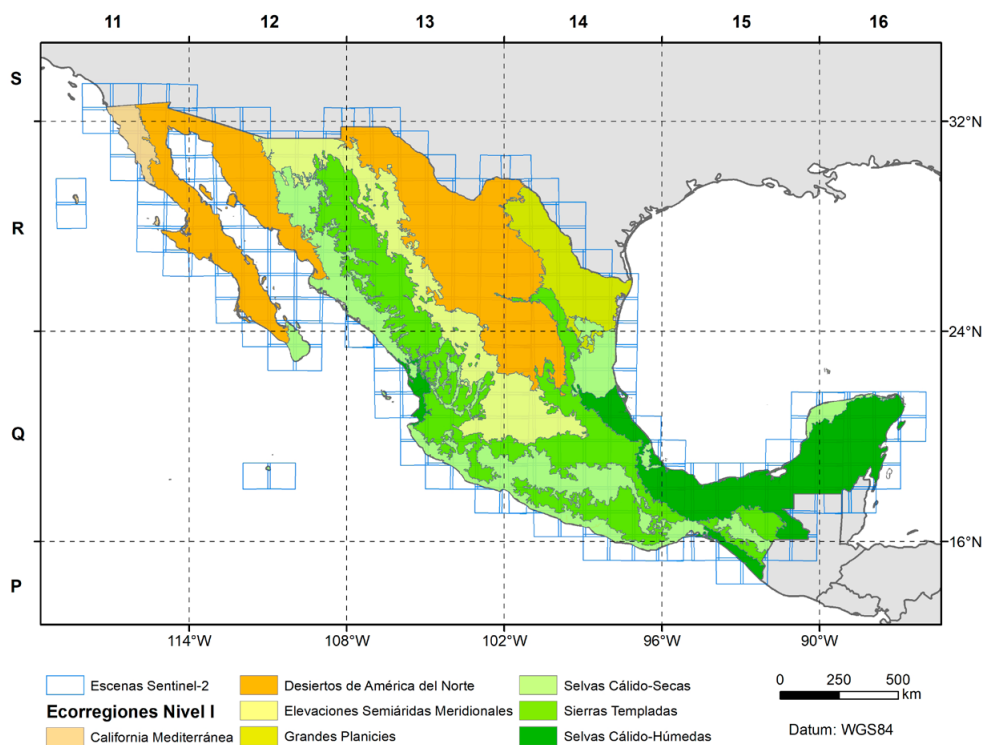


Figura 1. Ubicación geográfica de las ecorregiones nivel I de México de acuerdo con la clasificación de INEGI-CONABIO-INE (2008). La escala de colores muestra un gradiente general de mayor a menor humedad (verde oscuro a naranja claro). Además, se muestran las escenas de Sentinel-2 que cubren la superficie terrestre de México (Fuente: ESA, 2020b). En los ejes superior e izquierdo se muestran las zonas UTM donde se encuentra el país, de acuerdo con el Sistema de Referencia de Cuadrícula Militar, mientras que en los ejes inferior y derecho, se muestran las coordenadas geográficas que delimitan cada una de estas zonas.

2.2. Imágenes Sentinel-2

Las imágenes Sentinel-2 son distribuidas en escenas (“tiles” o “granules”) que abarcan un área de 110 km×110 km (12 100 km²), las cuales se superponen 10 km entre escenas contiguas (ESA, 2020b). Estas escenas siguen el Sistema de Referencia de Cuadrícula Militar (MGRS por sus siglas en inglés) con una proyección UTM/WGS84 (ESA, 2020b). En el resto de este trabajo, se usará el término escena para referirse a la clave única de las imágenes, mientras que el término imágenes se utilizará para referirse al registro de una escena en una fecha particular. En el caso de México, un total de 303 escenas cubren su superficie terrestre, las cuales están ordenadas, de acuerdo con las zonas UTM en las que se ubica el país (Figura 1).

La información a nivel de imagen y de píxel de las imágenes Sentinel-2 se obtuvo en la API de JavaScript de Google Earth Engine (GEE, 2020; Gorelick et al., 2017). Actualmente, existen dos colecciones de Sentinel-2 disponibles: la 1C (reflectancia sobre la atmósfera) y 2A (reflectancia de la superficie). Las tres principales diferencias entre estas colecciones son: 1) el nivel de tratamiento, 2) el algoritmo utilizado para detectar nubes y sombras, y 3) el periodo para el cual se encuentran disponibles. A pesar de que la colección 2A es la que tiene un mayor nivel de tratamiento y calidad, las primeras imágenes disponibles del territorio mexicano datan de diciembre de 2018 (GEE, 2020). Por el contrario, las primeras imágenes de la colección 1C son de julio de 2015; por ello, se eligió esta última colección para realizar el análisis. En GEE, se consultaron todas las imágenes Sentinel-2 de la colección 1C que abarcaban la superficie terrestre de México, utilizando un polígono suavizado del contorno de la superficie del país entre 01/07/2015 (mes del lanzamiento de Sentinel-2A; ESA, 2016) y 31/12/2019.

En primer lugar, se construyó una rutina en GEE para obtener la información de las imágenes que cubrieron la superficie terrestre mexicana en el periodo de estudio. Estos datos se obtuvieron de los metadatos e incluyeron: el número total de imágenes disponibles, el sensor que registró cada imagen (*i.e.*, Sentinel-2A o 2B), el porcentaje de la imagen cubierta por nubes y su fecha de captura.

En segundo lugar, se construyó una rutina para obtener la información a nivel de píxel, es decir, el número de observaciones despejadas por píxel. Para ello, se utilizó la información de la banda QA60 con una resolución de píxel de 60 m. Esta banda contiene la información de la evaluación de los píxeles, por lo tanto, permite diferenciar las observaciones despejadas, *i.e.*, sin nubes (Bit 1=0), de las áreas cubiertas por nubes densas y cirrus (Bit 10 ó Bit 11=1; GEE, 2020). En la colección 1C, se utiliza la reflectancia del azul y de dos bandas en el infrarrojo de onda corta para detectar la presencia de nubes (Coluzzi et al., 2018; ESA, 2020a). El criterio para definir las observaciones válidas por píxel constó de dos requisitos: 1) tratarse de una observación sin nubes, de acuerdo con la banda QA60 y 2) eliminar observaciones repetidas en las áreas traslapadas entre imágenes contiguas. Este número de observaciones válidas por píxel se calculó para cada mes y cada año del periodo de estudio (01/07/2015-31/12/2019). Esta información se obtuvo con la resolución de píxel nativa de la banda QA60, es decir, de 60 m. Posteriormente, se calculó el número de observaciones por píxel para cada ecorregión y se estimó la proporción de su superficie con por lo menos una observación válida anual. El código para obtener la información a nivel de imagen y de píxel puede ser consultado en el siguiente enlace: <https://github.com/JonathanVSV/PerPixelObsSentinel-2>.

Por último, para identificar el mejor periodo intra-anual para obtener observaciones válidas de cada ecorregión se utilizaron sólo los datos de 2018-2019, ya que en el periodo 2015-2017 el número de imágenes disponibles no fue constante en todos los meses. Esto se debió al incremento paulatino en la capacidad de funcionamiento de la constelación (ESA, 2018). En este procedimiento, se construyeron mosaicos mensuales, bimestrales y trimestrales que comenzaron en cada mes de 2018 y 2019. Para cada mosaico se promedió el número de observaciones válidas, así como la proporción de la superficie con, por lo menos, una observación válida en los dos años evaluados. El análisis de los datos y la elaboración de los gráficos se realizaron en R 3.6.2 (R Core Team, 2020) utilizando el paquete *tidyverse* (Wickham et al., 2019).

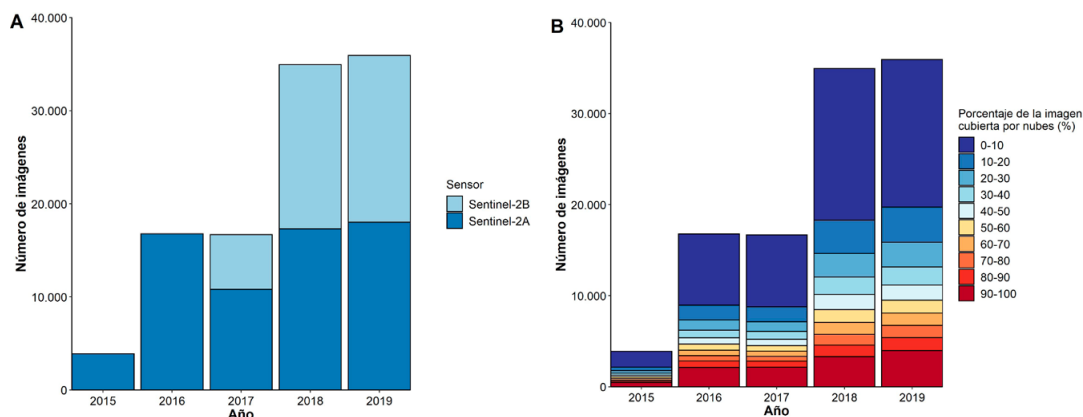


Figura 2. Número de imágenes Sentinel-2 IC disponibles para México entre 2015 y 2019 A) divididas por el satélite que las registró y B) por su porcentaje de cobertura de nubes.

3. Resultados

3.1. Información a nivel de imagen

En total, se encontraron 108242 imágenes que cubren la superficie terrestre mexicana entre 2015 y 2019, de las cuales, la mayoría fueron registradas entre 2018 y 2019 (34952 y 35933 imágenes, respectivamente; Figura 2A). Por su parte, en 2015-2017 se encontró un número menor de imágenes (16779, 16671 y 3907 imágenes en 2017, 2016, 2015, respectivamente; Figura 2A).

Adicionalmente, se encontró que la mayor parte de las imágenes tuvieron una calidad intermedia-alta, con un porcentaje de cobertura de nubes menor al 70% (entre un 61,5 y 65,5% de las imágenes disponibles por año; Figura 2B). De éstas, la mayoría correspondieron a las de mayor calidad, *i.e.*, 0-10% de cobertura por nubes (entre un 44,50 y 47,6% del total de imágenes por año; Figura 2B).

3.2. Información a nivel de píxel

El número de observaciones válidas por píxel de la superficie terrestre mexicana fue de entre 0 y 121 al año; sin embargo, esta distribución fue heterogénea tanto en el tiempo como en el espacio. Al igual que en los resultados a nivel de imagen, el número de observaciones por píxel aumentó gracias al inicio de operaciones del Sentinel-2B en 2017, así como al incremento en la capacidad de funcionamiento de ambos sensores (Figura 2 y Figura 3).

Además, se observaron franjas, alineadas en un eje NE - SO, con un mayor número de observaciones

válidas por píxel que corresponden a las áreas superpuestas entre órbitas adyacentes. Estas franjas presentaron casi el doble de observaciones válidas respecto a las demás áreas donde no se presenta dicho traslape (Figuras 4 y 6).

3.2.1. El patrón interanual en las ecorregiones

Las ecorregiones de *California Mediterránea*, *Elevaciones Semiáridas Meridionales*, *Grandes Planicies* y *Selvas Cálido Secas* presentaron, por lo menos, una observación válida para toda su superficie en el periodo 2016-2019, mientras que las ecorregiones de *Selvas Cálido Húmedas* y *Sierras Templadas*, sólo en el periodo 2017-2019 (Tabla 1). Un caso, excepcional fue *Desiertos de América del Norte*, donde en todos los años evaluados una porción muy pequeña de su superficie no mostró observación válida alguna.

3.2.2. El patrón intra-anual en las ecorregiones

En general, las ecorregiones más áridas (*California Mediterránea*, *Desiertos de América del Norte*, *Elevaciones Semiáridas Meridionales*) presentaron un mayor número de observaciones válidas por mes que las ecorregiones más húmedas (*Grandes Planicies*, *Selvas Cálido-Secas*, *Selvas Cálido-Húmedas* y *Sierras Templadas*; Figura 3). El promedio mensual de las observaciones válidas por píxel se encontró entre 0 y 6,58 observaciones (Figura 3). A pesar de ello, el promedio de observaciones por píxel fue menor en 2015-2017 (0-4,56 observaciones válidas) que en 2018-2019 (2-6,58 observaciones válidas; Figura 3).

Tabla 1. Superficie abarcada por cada ecorregión y la proporción de cada ecorregión con, por lo menos, una observación válida al año en el periodo 2015-2019. Con un asterisco (*) se indican los años donde áreas menores a 0,005% de la superficie de la ecorregión no mostraron observaciones válidas.

Ecorregión	Superficie (km ²)	Porcentaje con observaciones válidas				
		2015	2016	2017	2018	2019
<i>California Mediterránea</i>	25085,66	99,91%	100%	100%	100%	100%
<i>Desiertos de América del Norte</i>	559147,47	93,26%	99,99%	99,99*%	99,99*%	99,99*%
<i>Elevaciones Semiáridas Meridionales</i>	229850,64	93,25%	100%	100%	100%	100%
<i>Grandes Planicies</i>	107674,18	77,47%	100%	100%	100%	100%
<i>Selvas Cálido-Húmedas</i>	277255,26	68,89%	99,99*%	100%	100%	100%
<i>Selvas Cálido-Secas</i>	319891,29	97,12%	100%	100%	100%	100%
<i>Sierras Templadas</i>	433881,25	92,83%	99,99*%	100%	100%	100%

Para las siete ecorregiones se requirió de un distinto número de meses para construir mosaicos multitemporales que presentaran, por lo menos, una observación válida para toda su superficie en el periodo 2018-2019. A pesar de ello, el 95% de la superficie de todas las ecorregiones mostró, por lo menos, una observación válida en la mayoría de los meses, un criterio comúnmente utilizado para determinar una alta calidad de las imágenes (Figura 4 y 5; Whitcraft et al., 2015; Zhou et al., 2019). La única excepción a este umbral se observó en *Grandes planicies* en el mes de marzo (Figura 5). Por su parte, al realizar los mosaicos

bimestrales, el porcentaje de la superficie de cada ecorregión con, por lo menos, una observación válida fue mayor al 99,65%; mientras que los mosaicos trimestrales, fue mayor al 99,85% (Figura 5).

California Mediterránea fue la única ecorregión donde el 100% de su superficie presentó, por lo menos, una observación válida en los mosaicos mensuales de septiembre, octubre y noviembre (Figura 5). Las demás ecorregiones requirieron realizar mosaicos bimestrales o trimestrales para obtener el total de su superficie con, por lo menos,

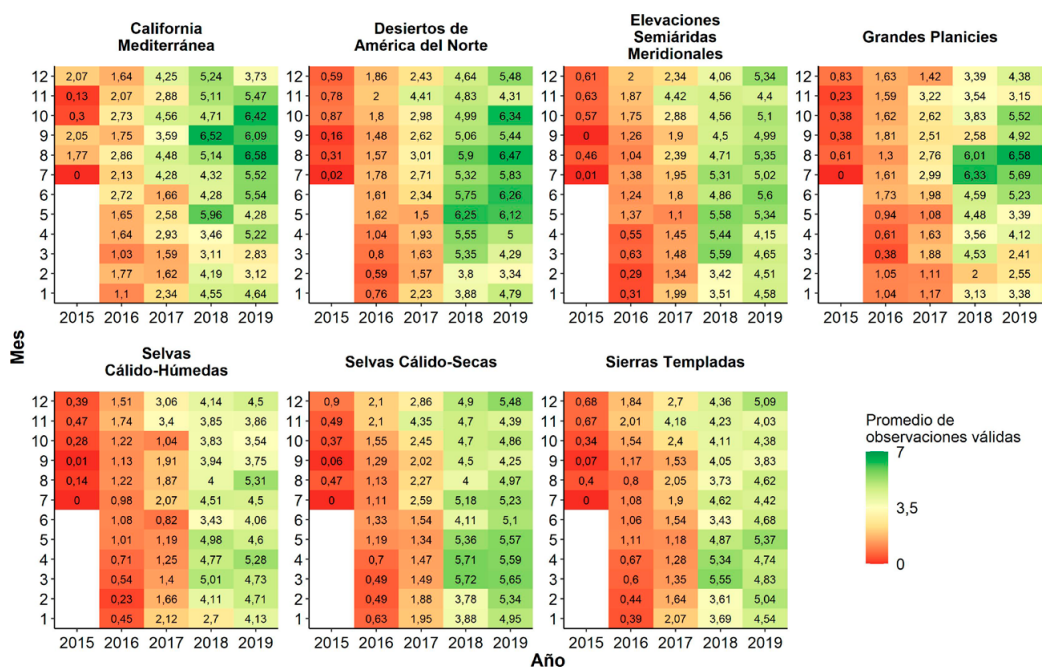


Figura 3. Promedio mensual de observaciones válidas por píxel de cada ecorregión del país durante el periodo 2015-2019.

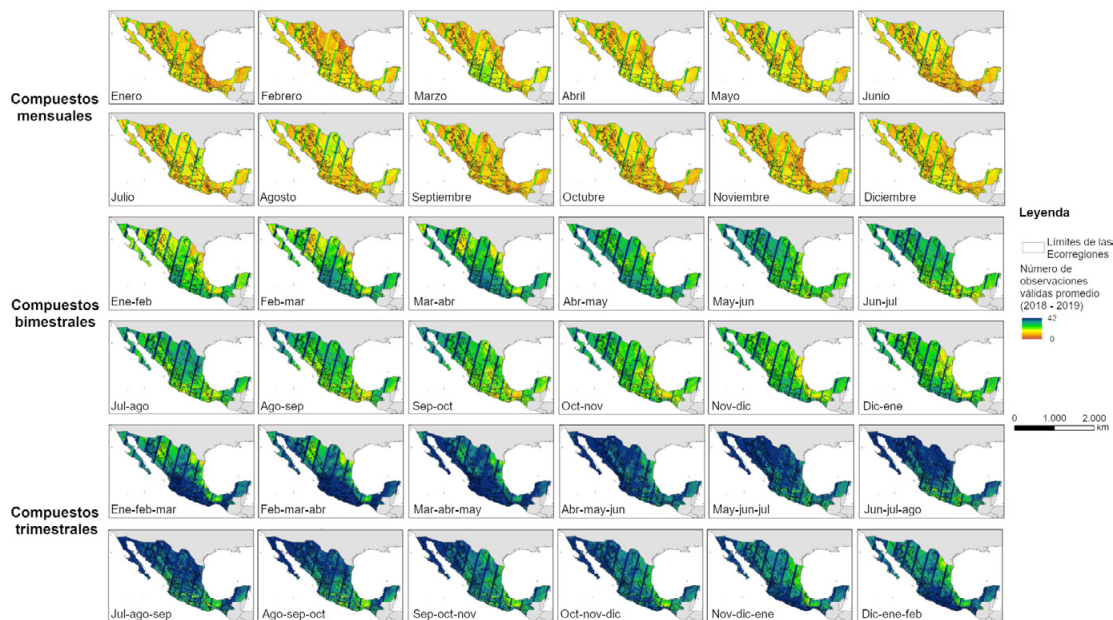


Figura 4. Número de observaciones válidas promedio en la superficie terrestre mexicana en el periodo 2018-2019 utilizando compuestos mensuales, bimestrales y trimestrales. En la esquina inferior izquierda de cada mapa se indican los meses utilizados para construir el compuesto.

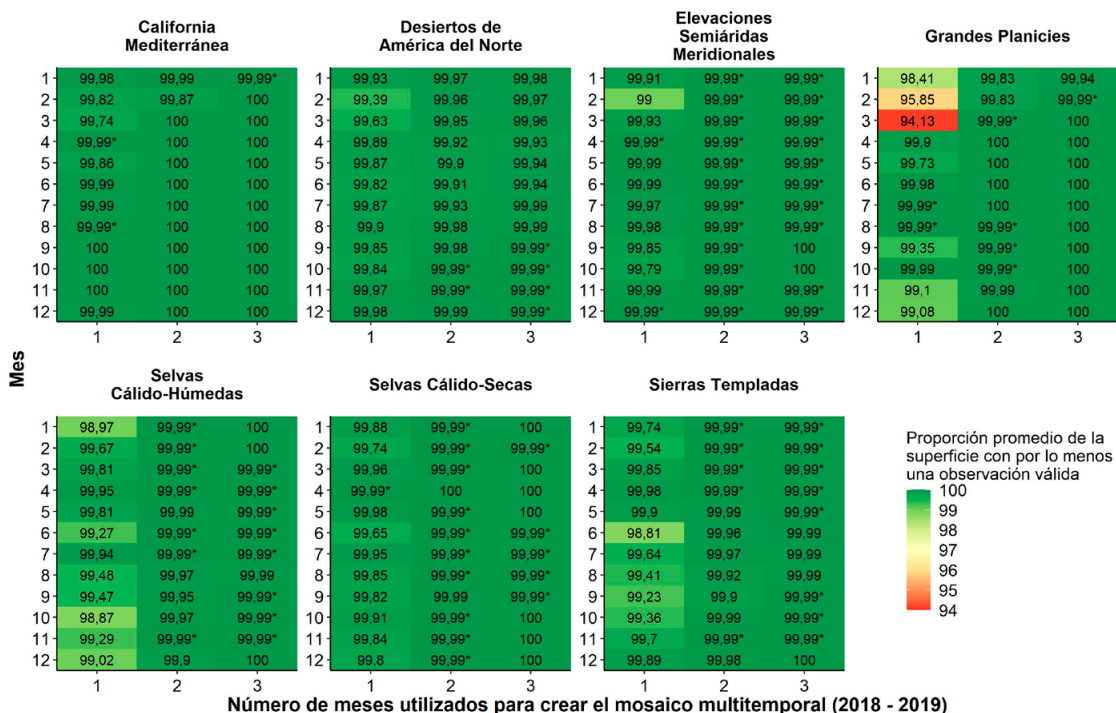


Figura 5. Proporción de la superficie de cada ecorregión con, por lo menos, una observación válida de acuerdo con los mosaicos construidos con imágenes de un mes (mensuales), dos meses (bimestrales) y tres meses (trimestrales) en el periodo de 2018-2019. Con un asterisco (*) se marcan los meses donde áreas menores a 0,005% de la superficie de cada ecorregión no presentaron observaciones válidas.

una observación válida. *Grandes Planicies* obtuvo, por lo menos, una observación válida para la totalidad de su superficie en los mosaicos bimestrales de abril-mayo, mayo-junio, junio-julio y julio-agosto, mientras que, en *Selvas Cálido-Secas*, en abril-mayo (Figura 5). Para *Elevaciones Semiáridas Meridionales* esto ocurrió en los compuestos trimestrales de septiembre-noviembre y octubre-diciembre, para *Selvas Cálido-Húmedas*, en los compuestos trimestrales de enero-marzo, febrero-abril y diciembre-febrero, mientras que para *Sierras Templadas* fue en el mosaico trimestral de diciembre-febrero (Figura 5). En el caso de *Desiertos de América del Norte*, en todas las evaluaciones bimestrales y trimestrales, una pequeña proporción de su superficie no presentó observaciones válidas, lo cual es consistente con lo observado en las evaluaciones anuales.

3.2.3. Errores detectados en la máscara QA60

Por último, se realizó una inspección visual de algunas zonas donde, de acuerdo con reportes previos, se esperaba que hubiera errores en la detección de nubes por parte de la banda QA60 (Coluzzi et al., 2018). Esta inspección permitió detectar dos fallos de la banda de evaluación de calidad de los píxeles: 1) la falta de detección de algunas nubes pequeñas o los bordes de éstas en la ecorregión de *Selvas Cálido-Húmedas* (i.e., error de omisión) y 2) la confusión de áreas prácticamente desprovistas de vegetación con sustratos de color muy claro con nubes en *Desiertos de América del Norte* (i.e., error de comisión; Figura 6). Esta última observación permite explicar por qué los *Desiertos de América del Norte* es la única ecorregión para la cual áreas muy pequeñas no mostraron observaciones válidas en el periodo 2016-2019 (Figura 6).

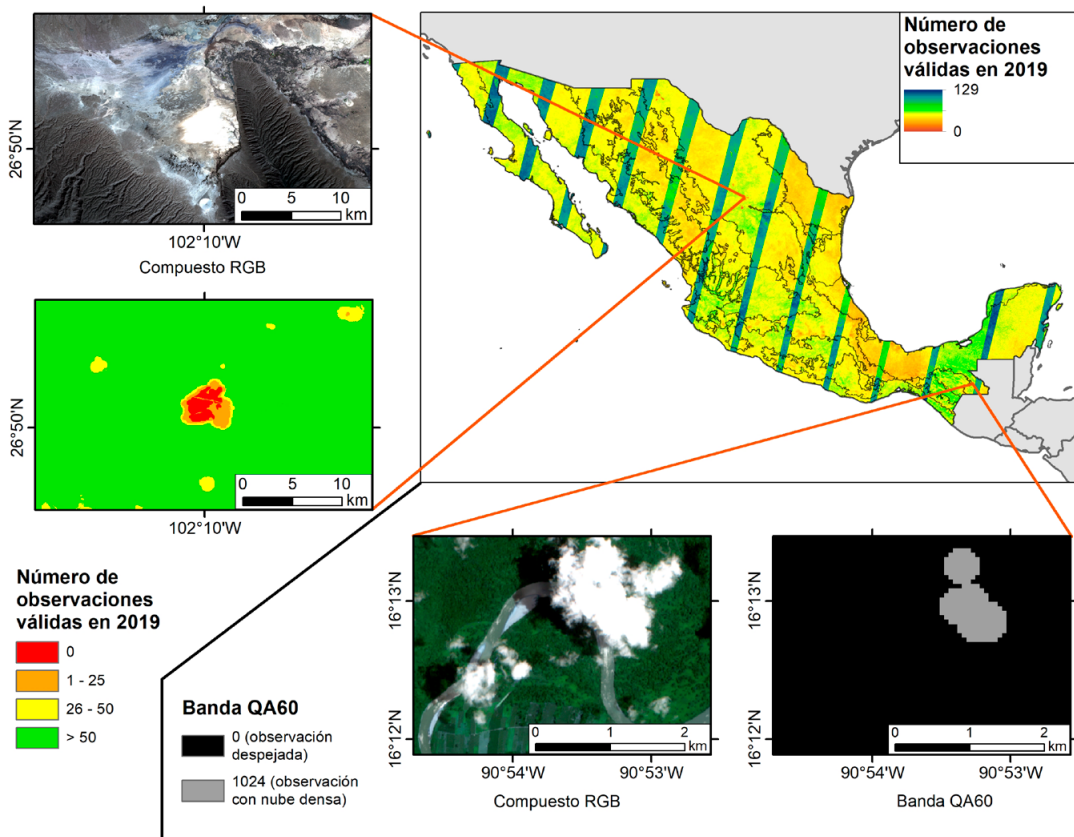


Figura 6. Ejemplos de errores en la banda de evaluación de calidad (QA60) de las imágenes Sentinel-2 1C. En la esquina superior izquierda se muestra un área donde se identificó erróneamente una zona con un sustrato muy claro como nubes. Se muestra la imagen (compuesto RGB) y debajo, el número de observaciones válidas que presentó dicha área en 2019. Por su parte, en la esquina inferior derecha, se muestra un ejemplo de una imagen (compuesto RGB) con su respectiva banda QA60 donde no se detectó con precisión la presencia de nubes.

4. Discusión

El conocer los principales patrones espacio-temporales de un acervo de imágenes para una región determinada es una labor poco abordada; sin embargo, resulta esencial para establecer: el mejor periodo para obtener observaciones sin nubes, la frecuencia con la que se podría realizar un monitoreo en particular y, finalmente, la viabilidad de utilizar un acervo para estudiar un fenómeno de interés (Griffiths et al., 2019; Zhou et al., 2019). En este estudio se identificaron los principales patrones espacio-temporales de las observaciones válidas de Sentinel-2 1C para la superficie terrestre mexicana.

Los resultados obtenidos en este estudio permitieron detectar dos patrones interanuales importantes: 1) el primer año con una cobertura completa del país con observaciones válidas es 2017 (a excepción de áreas pequeñas en *Desiertos de América del Norte*) y 2) en el periodo 2018-2019 se encuentra un acervo de imágenes más grande y homogéneo. Debido a que estos patrones se deben al aumento de las capacidades de la misión (ESA, 2016; ESA, 2018), se esperaría observar un patrón similar a nivel global, aunque podrá variar en mayor o menor grado dependiendo de la latitud.

Por otro lado, se observa que el potencial de utilizar el acervo de imágenes Sentinel-2 para estudiar la superficie terrestre mexicana es heterogéneo en el espacio y respondió a dos factores: 1) a las distintas condiciones climáticas relacionadas con la presencia de nubes de cada ecorregión y 2) las características de la órbita de los sensores. Estudios previos han observado un comportamiento análogo al analizar el número de observaciones de Sentinel-2 disponibles en otras partes del mundo (Carrasco et al., 2019; Griffiths et al., 2019). De hecho, un estudio realizado a nivel global, describe a México como un país con potencial entre medio y alto para estudiar su superficie mediante imágenes Sentinel-2, dadas sus condiciones de nubosidad promedio y el tiempo de revisita de la constelación (Sudmanns et al., 2019).

Varias de las aplicaciones para las que se planeó la misión Sentinel-2 incluyen el monitoreo de cambios en la cobertura terrestre, de la vegetación, de cuerpos de hielo y de costas y mares interiores (Berger et al., 2012; Malenovsky et al., 2012). De acuerdo con nuestros resultados, resultaría factible

realizar cualquiera de estos monitoreos anualmente, a partir de 2017 en cualquier ecorregión del país. Sin embargo, las ventanas temporales para contar con imágenes de mayor calidad o construir mosaicos multitemporales serán distintas dependiendo de la ecorregión. En total, se distinguieron tres periodos para obtener las imágenes de mayor calidad o mosaicos multitemporales de mayor calidad: 1) en los primeros y últimos meses del año (*Selvas Cálido-Húmedas*, *Sierras Templadas*), 2) en los meses de septiembre-noviembre (*California Mediterránea*, *Elevaciones Semiáridas Meridionales* y *Desiertos de América del Norte*) y 3) entre los meses de abril y julio (*Grandes Planicies* y *Selvas Cálido-Secas*). Estos periodos presentaron una alta relación con el periodo de secas de cada ecorregión.

Estos resultados indican que para todas las ecorregiones se puede obtener información remota de su superficie en ventanas temporales menores a la anual, sobre todo a partir de 2018; en algunas de ellas, en intervalos mensuales (e.g., *California Mediterránea*), mientras que, en otras, en periodos trimestrales (e.g., *Selvas Cálido-Húmedas* y *Sierras Templadas*). La posibilidad de tener información para ciertas temporadas del año, permite contar con información sobre la variabilidad temporal de la superficie, lo cual puede ser de gran utilidad para aplicaciones como la clasificación de tipos de cobertura o uso de suelo (Carrasco et al., 2019; Griffiths et al., 2019) o el monitoreo de glaciares (Viola et al., 2019).

Por otro lado, cabe mencionar que para ciertas aplicaciones, el uso de Sentinel-2 será mejor que en otras, debido a la coincidencia del periodo de menor nubosidad con el de mayor frecuencia de los eventos de interés. Por ejemplo, para la identificación de cicatrices de incendios, donde la época de mayor ocurrencia de eventos coincide con la época de mayor número de observaciones válidas por píxel (i.e., época de secas; Filipponi, 2018; Roteta et al., 2019). Sin embargo, en el caso del monitoreo de la vegetación y variables biofísicas relacionadas con su productividad, por ejemplo, el índice de área foliar (LAI) o el índice de vegetación de diferencia normalizada (NDVI), los meses de mayor actividad fotosintética suele coincidir con el periodo de mayor presencia de nubes; por lo tanto, con menor número de observaciones válidas por píxel (Ramoelo et al.,

2015; Lima et al., 2019). Esto podría resultar en un monitoreo subóptimo de las variables biofísicas relacionadas con la productividad de la vegetación, sobre todo para las ecorregiones más húmedas o muy estacionales (e.g., *Selvas Cálido-Húmedas* o *Selvas Cálido-Secas*). Para estos casos, se podría complementar la información con otros sensores del mismo programa Copernicus u otros (e.g., Sentinel-1; Heckel et al., 2020) o utilizar en conjunto el acervo de imágenes Sentinel-2 y Landsat-8 para aumentar el volumen de observaciones disponibles para estudiar un fenómeno (Claverie et al., 2018).

Varios trabajos previos han reportado mejores resultados utilizando imágenes Sentinel-2, respecto a Landsat-8, por su mayor resolución espectral, temporal y espacial, para aplicaciones que incluyen la detección de disturbios en bosques (Lima et al., 2019), el monitoreo de eventos de proliferación de algas nocivas (Caballero et al., 2020) y el monitoreo de asentamientos humanos (Pesaresi et al., 2016). Por lo tanto, se espera que el uso de este acervo para distintas aplicaciones en la superficie mexicana tenga resultados similares.

Por último, se encuentran franjas donde el número de observaciones válidas prácticamente se duplican, debido a la configuración de las órbitas de los satélites Sentinel-2A y 2B. Estas áreas se presentan en todas las ecorregiones en las que se dividió el país; por lo cual, representan sitios ideales para utilizar las imágenes Sentinel-2 para monitorear su superficie o para probar métodos basados en este acervo. Debido a la órbita de la constelación Sentinel-2, estas franjas son más amplias en regiones polares y más angostas en regiones cercanas al Ecuador (Li y Roy, 2017; ESA, 2020b). En el caso de México, estas franjas tienen un ancho aproximado de entre 30 y 70 km.

4.1. Consideraciones sobre la colección Sentinel-2 nivel 1C

Trabajos previos han reportado que la precisión de detección de nubes y sombras en la colección Sentinel-2 nivel 1C puede variar entre 29,44%-97,44% (Coluzzi et al., 2018). Sin embargo, los autores reportan que la precisión depende de tres factores: la humedad del ecosistema (menor precisión en ambientes húmedos),

la agregación espacial de las nubes (mayor precisión en imágenes con nubes agregadas) y el color del sustrato (menor precisión en superficies desprovistas de vegetación y con sustrato de color claro). Estos resultados también pueden observarse en la superficie terrestre mexicana.

Dado este panorama, el uso de la colección Sentinel-2 nivel 1C debe realizarse con cautela, sobre todo al utilizarse para estudiar las ecorregiones más húmedas (e.g., *Selvas Cálido-Húmedas*, *Sierras Templadas*) y áridas (e.g., *California Mediterránea* y *Desiertos de América del Norte*). En el primer caso, la banda QA60 presentará una mayor omisión de detección de nubes, mientras que, en las más áridas, la misma banda presentará un mayor número de áreas identificadas erróneamente como nubes. Por otro lado, se esperaría que, en ecorregiones como *Elevaciones Semiáridas Meridionales*, *Grandes Planicies* y *Selvas Cálido-Secas*, la presencia de este tipo de errores en la banda QA60 fuera menor.

Las evaluaciones sobre el algoritmo de detección de nubes de la colección de Sentinel-2 nivel 2A en diferentes tipos de ambientes reportan una precisión mayor a la del nivel 1C (84-92%; Main-Knorn et al., 2017). Debido a esta diferencia en la precisión de detección de nubes, ciertos usuarios podrían estar más interesados en utilizar la colección 2A en fechas previas a diciembre de 2018. Una alternativa para obtener las imágenes en nivel 2A previo al 2019 sería descargar las imágenes en nivel 1C y procesarlas de manera local utilizando el algoritmo “sen2cor” dentro del programa SNAP (ESA, 2020c).

5. Conclusiones

Sentinel-2 se perfila como uno de los acervos gratuitos de imágenes multiespectrales más utilizados debido a su alta resolución espacial, espectral y temporal. Por ello, este estudio permitió identificar los principales patrones espacio-temporales de la disponibilidad de observaciones a nivel de imagen y de píxel de la colección de imágenes Sentinel-2 nivel 1C sobre la superficie terrestre mexicana entre el 2015 y 2019. Se espera que este trabajo promueva el uso de estas imágenes para realizar diferentes tipos de estudios en México, así como sugerir posibles

capacidades de análisis con este conjunto de imágenes. A pesar de que esta evaluación fue nacional, es muy probable que patrones similares sean observados en otros sitios con ecorregiones similares, sobre todo aquellas que se encuentren en latitudes cercanas a los trópicos. Por último, para facilitar la implementación de este tipo de evaluaciones en otras partes del mundo, se puso a disponibilidad de cualquier usuario el código utilizado en este trabajo.

Agradecimientos

El primer autor agradece al CONACyT por la beca otorgada para realizar sus estudios de posgrado. Agradecemos a dos revisores anónimos por sus comentarios que nos ayudaron a mejorar significativamente el manuscrito de este artículo.

Referencias

- Agapiou, A., Alexakis, D.D., Sarris, A., Hadjimitsis, D.G. 2014. Evaluating the potentials of sentinel-2 for archaeological perspective. *Remote Sensing*, 6(3), 2176-2194. <https://doi.org/10.3390/rs6032176>
- Berger, M., Moreno, J., Johannessen, J.A., Levelt, P.F., Hanssen, R.F. 2012. ESA's sentinel missions in support of Earth system science. *Remote Sensing of Environment*, 120, 84-90. <https://doi.org/10.1016/j.rse.2011.07.023>
- Boyd, D.S., Danson, F.M. 2005. Satellite remote sensing of forest resources: three decades of research development. *Progress in Physical Geography*, 29(1), 1-26. <https://doi.org/10.1191/0309133305pp432ra>
- Caballero, I., Fernández, R., Moreno Escalante, O., Mamán, L., Navarro, G. 2020. New Capabilities of Sentinel-2A/B Satellites Combined with in Situ Data for Monitoring Small Harmful Algal Blooms in Complex Coastal Waters. *Scientific Reports*, 10, 1-14. <https://doi.org/10.1038/s41598-020-65600-1>
- Carrasco, L., O'Neil, A.W., Morton, R.D., Rowland, C.S. 2019. Evaluating Combinations of Temporally Aggregated Sentinel-1, Sentinel-2 and Landsat 8 for Land Cover Mapping with Google Earth Engine. *Remote Sens.*, 11, 288. <https://doi.org/10.3390/rs11030288>
- Claverie, M., Ju, J., Masek, J.G., Dungan, J.L., Vermote, E.F., Roger, J.-C., Skakun, S.V., Justice, C. 2018. The Harmonized Landsat and Sentinel-2 Surface Reflectance Data Set. *Remote Sensing of Environment*, 219, 145-61. <https://doi.org/10.1016/j.rse.2018.09.002>
- Coluzzi, R., Imbrenda, V., Lanfredi, M., Simoniello, T. 2018. A first assessment of the Sentinel-2 Level 1-C cloud mask product to support informed surface analyses. *Remote Sensing of Environment*, 217, 426-443. <https://doi.org/10.1016/j.rse.2018.08.009>
- Comber, A., Wulder, M.A. 2019. Considering spatiotemporal processes in big data analysis: Insights from remote sensing of land cover and land use. *Transactions in GIS*, 23, 879-891. <https://doi.org/10.1111/tgis.12559>
- Drusch, M., Del Bello, U., Carlier, S., Colin, O., Fernandez, V., Gascon, F.,... Bargellini, P. 2012. Sentinel-2: ESA's Optical High-Resolution Mission for GMES Operational Services. *Remote Sensing of Environment*, 120, 25-36. <https://doi.org/10.1016/j.rse.2011.11.026>
- ESA (European Space Agency). 2016. *Sentinel Data Access Annual Report*. Disponible en <https://sentinel.esa.int/documents/247904/2955773/Sentinel-Data-Access-Annual-Report-2016>
- ESA (European Space Agency). 2018. *Sentinel Data Access Annual Report*. Disponible en <https://sentinels.copernicus.eu/web/sentinel/news/-/article/2018-sentinel-data-access-annual-report>
- ESA (European Space Agency). Sentinel-2 MSI Technical Guide. Último acceso 25/05/2020, de <https://sentinel.esa.int/web/sentinel/technical-guides/sentinel-2-msi>
- ESA (European Space Agency). Sentinel-2 MSI User Guide. Último acceso 28/05/2020, de <https://sentinel.esa.int/web/sentinel/user-guides/sentinel-2-msi>
- ESA (European Space Agency). SNAP. Último acceso 20/05/2020, de <https://step.esa.int/main/toolboxes/snap/>
- Espinosa, D., Ocegueda, S., Aguilar, C., Flores, O., Llorente-Bousquets, J. 2008. El conocimiento biogeográfico de las especies y su regionalización natural, En: *Capital natural de México, vol. I: Conocimiento actual de la biodiversidad*. Conabio, México, pp. 33-65.
- Filipponi, F. 2018. BAIS2: Burned Area Index for Sentinel-2. *Proceedings 2nd International Electronic Conference on Remote Sensing*, 22 March–5 April 2018, 2, 364. <https://doi.org/10.3390/ecrs-2-05177>
- GEE (Google Earth Engine). Sentinel-2 MSI: MultiSpectral Instrument, Level-2A. Último acceso 05/03/2020, de https://developers.google.com/earth-engine/datasets/catalog/COPERNICUS_S2_SR

- Gorelick, N., Hancher, M., Dixon, M., Ilyushchenko, S., Thau, D., Moore, R. 2017. Google Earth Engine: Planetary-scale geospatial analysis for everyone. *Remote Sensing of Environment*, 202, 18-27. <https://doi.org/10.1016/j.rse.2017.06.031>
- Griffiths, P., Nendel, C., Hostert, P. 2019. Intra-Annual Reflectance Composites from Sentinel-2 and Landsat for National-Scale Crop and Land Cover Mapping. *Remote Sensing of Environment*, 220, 135-51. <https://doi.org/10.1016/j.rse.2018.10.031>
- Heckel, K., Urban, M., Schratz, P., Mahecha, M.D., Schmullius, C. 2020. Predicting Forest Cover in Distinct Ecosystems: The Potential of Multi-Source Sentinel-1 and -2 Data Fusion. *Remote Sensing*, 12, 302. <https://doi.org/10.3390/rs12020302>
- INEGI (Instituto Nacional de Estadística), CONABIO (Comisión Nacional para el Conocimiento y Uso de la Biodiversidad), INE (Instituto Nacional de Ecología). 2008. Ecorregiones terrestres de México 1:1000000. Disponible en http://www.conabio.gob.mx/informacion/metadatos/gis/ecort08gw.xml?_xsl=/db/metadatos/xsl/fgdc_html.xsl&_indent=no
- Li, J., Roy, D.P. 2017. A global analysis of Sentinel-2a, Sentinel-2b and Landsat-8 data revisit intervals and implications for terrestrial monitoring. *Remote Sensing*, 9, 902. <https://doi.org/10.3390/rs9090902>
- Lima, T.A., Beuchle, R., Langner, A., Griess, V.C., Achard, F. 2019. Comparing Sentinel-2 MSI and Landsat 8 OLI Imagery for Monitoring Selective Logging in the Brazilian Amazon. *Remote Sensing*, 11, 961. <https://doi.org/10.3390/rs11080961>
- Main-Knorn, M., Pflug, B., Louis, J., Debaecker, V., Müller-Wilm, U., Gascon, F., 2017 Sen2Cor for Sentinel-2. En: *Image and Signal Processing for Remote Sensing XXIII*. Varsovia, Polonia. pp 1042704-1042701.
- Malenovský, Z., Rott, H., Cihlar, J., Schaepman, M.E., García-Santos, G., Fernandes, R., Berger, M. 2012. Sentinels for science: Potential of Sentinel-1, -2, and -3 missions for scientific observations of ocean, cryosphere, and land. *Remote Sensing of Environment*, 120, 91-101. <https://doi.org/10.1016/j.rse.2011.09.026>
- Melesse, A.M., Weng, Q., Thenkabail, P.S., Senay, G.B. 2007. Remote Sensing Sensors and Applications in Environmental Resources Mapping and Modelling. *Sensors*, 7, 3209-3241. <https://doi.org/10.3390/s7123209>
- Pesaresi, M., Corbane, C., Julea, A., Florczyk, A.J., Syrris, V., Soille, P. 2016. Assessment of the Added-Value of Sentinel-2 for Detecting Built-up Areas. *Remote Sensing*, 8, 299. <https://doi.org/10.3390/rs8040299>
- R Core Team. 2020. R: A language and environment for statistical computing. Vienna: R Foundation for Statistical Computing. Disponible en <https://www.R-project.org/>
- Ramoelo, A., Cho, M., Mathieu, R., Skidmore, A.K. 2015. Potential of Sentinel-2 spectral configuration to assess rangeland quality. *Journal of Applied Remote Sensing*, 9, 094096. <https://doi.org/10.1117/1.jrs.9.094096>
- Roteta, E., Bastarrika, A., Padilla, M., Storm, T., Chuvieco, E. 2019. Development of a Sentinel-2 burned area algorithm: Generation of a small fire database for sub-Saharan Africa. *Remote Sensing of Environment*, 222, 1-17. <https://doi.org/10.1016/j.rse.2018.12.011>
- Solórzano, J.V., Gallardo-Cruz, J.A., Peralta-Carreta, C. 2020. Potencial del acervo de imágenes Landsat disponible en Google Earth Engine para el estudio del territorio mexicano. *Investigaciones Geográficas*, 101(Abril), e59821. <https://doi.org/10.14350/ig.59821>
- Sudmanns, M., Tiede, D., Augustin, H., Lang, S. 2019. Assessing global Sentinel-2 coverage dynamics and data availability for operational Earth observation (EO) applications using the EO-Compass. *International Journal of Digital Earth*, 13(7), 1-17. <https://doi.org/10.1080/17538947.2019.1572799>
- Van der Meer, F.D., van der Werff, H.M.A., van Ruitenbeek, F.J.A. 2014. Potential of ESA's Sentinel-2 for geological applications. *Remote Sensing of Environment*, 148, 124-133. <https://doi.org/10.1016/j.rse.2014.03.022>
- Viola, D., McKay, C.P., Navarro-González, R. 2019. A Method for Monitoring Glacial Loss and Temperature Variation Using Satellite Observations: Case Study of Pico de Orizaba and Iztaccihuatl (Mexico). *Arctic, Antarctic, and Alpine Research*, 51(1), 379-396. <https://doi.org/10.1080/15230430.2019.1648163>
- Whitcraft, A.K., Becker-Reshef, I., Justice, C.O. 2015. A framework for defining spatially explicit earth observation requirements for a global agricultural monitoring initiative (GEOGLAM). *Remote Sensing*, 7, 1461-1481. <https://doi.org/10.3390/rs70201461>
- White, J.C., Wulder, M.A. 2014. The landsat observation record of Canada: 1972-2012. *Canadian Journal of Remote Sensing*, 39(6), 455-467. <https://doi.org/10.5589/m13-053>
- Wickham, H., Averick, M., Bryan, J., Chang, W., D'Agostino McGowan, L., François, R.,... Yutani, H. 2019. Tidyverse. *Journal of Open Source Software*, 4(43), 1686. <https://doi.org/10.21105/joss.01686>

- Wilson, A.M., Jetz, W. 2016. Remotely Sensed High-Resolution Global Cloud Dynamics for Predicting Ecosystem and Biodiversity Distributions. *PLoS Biology*, 14(3), e1002415. <https://doi.org/10.1371/journal.pbio.1002415>
- Wulder, M.A., White, J.C., Loveland, T.R., Woodcock, C.E., Belward, A.S., Cohen, W.B.,... Roy, D.P. 2016. The global Landsat archive: Status, consolidation, and direction. *Remote Sensing of Environment*, 185, 271-283. <https://doi.org/10.1016/j.rse.2015.11.032>
- Zhou, Y., Dong, J., Liu, J., Metternicht, G., Shen, W., You, N.,... Xiao, X. 2019. Are there sufficient Landsat observations for retrospective and continuous monitoring of land cover changes in China? *Remote Sensing*, 11, 1808. <https://doi.org/10.3390/rs11151808>