

Metodología para determinación de coeficientes de escurrimiento utilizando imágenes de acceso abierto y algoritmos de clasificación de código abierto
Methodology for determining runoff coefficients using open access images and classification open-source algorithms

D. Italibi Uruga-Tovar¹, ORCID: <https://orcid.org/0000-0003-4711-5289>

Felipe Omar Tapia-Silva², ORCID: <https://orcid.org/0000-0002-5618-7594>

Alejandra A. López-Caloca³, ORCID: <https://orcid.org/0000-0002-8426-1050>

Eugenio Gómez-Reyes⁴ ORCID: <https://orcid.org/0000-0001-8924-165X>

¹Universidad Autónoma Metropolitana, Iztapalapa, Ciudad de México, Mexico, uragaisa@gmail.com, italibiuraga@xanum.uam.mx

²Universidad Autónoma Metropolitana, Iztapalapa, Centro de Investigación en Ciencias de la Información Geoespacial, Ciudad de México, México, omartapiasilva@gmail.com, otapia@xanum.uam.mx

³Centro de Investigación en Ciencias de la Información Geoespacial, Tlalpan, Ciudad de México, México, alopez@centrogeo.edu.mx

⁴Universidad Autónoma Metropolitana, Iztapalapa, Ciudad de México, México, egr@xanum.uam.mx

Autor para correspondencia: D. Italibi Uruga-Tovar, uragaisa@gmail.com, italibiuraga@xanum.uam.mx

Resumen

Este estudio propone una metodología que utiliza imágenes Landsat-8, Sentinel-1, y Sentinel-2 para determinar cobertura terrestre y coeficientes de escurrimiento. La metodología considera características geográficas y climáticas de la región, resolución de sensores y exactitud obtenida mediante cuatro clasificadores: distancia mínima, máxima verosimilitud, mapeo espectral angular y máquinas de soporte vectorial. La metodología se aplicó en regiones en México con características diversas. La exactitud general, error de comisión y de omisión fueron obtenidos para cada combinación de clasificador y sensor. Asimismo, estos indicadores se analizaron por región, sensor y algoritmo. Presencia, exactitud, error de comisión y omisión se analizaron por cada clase de cobertura terrestre. Landsat-8 obtuvo un acuerdo promedio mayor (76.1 %), seguido por Sentinel-2 (75 %) y Sentinel-1 (38.8 %). Distancia mínima tuvo el mayor acuerdo promedio (71.2 %), seguido por máquinas de soporte vectorial con 70.5 %, mapeo angular espectral con 60.9 % y

máxima verosimilitud con 50.7 %. Esta metodología hace posible usar imágenes y programas de acceso abierto para definir criterios que permitan determinar cobertura terrestre con buena exactitud y alta resolución espacial. El resultado de la investigación muestra que, para estimar correctamente coeficientes de escurrimiento, las imágenes satelitales de acceso abierto deben ser seleccionadas con base en criterios como resoluciones del sensor, algoritmo de clasificación a ser ocupado, periodo y escala del estudio, clima, tipos y dinámica de cobertura terrestre, así como clase de cobertura dominante.

Palabras clave: coeficiente de escurrimiento, cuenca del Valle de México, bajo Bravo, bajo Grijalva, distancia mínima, máxima verosimilitud, mapeo espectral angular, máquinas de soporte vectorial, Sentinel, Landsat.

Abstract

This study proposes a methodology using Landsat-8, Sentinel-1, and Sentinel-2 images to determine Landcover and Runoff Coefficient. It considers geographic and climatic characteristics of the region, resolutions of sensors, and accuracy obtained using four classifiers: Minimum Distance, Spectral Angle Mapper, Maximum Likelihood, and Support Vector Machines. The methodology was applied to regions in Mexico with diverse characteristics. The overall accuracy, commission, and omission were obtained for each classifier-sensor combination. These indicators were analyzed by region, sensor, and algorithm. Presence,

accuracy, error of commission, and omission of cover were analyzed according to land cover class. Landsat-8 had the highest average accuracy (76.1 %), followed by Sentinel-2 (75 %), and Sentinel-1 (38.8 %). Minimum distance had the highest accuracy (71.2 %), followed by Support Vector Machines with 70.5 %, Spectral Angle Mapper with 60.9 %, and Maximum Likelihood with 50.7 %. This methodology makes it possible to use open-access satellite images and programs to define criteria for determining land cover with good accuracy and high spatial resolution. The results of our research show that to estimate runoff coefficients, open-access satellite images must be selected based on criteria such as sensor resolutions, classification algorithm to be used, period and scale of the study, climate, types, and dynamics of land coverage, as well as the dominant coverage class.

Keywords: Runoff Coefficient, Mexico's valley basin, Bajo Bravo, Bajo Grijalva, minimum distance, maximum likelihood, spectral angle mapper, support vector machines, Sentinel, Landsat.

Recibido: 27/11/2019

Aceptado: 22/09/2020

Introducción

El coeficiente de escurrimiento (CE) se utiliza para calcular la escorrentía y el balance hídrico, así como para estudiar otros factores hidrológicos (Savenije, 1996; Sivapalan, BlöschlMerz, & Gutknecht, 2002; Merz, Blöschl, & Parajka, 2006). El CE se obtiene utilizando capas espaciales de cobertura terrestre (CT), textura del suelo (TS) y precipitación media (PM) (DOF, 2015). Un problema con la aplicación de este método, especialmente con respecto a CT, es que estas capas por lo general no están actualizadas, tienen errores significativos o no están disponibles. Una opción para abordar este problema es obtener CT a partir de una clasificación válida de imágenes de satélite y, por lo tanto, obtener CE. Diversos estudios han explorado cómo definir CE (o variables similares) mediante el uso de sensores remotos para determinar CT. Rawat, Mishra y Ahmad (2017) utilizaron imágenes de *Linear Imaging Self Scanning Sensor* (LISS-III) para obtener capas de CT, en función de las cuales encontraron números de curva (similares a CE). Zeng, Tang, Hong, Zeng y Yang (2017) obtuvieron CT de MODIS para actualizar el mapa de números de curva global y calcular la escorrentía en función de la precipitación y la TS. Che, Liang, Li y Ma (2018) clasificaron los tipos de vegetación utilizando imágenes Landsat-8 (L8) con máquinas de soporte vectorial (MSV), en función de las cuales encontraron el CE. Kurczyn-Robledo, Kretschmar y Hinojosa-Corona (2007) utilizaron imágenes de Ikonos para calcular el índice de vegetación diferencial normalizado (NDVI), y así encontraron la escorrentía

superficial potencial en la serranía Matcuatai, México. También se han realizado estudios utilizando sensores remotos con productos relacionados con la escorrentía o similares (Weng, 2001; Immerzeel, Droogers, De-Jong, & Bierkens, 2009; Milewski *et al.*, 2009; Stisen & Sandholt, 2010).

Aunque es posible calcular CE a partir de imágenes de satélite, todavía no se dispone de criterios bien definidos para seleccionar una imagen y un algoritmo de acuerdo con las características particulares del área de interés. Los diversos tipos de resolución de imagen es un aspecto que se puede considerar para definir estos criterios. Por ejemplo, la resolución temporal (RT) permite analizar si el número de imágenes por unidad de tiempo es suficiente para las necesidades de un proyecto (Chuvieco, 1991; Eastman, 2003). Las regiones que son muy heterogéneas deben utilizar datos con una alta resolución espacial (RE) (Herold, Latham, Di-Gregorio, & Schmallius, 2006; Liu & Tian, 2010; Tran, Julian, & De-Beurs, 2014; Lei *et al.*, 2016; Chen *et al.*, 2015; Abdikan, Sanli, Ustuner, & Calò, 2016; Chatziantoniou, Psomiadis, & Petropoulos, 2017). La resolución espectral (RS) define las características del CT que serán percibidas por el sensor. Con respecto a los sensores de acceso abierto, L8 y Sentinel-2 (S2) registran información de la luz reflejada en bandas ópticas y de la región infrarroja. El radar de apertura sintética a bordo del Sentinel-1 (S1) registra las propiedades dieléctricas y la forma de CT, y no es afectado por nubes, ya que es sensible a la región electromagnética de las microondas (Zuhlke *et al.*, 2015; Grizonnet *et al.*, 2017).

Los objetivos del estudio son definir las características que debe tener una imagen satelital de acceso abierto para obtener CT y así tener CE, y definir qué combinaciones de sensor con algoritmos clasificadores comunes funcionan mejor para determinar CE dadas las características hidrológicas del estudio.

Metodología

La metodología propuesta en este artículo se utilizó para definir criterios de selección del sensor de acceso abierto más adecuado en función de características de estos sensores, características hidrológicas y geográficas del área de estudio involucrada en el cálculo del CE y obtenida con la combinación clasificador-algoritmo. Con el fin de incluir diversas características climáticas y geográficas, la metodología se aplicó a las siguientes regiones de México: bajo Grijalva (BG, clima tropical húmedo con baja densidad poblacional); Valle de México (VM, altamente urbanizado, altiplano central), y San Juan-bajo Bravo (BB, semiárido con cultivos de regadío y algunas zonas urbanas).

Esta sección está estructurada en las siguientes secciones: área de estudio; criterios base para la selección de imágenes; procesamiento y

evaluación de la clasificación de CT; selección de la imagen que se utilizará para calcular CE, y cálculo del CE.

Área de estudio

La Figura 1 muestra las regiones BG, VM y BB, que tienen características hidrológicas contrastantes y representan diferentes zonas geográficas, y climáticas en México (Rascón & Rivera, 2005). La cuenca BG forma parte de la zona noroeste de la Región Hidrológica Grijalva-Usumacinta, al sur del territorio mexicano (Conagua, 2007). Esta región tiene un clima húmedo tropical (García, 1998), bajo grado de alteración y alto nivel de presión hídrica (Cotler, Garrido, Bunge, & Cuevas, 2010); los trabajadores asalariados de esta región se dedican principalmente a actividades industriales, pero alrededor del 30 % del total recibe menos del salario mínimo (INEGI, 2009); el núcleo de población más importante es la ciudad de Villahermosa, con más de 300 000 habitantes (INEGI, 2015); los parámetros hidrológicos de esta cuenca exorreica son PM 1 500-4 500 mm (Cuervo-Robayo *et al.*, 2014), escorrentía media anual de 1 000-2 000 mm (Jiménez & Maderey, 1992), evapotranspiración de 1 401-1 500 (Maderey, 1990) y CE de 0-30 % (INEGI, 2010). VM se encuentra en el altiplano central de la región hidrológica homónima (CONAGUA, 2007); esta región tiene clima templado (García, 1998),

grado extremo de alteración y nivel de presión hídrica medio (Cotler *et al.*, 2010); la cuenca muestra alta urbanización y presenta la densidad de población más alta entre las zonas del estudio; un 70 % de la población se dedica a actividades comerciales y de servicios (INEGI, 2009); el núcleo de población más importante es la Ciudad de México y su zona metropolitana, con más de 19 millones de habitantes (INEGI, 2015); esta cuenca exorreica tiene los parámetros hidrológicos: PM de 400-1 500 mm (Cuervo-Robayo *et al.*, 2014), escorrentía media anual de 10-500 mm (Jiménez & Maderey, 1992), evapotranspiración de 400-800 (Maderey, 1990) y CE de 0-30 % (INEGI, 2010). BB está en el norte en las regiones hidrológicas Bravo Conchos y río San Juan (CONAGUA, 2007); tiene un clima semiárido (García, 1998), alto grado de alteración y de alta presión hídrica (Cotler *et al.*, 2010); en esta parte del territorio, la densidad poblacional varía en un intervalo de 23 y 80 habitantes/km²; predominan las actividades industriales y otros empleos asalariados (INEGI, 2009); el núcleo de población más importante es la ciudad de Monterrey, con una población de 1 109 171 habitantes (INEGI, 2015). Los parámetros hidrológicos de esta cuenca exorreica son PM de 500-800 mm (Cuervo-Robayo *et al.*, 2014), escorrentía media anual de 10-50 mm (Jiménez & Maderey, 1992), evapotranspiración de 400-500 (Maderey, 1990) y CE de 0-20 % (INEGI, 2010).

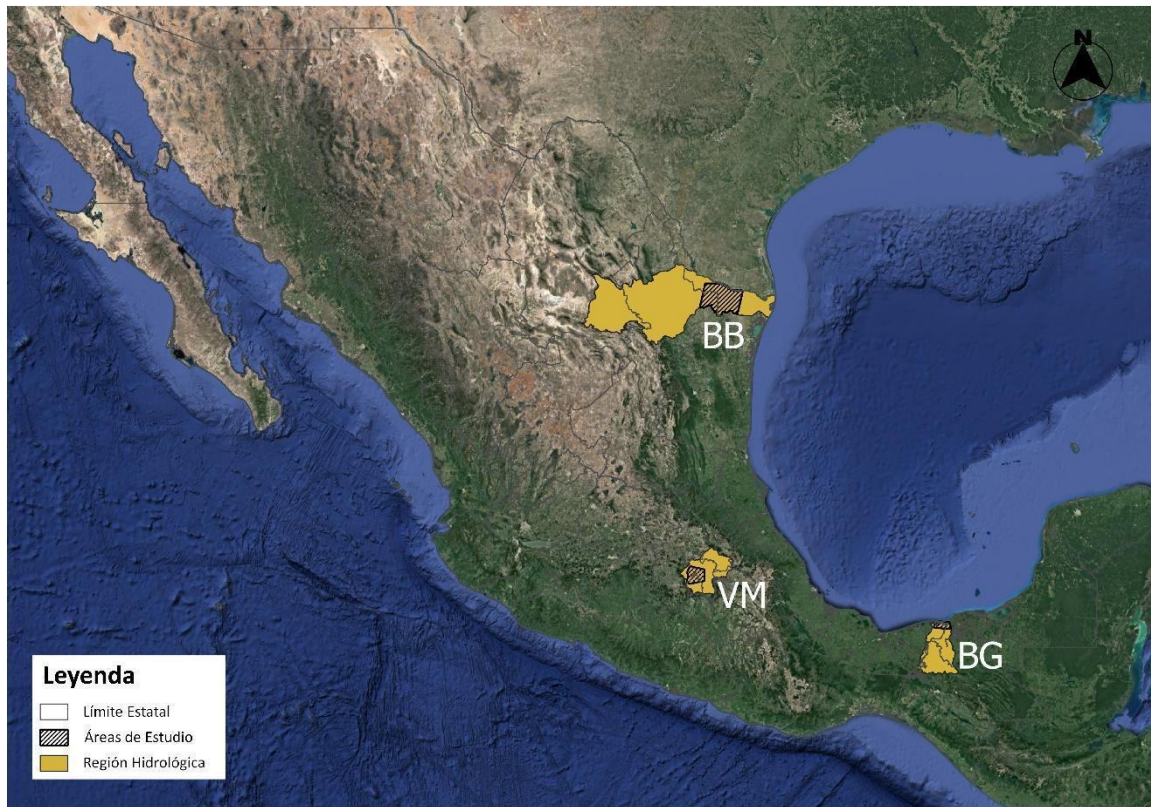


Figura 1. Ubicación de las regiones de estudio BB, BG y VM. Fuente: diseño propio con datos de CONAGUA (2007).

Recursos de información

La Tabla 1 muestra información de las imágenes L8, S1 y S2 que se seleccionaron para cada región y se descargaron

de <https://earthexplorer.usgs.gov/> y <https://scihub.copernicus.eu/>. Las imágenes corresponden al final de la temporada de lluvias para poder incluir CT durante un periodo que tiene un alto nivel de escorrentía. Para efectos de comparación, se utilizaron las fechas más cercanas posibles a septiembre. Las áreas de las imágenes que tienen la mayor superposición espacial se seleccionaron para cada región. También se seleccionaron con base en el criterio de nubosidad baja. La Tabla 1 muestra las coordenadas mínimas y máximas, y las áreas con sobreposición de imágenes de los tres sensores de estudio para cada una de las regiones. También se indica el identificador y la fecha de cada una de las imágenes.

Tabla 1. Imágenes utilizadas en el estudio.

Región	Sensor/fecha/identificación de la imagen	Superposición de áreas en las imágenes		
		Coordenadas		Área (km ²)
		Mínimo	Máximo	
BB	LS8/ 8 Sept. 2016 LC08_L1TP_027042_20160908_20170222_01_T1	99.0217 N, 25.4894 O	97.9482 N, 26.219 O	5 915
	S1/ 25 Sept. 2016 S1A_IW_GRDH_1SDV_20160925T004143_20160925T004208_013202_01500A_8E60			
	S2/ 9 Sept. 2016			

	S2A_OPER_MSI_L1C_TL_SGS__20160909T2 21922_A006358_T14RNP. S2A_OPER_MSI_L1C_TL_SGS__20160909T2 21922_A006358_T14RMP			
BG	LS8/ 24 Sept. 2016 LC80220472016249LGN00	93.2607 N, 18.2439 O	92.7732 N, 18.4422 O	688.6
	S1/ 27 Sept. 2016 S1A_IW_GRDH_1SDV_20160927T002314_2 0160927T002340_013231_0150F0_905A			
	S2/ 21 Aug. 2016 S2A_OPER_MSI_L1C_TL_SGS__20160821T2 14512_A006086_T15QVA S2A_OPER_MSI_L1C_TL_SGS__20160821T2 14512_A006086_T15QWA			
VM	L8/17 sept. 2016 LC80260472016261LGN00	99.3396 N, 19.3129 O	98.9069 N, 19.7256 O	1 676
	S1 / 25 Sept. 2016 S1A_IW_GRDH_1SDV_20160930T004826_2 0160930T004851_013275_015252_C5B5			
	S2 / 9 Sept. 2016 S2A_OPER_PRD_MSIL1C_PDMC_20160912T 231518_R069_V20160909T170302_201609 09T17110			

Criterios básicos para la selección de imágenes

Con el fin de identificar si cada sensor puede ayudar a determinar la CT del territorio mexicano y cuáles son las ventajas proporcionadas por cada uno de ellos, se hizo un análisis comparativo para RE, RT, y RS. El análisis de RS de imágenes ópticas incluyó la sensibilidad del sensor para las firmas espectrales relacionadas con el CE: agua del grifo, hormigón, arena gris parduzco y vegetación. Para ello se generó un gráfico (Figura 2, incluida en la sección de Resultados) con las firmas mencionadas y los rangos del espectro electromagnético de cada sensor (Baldrige, Hook, Grove, & Rivera, 2009; ESA, 2013a; ESA, 2013b; USGS, 2016). Para S1 se utilizaron las polarizaciones vertical-horizontal (VH), vertical-vertical (VV) y su resta (VV-VH) de acuerdo con Abdikan *et al.* (2016).

Procesamiento y evaluación de la clasificación de CT

Para L8 y S2 se realizó una corrección radiométrica y atmosférica con el método DOS, utilizando el QGIS 2.18 "Semi-Automatic Classification Plugin" (SCP) (Song, Woodcock, Seto, Lenney, & Macomber 2001; Congedo, 2016). Para S1, la eliminación de ruido, la calibración, el barrido

múltiple y las correcciones del terreno se efectuaron utilizando la "Herramienta SNAP" (ESA, 2013a). Las clases de CT se definieron con base en las características de cada región, tomando como referencia los datos oficiales del INEGI sobre uso de suelo y vegetación "serie V", así como la tabla de correspondencia CT-K (INEGI, 2013). El plugin SCP se utilizó para crear las regiones de interés (Solis *et al.*, 2005), definidas como cuerpos de agua, asentamientos humanos, suelo desnudo, tierras de cultivo-pastos, nubes, sombras, mezquite xerófito, arbustos espinosos, vegetación sumergida, zona inundada, bosque y arbustos.

Si bien existen varios algoritmos de clasificación supervisados, el estudio se limita a distancia mínima (DM), máxima probabilidad (MP), mapeo de ángulo espectral (MAE) y MSV. DM es simple en términos matemáticos. Calcula la distancia euclidiana a partir de las firmas espectrales, asignando la clase correspondiente a la firma más cercana al píxel (Wacker & Landgrebe, 1972; Richards & Xiuping, 2013; Congedo, 2016). MP calcula distribuciones de probabilidad de acuerdo con el teorema de Bayes (Sudhakar, Sridevi, Ramana, Rao, & Raha, 1999; Bruzzone & Prieto, 2001; Richards & Xiuping, **2013**; Zhao & Zhao, 2013; Jia *et al.*, 2014). MAE calcula el ángulo entre las firmas espectrales de los píxeles de la imagen y las firmas espectrales de entrenamiento (Kruse *et al.*, 1993). MSV define la superficie de separación entre dos clases con base en la definición de vectores de soporte (Manning, Raghavan, & Schuetze, 2009; Theodoridis & Koutroumbas, 2008; Mountrakis, Im, & Ogole, 2011). Los cuatro algoritmos se aplicaron a cada región utilizando de 25 a 30 áreas de entrenamiento por clase, lo que correspondió a un

muestreo del 2 al 5 % del área total. Las áreas de entrenamiento se seleccionaron a partir de un muestreo aleatorio estratificado de cada tipo de cobertura. Se aplicaron DM y MAE con SCP-QGIS, MP con GRASS GIS y MSV con Orfeo-QGIS.

El acuerdo que presenta una clasificación con el valor considerado real en el terreno depende de la RE, RT y la resolución radiométrica (RR) de cada sensor (Rogan & Chen, 2004). La validación de la CT obtenida se realizó tomando datos de referencia del Instituto Nacional de Estadística y Geografía (INEGI), así como con imágenes de alta resolución de *Google Earth* y *Bing Aerial* (Abdikan *et al.*, 2016; Yu & Gong, 2012). Se generaron aleatoriamente al menos 30 puntos de validación por clase de CT y los resultados individuales de cada combinación de algoritmo-sensor-región se validaron con esos puntos según Abdikan *et al.* (2016), y Yu y Gong (2012). Posteriormente, se hicieron los cálculos usando la matriz población imparcial (Pontius Jr. & Santacruz, 2014) para validar las clasificaciones corrigiendo sesgos de muestreo (Pontius Jr. & Millones, 2011; Pontius Jr. & Santacruz, 2014; Estoque *et al.*, 2018; Huang, Huang, Pontius, & Tu, 2018). Se aplicaron las ecuaciones propuestas por Pontius Jr. y Santacruz (2014) a cada combinación de algoritmo-sensor para cada región con el fin de obtener los indicadores: matriz poblacional insesgada, acuerdo general (AG), omisión general (OG), comisión general (CG), acuerdo de cobertura (AC), omisión de cobertura (OC) y comisión de cobertura (CC). Para sintetizar los resultados, se obtuvo el AG promedio para cada región hidrológica, así como para cada sensor y cada algoritmo de clasificación.

Cálculo de CE

El primer paso para calcular CE fue seleccionar la imagen CT. Para ello se utilizan los criterios resultantes del apartado "Recursos de información", así como los resultados de las clasificaciones con mayor AG. Después de eso, el cálculo se realizó de acuerdo con las siguientes ecuaciones:

CE se expresa en función de PM y el parámetro K, como se muestra en (DOF, 2015):

$$Ce = \frac{K(P-250)}{2000} \text{ si } K \leq 0.15 \quad (1)$$

$$Ce = \frac{K(P-250)}{2000} + \frac{K-0.15}{1.5} \text{ si } K > 0.15 \quad (2)$$

K se obtiene de acuerdo con tablas que combinan CT y TS, como las reportadas por Solis *et al.* (2005).

La Ecuación (1) y la Ecuación (2) se aplicaron a las imágenes seleccionadas. Se transformaron en un algoritmo de decisión para calcular CE, que utilizó un ráster de factor K obtenido de las tablas de

correspondencia de Solis *et al.* (2005), un ráster de PM anual obtenido con interpolación de regresión-kriging de acuerdo con lo reportado por Tapia-Silva (2019) y un ráster de TS (INIFAP, 1995). El uso de tablas de correspondencia es un método que se sugiere en países como México para la determinación del CE (DOF, 2015). Estas tablas muestran la relación entre el parámetro K y TS (INIFAP, 1995; Solís *et al.*, 2005).

Resultados y discusión

Criterios base para la selección de imagen

La Figura 2 presenta una comparación de las bandas espectrales seleccionadas para los sensores ópticos L8 y S2. La sección superior muestra el comportamiento de las firmas espectrales del agua del grifo, concreto, arena gris parduzca y vegetación (Baldrige *et al.*, 2009). La longitud de onda, en micrómetros, se muestra en el eje x y la reflectancia en el eje y. Líneas punteadas atraviesan y cruzan las longitudes de onda que son percibidas por cada sensor. Este gráfico permitió seleccionar las bandas del óptico sensibles al rango del espectro electromagnético, pues la reflectancia varía en función del tipo de CT. Se seleccionaron las bandas

2, 3, 4, 5, 6 y 7 para clasificar CT usando L8. Dado que la banda 1 se usa para estudiar aguas poco profundas, se incluyó sólo en la región BG. Se seleccionaron las bandas 2, 3, 4, 5, 6, 7, 8, 8A, 11 y 12 para clasificar CT utilizando S2. También se incluyó 1 con S2 para la región BG con el fin de mejorar la definición de cuerpos de agua.

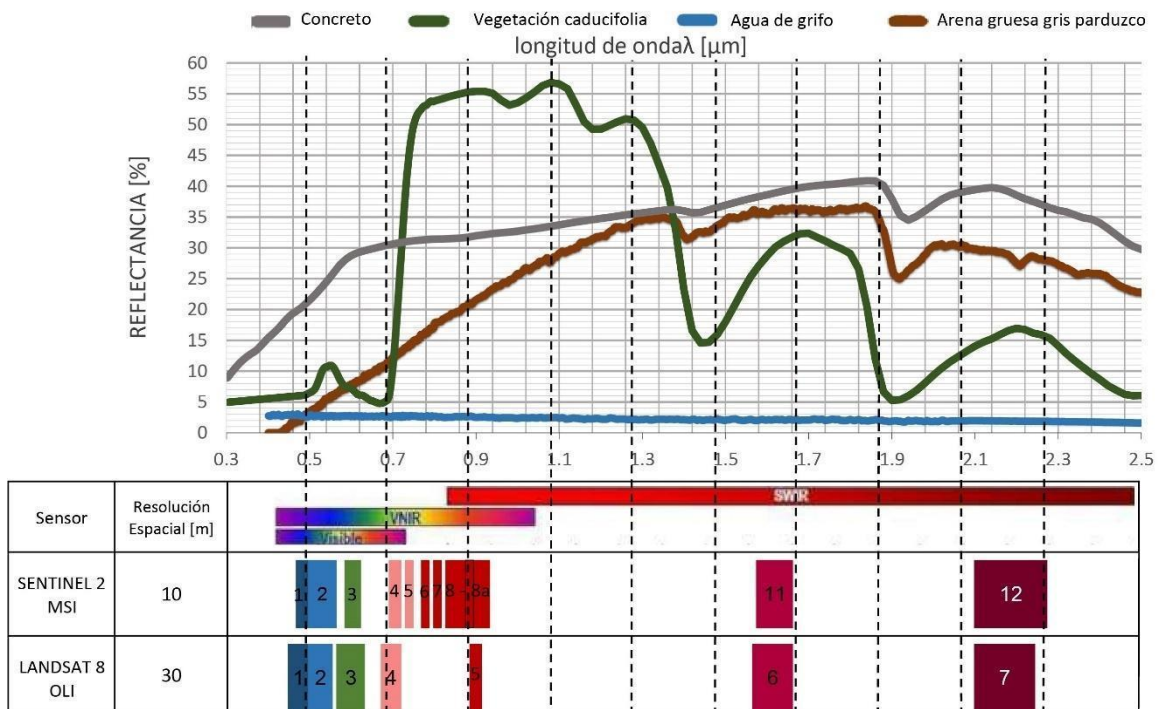


Figura 2. Comparación espectral de los sensores L8 y S2 para determinar CT. Desarrollado por los autores con información de Baldridge *et al.* (2009), ESA (2013a), ESA (2013b) y USGS (2016).

Procesamiento y evaluación de la clasificación CT

La Tabla 2 muestra el AG de todas las combinaciones de algoritmo-sensor para cada una de las regiones, en orden de mayor a menor. La Región BG tuvo el AG promedio más alto para todas las clasificaciones (70.3 %), mientras que BB resultó en 61.5 % y VM en 58.2 %. El tamaño del área seleccionada para cada región puede ser un factor de influencia, dado que el AG más alto corresponde al área de análisis de menor tamaño. En BG, los cuerpos de agua cubren una gran área, lo que podría haber influido en la obtención de un alto AG, pues una banda extra ayudó a identificarlos mediante sensores ópticos, además de que las imágenes de radar son útiles para detectar agua. Para el caso de VM, la dinámica de cambio y la complejidad del área pueden haber influido en el AG obtenido para esa región, que tuvo el promedio más bajo de las regiones de estudio. La parte inferior de la Tabla 2 muestra los resultados de cada sensor. L8 presentó el promedio más alto de AG, con 76.1 %, a pesar de tener la RE más baja. Eso le da la distinción de ser un sensor muy útil para definir tipos de CT, así como otros parámetros biofísicos. El desempeño de S2 fue similar, con un AG del 75. S1 dio como resultado un AG del 38.8 %, que es mucho más bajo que los sensores mencionados. Los sensores que obtuvieron el AG más alto fueron los que tienen la RS más alta. El bajo acuerdo encontrado con S1 puede deberse al uso de sólo tres bandas para la clasificación, lo que difiere mucho de lo obtenido por Abdikan *et al.* (2016), quienes lograron los mejores resultados con la combinación

de las bandas VV, VH y la resta de VV-VH. DM fue el clasificador con mejor desempeño, con AG de 71.2 %, seguido de MSV con 70.5 % y MAE con 60.9 %. El desempeño más bajo fue MP, con 50.7 %.

Tabla 2. AG de la clasificación CT para cada combinación sensor-algoritmo implementada en este estudio.

BB			BG			VM		
Sensor	Algtm*	AG (%)	Sensor	Algtm*	AG (%)	Sensor	Algtm*	AG (%)
S2	DM	83.5	L8	MSV	90.5	L8	MAE	84.6
S2	MSV	81.5	L8	MP	88.6	L8	DM	83.8
S2	MAE	80.8	S2	MSV	87.9	L8	MSV	80.1
L8	MSV	78.2	S2	DM	86.2	L8	MP	79.4
S2	MP	77.4	L8	MAE	86.1	S2	MAE	71.5
L8	DM	76.9	S2	MAE	84.2	S2	DM	67
S1	MSV	68.6	S2	MP	84.1	S2	MSV	57.3
S1	DM	62.3	L8	DM	81.5	S1	DM	46
L8	MAE	57.9	S1	DM	53.7	S1	MSV	41.6
S1	MAE	26	S1	MSV	48.7	S2	MP	39.2
L8	MP	26	S1	MAE	28	S1	MAE	27
S1	MP	18	S1	MP	23	S1	MP	21
Promedio BB = 61.5			Promedio BG = 70.3			Promedio VM = 58.2		
Promedio por sensor				Promedio por algoritmo				

L8 =	S2 =	S1 =	DM=	MSV=	MAE=	MP = 50.7
76.1	75	38.8	71.2	70.5	60.9	

*Algtm: algoritmo.

Para BB, ocho combinaciones tuvieron AG superior al 60 %. El AG más alto en esta región se obtuvo con S2 combinado con MD, MSV y MAE (en ese orden), y el AG más bajo se logró con MP combinado con sensores L8 y S1. Con base en estos resultados, se recomienda S2 para regiones que son similares a BB (poca precipitación y gran presencia de tierras de cultivo irrigadas). La RE de S2 facilita la identificación de pequeños objetos de interés, por lo que fue útil para esta región, que contiene grandes contrastes territoriales.

Para la región BG, ocho combinaciones alcanzaron un AG superior al 80 %: L8 y S2 combinadas con los cuatro algoritmos. El AG más alto fue del 90.5 %, que se obtuvo con L8-MSV y que representó el mejor desempeño de todas las combinaciones en este estudio. S2 con MD terminó en cuarto lugar en general, a pesar de que su AG promedio fue más alto que el de los otros algoritmos. Por el contrario, el MP para esta región tuvo el segundo AG más alto, aunque tuvo un desempeño pobre en otras combinaciones. Las imágenes seleccionadas de BG tienen una cobertura de nubes del 1 al 3 %, y no se pudo encontrar una imagen sin nubes para esas fechas. Además, la cobertura de nubes y sus sombras presentaron el mayor acuerdo en esta región, lo que afectó positivamente el desempeño general. Por lo general, el uso de S1 puede ser ventajoso para regiones como BG, donde hay altas precipitaciones y nubosidad, ya

que su tecnología es insensible a esos factores. Sin embargo, en nuestro caso esta ventaja no significó mejoras en el AG y ello puede relacionarse con el hecho de que las imágenes seleccionadas presentaron los porcentajes de nubosidad antes mencionados.

Para la región de VM, seis combinaciones tuvieron un AG de más del 60 %. L8 combinado con los cuatro algoritmos resultó en el AG más alto, aunque se usaron más bandas con S2. Ello indica que esta combinación es adecuada para regiones con configuraciones espaciales similares a VM (predominantemente urbanas). Esta combinación presentó mayor AG con MAE y MD. El AG fue inferior al 60 % para S2 combinado con MSV y MP. En esta región, los peores resultados fueron para S1-MP, S1-MAE y S2-MP.

La Figura 3 presenta (en % del dominio) la presencia de cobertura (PC), representada por un cuadrado negro. En la misma figura se muestran AC (barras verdes), OC (barras rojas) y CC (barras azules) para las clasificaciones con mejor desempeño en cada región. Para BB, agricultura-pastizal presentó la mayor PC (55.7) y AC (51.4) con la combinación S2-MD. El AC para asentamientos humanos fue 3.0. Para esta categoría, CC fue mayor que OC, lo cual indica que esta categoría fue sobreestimada. El mezquite xerofítico y los arbustos espinosos tienen firmas espectrales muy similares, lo que resultó en valores altos de OG y CC. Los errores para suelo desnudo pueden deberse a la confusión con las áreas donde se han plantado cultivos recientemente. Por lo tanto, una gran cantidad de píxeles se asignaron a la clase suelo desnudo (1.8 de CC) y como resultado se sobreestimó la categoría. Para BG, el suelo

desnudo fue la cobertura del suelo con menor AC y PC, con 1.1 % en ambos valores. El CC para tierras de cultivo-pastos (0.9) y zonas de inundación (2.5) puede deberse a que tienen firmas espectrales muy similares cuando los cultivos comienzan a crecer en esas áreas. Los manglares se distinguen claramente en la imagen y obtuvieron un AC alto (13 % para el 15.5 % de AC). Los cuerpos de agua obtuvieron un CC bajo (0.1 %) ya que prácticamente no se presentó confusión espectral. Los asentamientos humanos fueron subestimados, pues el CC para esta clase fue menor que el OC, con un AC del 2.8 %.




Figura 3. AC, PC, OC y CC de las clasificaciones de mejor desempeño en el análisis (como % del dominio).

En VM predominaron zonas urbanas con AC alto (46.3 % con una PC del 49.9 %), y se clasificaron de modo correcto por la combinación L8-MAE. El suelo desnudo, los bosques y los cuerpos de agua obtuvieron AC y PC más bajos. Las tierras de cultivo, pastos y arbustos obtuvieron un PC bajo. Para estos casos, AC superó la mitad de la PC. Al igual que en las otras regiones, la OC fue mayor para suelo desnudo y tierras de cultivo-pastos, y esta última se confundió con arbustos. Las áreas arbustivas y urbanas se subestimaron, con CC de 4.9 y 3.6 %, respectivamente. Las clases restantes se subestimaron, como lo indica un OC menor que CC.

En todas las regiones de estudio, la clase dominante hizo posible identificar áreas de entrenamiento con un alto número de píxeles y una firma espectral homogénea, lo que resultó en valores de AC altos. Esta relación proporcional entre AC y PC se reflejó en el suelo desnudo, que presentó AC y PC bajos. Si bien sombras y nubes dieron como resultado niveles altos de AC, estas no se expresan como valores de CE y, además, dificultan la determinación adecuada del mismo al impedir la identificación de CT en el sitio.

La Tabla 3 presenta los resultados de PC de las combinaciones de sensor-clasificador para las tres regiones. Las combinaciones con el AG más alto están señaladas con negritas (S2-DM-BB, L8-MSV-BG y L8-MAE-

VM). Para BB, L8-MSV y S1-MSV se trata de las combinaciones con PC que fueron más similares a la que obtuvo la PC más alta. Las combinaciones con PC que fueron menos similares a aquellas con la PC más alta fueron L8-MP y S1-MP. S1-MAE y S1-DM no son recomendables porque sobreestimaron o subestimaron una de las clases estudiadas.

Tabla 3. Resultados de PC, por categoría, para las combinaciones de sensor y clasificador aplicadas a las regiones BB, BG y VM (en % del dominio).

		PC por categoría (ver el significado de los números debajo de la tabla)												
		1	2	3	4	5	6	7	8	9	10	11	12	13
Sensor/ algoritmo		BB												
L8	DM	0.61	4.39	21.93	6.21	49.1	16.81	0.37	0.59	-	-	-	-	-
	MAE	0.45	4.04	24.29	6.96	41.56	20.37	0.5	1.84	-	-	-	-	-
	MP	0.42	4.92	19.64	55.7	17.71	0	1.09	0.53	-	-	-	-	-
	MSV	0.66	3.8	20.6	5.8	50.64	16.34	1.47	0.69	-	-	-	-	-
S1	DM	34.2	2.93	11.01	16.4	25.46	10.09	-	-	-	-	-	-	-
	MAE	15.2	17.3	14.9	17.4	23.58	11.62	-	-	-	-	-	-	-
	MP	0	0	0	100	0	0	-	-	-	-	-	-	-
	MSV	0.89	2.3	20.25	4.78	44.81	26.96	-	-	-	-	-	-	-
S2	DM	0.4	3.3	16.23	5.92	55.64	17.93	0.36	0.21	-	-	-	-	-
	MAE	0.42	2.78	19.65	6.22	46.4	21.74	0.58	2.22	-	-	-	-	-

	MP	0	8.54	30.96	4.09	55.87	0	0.38	0.15	-	-	-	-	-
	MSV	0.27	3.65	27.73	4.3	51.63	11.51	0.65	0.26	-	-	-	-	-
BG														
L8	DM	7.58	2.31	-	2.74	17.77	-	1.3	1.73	18.2	29.9	18.5	-	-
	MAE	9.29	1.51	-	1.76	21.07	-	1.73	4.73	17.7	26.7	15.5	-	-
	MP	7.03	8.9	-	3.62	20.48	-	4.73	1.78	14.2	23	16.3	-	-
	MSV	7.69	2.64	-	1.08	21.12	-	2.99	2.51	15.5	27.5	18.9	-	-
S1	DM	6.99	14.7	-	10.2	14.32	-	-	-	15.2	19.7	18.9	-	-
	MAE	11.3	13.7	-	9.39	12.64	-	-	-	20.3	14.2	18.6	-	-
	MP	-	4.14	-	-	57.3	-	-	-	-	38.6	-	-	-
	MSV	8.23	1.56	-	20.5	24.97	-	-	-	28	-	16.7	-	-
S2	DM	7.83	1.14	-	1.55	22.25	-	-	-	18.6	27.6	21	-	-
	MAE	8.29	0.77	-	1.12	18.62	-	-	-	15.9	34	21.3	-	-
	MP	7.84	6.05	-	5.77	22.56	-	-	-	16.2	23.6	18	-	-
	MSV	7.97	3.95	-	3.64	20.61	-	-	-	19.4	26.9	17.5	-	-
VM														
L8	DM	1.21	50.5	-	13	17	-	2.67	0.91	-	-	-	5.68	9.04
	MAE	1.1	49.9	-	11.8	11.77	-	2.92	3	-	-	-	7.29	12.3
	MP	1.11	58.8	-	6.67	16.86	-	1.68	1.01	-	-	-	4.6	9.32
	MSV	2	59.3	-	6.49	14.57	-	3.3	1.22	-	-	-	5.16	7.97
S1	DM	2.27	35.8	-	10.5	13.96	-	-	-	-	-	-	24.3	13.2

	MAE	20.6	31.1	-	17.4	12.73	-	-	-	-	-	-	10.1	8.19
	MP	2.08	0	-	0	0	-	-	-	-	-	-	0	97.9
	MSV	2.1	51.4	-	9.86	12.1	-	-	-	-	-	-	8.85	15.7
S2	DM	2.09	45.3	-	12.3	23.92	-	1.07	0.91	-	-	-	6.64	7.83
	MAE	1.06	43	-	14.4	20.39	-	3.25	2.94	-	-	-	5.41	9.64
	MP	0.88	46.9	-	25	8.57	-	0.77	0	-	-	-	16.7	1.16
	MSV	0.88	45.5	-	7.15	13.37	-	0.97	20.2	-	-	-	4.26	7.69

1 = cuerpos de agua; 2 = asentamientos humanos; 3 = suelo desnudo; 4 = tierras de cultivo-pastos; 5 = nubosidad; 6 = sombras; 7 = mezquite xerófito; 8 = arbustos espinosos; 9 = manglares; 10 = vegetación sumergida; 11 = zonas inundables; 12 = bosque; 13 = arbusto.

Para la región BG, las PC obtenidas con S2-MSV y S2-DM fueron similares a las obtenidas con L8-MSV (que tuvo el mayor AC). Las combinaciones que sobrestimaron o subestimaron PC fueron todas las combinaciones con S1. Por lo tanto, como se observó previamente, usar S1 para regiones similares a BG (tropical húmedo) con condiciones de nubosidad menores a 3 % puede resultar en errores considerables que deberían corregirse. La nubosidad frecuente reduce de forma significativa la capacidad de utilizar imágenes ópticas y de acuerdo con los hallazgos, estas pueden ocuparse con nubosidad menor al 3 %. Así, no recomendamos la combinación L8-MP para estudiar asentamientos humanos en regiones similares a BG, ya que puede sobrestimar la PC.

Para la región VM, las PC obtenidas con L8-MAE fueron comparables a S1-MSV y S2-MAE. Las combinaciones que más se diferenciaron de lo

obtenido con L8-MAE fueron S1-MAE, S1-MD y S2-MP, por lo que no se recomiendan. Las PC obtenidas con L8 fueron similares con todos los algoritmos probados, lo que es un fuerte argumento para recomendar el uso de este sensor con cualquiera de los clasificadores para regiones donde predomina la cobertura de suelo urbano.

Cálculo de CE

En la Tabla 4 se muestran los factores tomados en cuenta para seleccionar la imagen más útil para el cálculo de CE: inicio del periodo de estudio, RT, RE, RS, y sensibilidad a condiciones climáticas. La RT de S2 (cinco días) fue mejor que la de L8 (16 días) y S1 (12 días). S2 comenzó a generar imágenes en 2015 y L8 en 2012. L8 se puede complementar con la serie Landsat, que está disponible desde 1972. Las imágenes S1 están disponibles para todo México desde 2016. Mientras que S1 y S2 tienen la desventaja de haber sido lanzadas recientemente, su RE es mejor que la de L8 lo que permite distinguir CT con presencia pequeña. Por ejemplo, en BB, la RE de S2 permitió clasificar pequeñas áreas con alto contraste. Sin embargo, se debe considerar el tamaño de la región hidrológica de estudio, ya que un alta RE requiere un mayor tiempo de procesamiento y mayor capacidad de cálculo.

Tabla 4. Factores para seleccionar una imagen para la determinación de CT con el fin de obtener CE.

Factor	Sensor		
	L8 OLI	S1 SAR	S2 MSI
Inicio del periodo de estudio de la investigación a realizar Apto para estudios	1972 *	2016	2015
	Histórico	Actual	Actual
RT [d] Apto para estudios	16	12	5
	Quincenal	Quincenal	Semanal
RE [m] Apto para estudios	30-15	10	10
	Regional/local	Regional/local	Regional/local
Rango de RS [μ m] Adecuado para tipo de CT	0.48-2.2	37 500-75 000	0.44-2.19
	Cuerpos de agua, vegetación, suelo desnudo y asentamientos humanos	Cuerpos de agua, vegetación, suelo desnudo y asentamientos humanos	Cuerpos de agua, vegetación, suelo desnudo y asentamientos humanos
Sensibilidad a condiciones climáticas Apto para estudios	Sí	No	Sí
	Regiones con poca nubosidad	Regiones con gran nubosidad	Regiones con poca nubosidad
(%) AG promedio en el presente estudio	76.10	38.75	75.04

Los tres sensores pudieron distinguir las cuatro categorías principales de CT en el estudio: agua, suelo desnudo, asentamientos humanos y vegetación. El mayor número de bandas en S2 no resultó en un mayor AG. Asimismo, las tres bandas en S1 no proporcionaron buenos resultados de clasificación. Si bien este sensor se asocia con una buena clasificación de áreas urbanas con una RE alta (Goldewijk, 2001; Liu & Tian, 2010; Loperfido, Noe, Jarnagin, & Hogan, 2014), su uso en el presente estudio no mejoró los resultados en la región VM (altamente urbanizado). Dada la RT de los sensores utilizados en este estudio, cualquiera de ellos podría emplearse para hacer el análisis presentado por esta investigación. S1 se puede utilizar con una alta nubosidad, en cuyo caso será útil usar las combinaciones que la sección anterior indicó como de mayor acuerdo. Se recomiendan ciertas acciones para mejorar los resultados de la clasificación, como técnicas de posprocesamiento, aumento del número de bandas, y selección de áreas de entrenamiento que tengan mayor número de píxeles y homogeneidad espectral (Congedo, 2016; Richards & Xiuping, 2013; Chuvieco, 1991). La Tabla 4 se puede utilizar como referencia para seleccionar la imagen. Los datos de S1 y S2 pueden usarse si el proyecto que se está llevando a cabo implica el estudio de CT actual, pero si el estudio incluye cambios históricos, se limitará a los datos de la serie Landsat, que ha generado imágenes desde 1972. Los tres sensores pueden emplearse para análisis regionales o locales, y permitir la identificación de cuerpos de agua, vegetación, suelo desnudo y asentamientos humanos con un buen grado de acuerdo. Después de consultar la Tabla 4 para seleccionar el sensor

más adecuado, se recomienda que se combine con el algoritmo que tenga el mayor acuerdo, según lo reportado en este estudio (Tabla 2).

La Figura 4 muestra los resultados de CE para cada región, incluyendo la clasificación de CT obtenida con la combinación sensor-algoritmo con el AG más alto, y cuatro capas geográficas: PM, TS, el CE resultante y el CE del INEGI (INEGI, 2010) (información oficial) para propósitos de comparación. Las siguientes observaciones son aplicables a todas las áreas de estudio. La distribución espacial del CE obtenido por el presente estudio es drásticamente diferente a las del cuadro hidrológico del INEGI. La información presentada por INEGI es mucho más general que la que resultó de nuestro estudio. La información de nuestro estudio tiene una RE mayor (10 m). En el caso del INEGI, los datos están en una escala de 1:50 000. Los valores de CE de INEGI no se determinaron de manera precisa, sino que existen cinco categorías discretas, la más alta de las cuales se encuentra entre 0.10 y 0.20 para BB y VM, y ≥ 0.3 para BG.

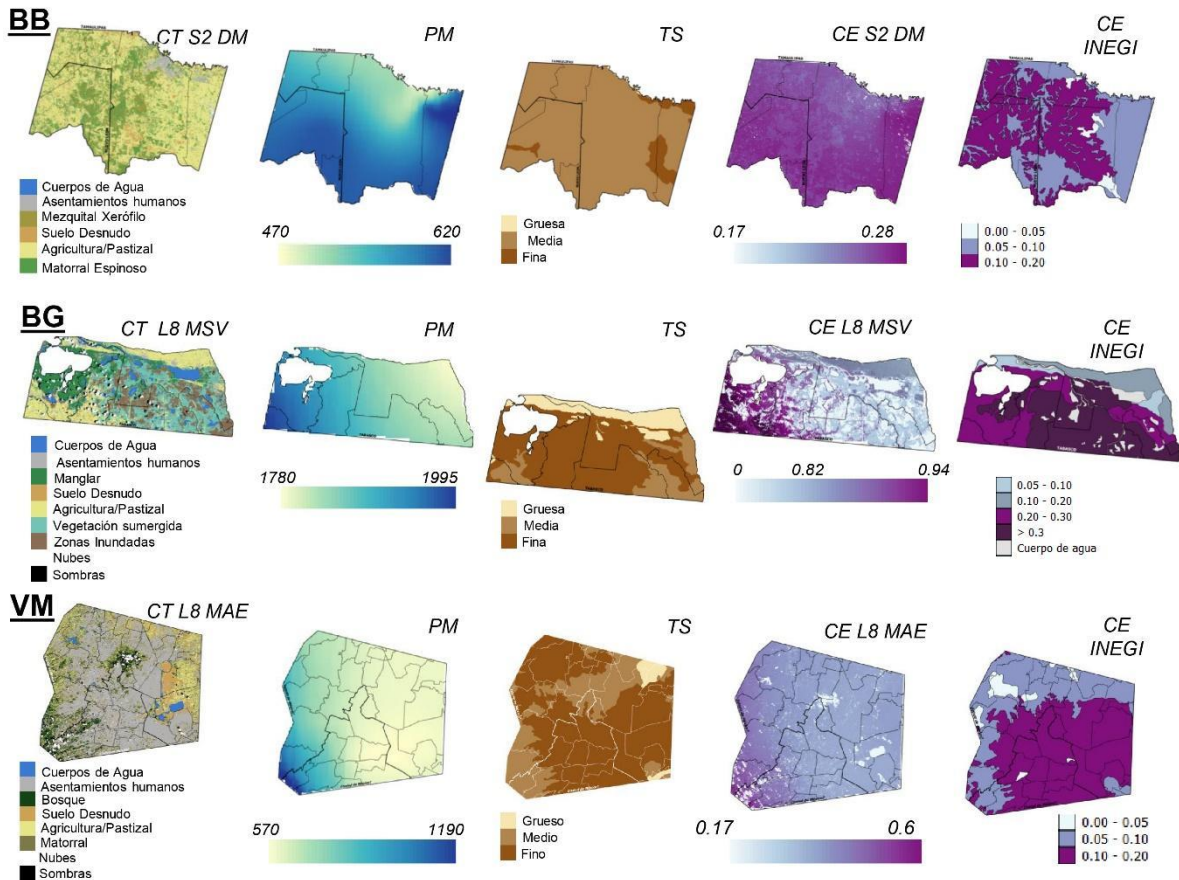


Figura 4. Clasificaciones de CT obtenidas con la combinación sensor-algoritmo de mayor AG y capas de PM, TS, CE resultante de este estudio, y CE de INEGI (información oficial), para las tres regiones estudiadas.

En el caso de BB, la combinación que se seleccionó fue S2-DM. La PM varió de 470 a 620 mm y aumentó hacia la parte sur de la región hidrológica. La TS dominante fue mediana, con pequeñas áreas de textura

fina y muy poca textura gruesa en el norte. El CE osciló entre 0.17 y 0.28, superando este último el límite superior informado por el INEGI (0.20). La distribución espacial fue bastante diferente a la carta hidrológica del INEGI. El CE en el gráfico osciló entre 0 y 0.5 % en el sureste y norte, mientras que nuestro estudio resultó en un CE más pequeño para un área más grande de la parte norte de la región. En nuestro estudio, los valores más altos se encontraron en el sur, mientras que el gráfico del INEGI identificó al noroeste como el área con los valores más altos.

Para la región BG, la CT se obtuvo con L8-MSV. La PM más baja fue de 1 780 mm, que aumentó a casi 2000 mm hacia el oeste. La TS dominante es fina, pero media en el sur y gruesa en el norte. El CE varió de 0 a 1, con predominio de valores superiores a 0.85. Los valores de CE más altos se encuentran en la parte occidental de la región hidrológica, mientras que la carta de INEGI identifica la región central como la que tiene los valores más altos.

Para la región VM, CT se obtuvo con la combinación L8-MAE. La PM mínima fue de 570 mm, que aumentó a 1 190 mm hacia el oeste. La TS dominante fue fina, media en la región central y gruesa en el noreste. El CE osciló entre 0.17 y 0.6, con predominio de valores superiores a 0.24. Los valores más altos se encontraron en la porción central de la región, lo que puede deberse a que el cálculo utilizado por el presente estudio incluyó a la PM como una variable importante para el valor de CE, considerando que al comparar visualmente los resultados de CE con el mapa de PM se observa correspondencia entre ambos.

Conclusiones

Este estudio presenta hallazgos y recomendaciones para seleccionar imágenes satelitales de acceso abierto con el fin de calcular CT y CE con base en las condiciones del área de estudio. No obstante, los resultados y recomendaciones son aplicables a cualquier estudio que utilice este tipo de imágenes para determinar la CT. En nuestro caso, las características de los sensores analizados permitieron obtener la CT, necesaria para determinar la CE del área de estudio. Se obtuvieron diferentes resultados con cada uno de los sensores. Para la determinación de CT, el sensor L8 tuvo en promedio el AG más alto, seguido de cerca por S2, mientras que S1 tuvo los valores más bajos. Con base en este estudio, la determinación de CT en el territorio mexicano debe priorizar el uso de MD y MSV, y evitar MP. Es un hallazgo importante dado que MP generalmente se considera un algoritmo estándar y de primera opción. Con respecto a MAE, esto se puede utilizar en áreas con características similares a la VM.

Un alta RE es útil para determinar la CT en áreas como la región BB (semiárida con una gran cantidad de tierras de cultivo irrigadas y asentamientos humanos aislados). Como resultado, se obtuvieron los mejores acuerdos con S2. La recomendación para las regiones similares a BB es combinar DM, MSV y MAE con S2. MP debe evitarse para este tipo de región. La CT para BB presentó un alto CC para arbustos espinosos de

mezquite xerofíticos y suelos desnudos de tierras de cultivo. Se recomienda que las áreas de entrenamiento para masas de agua se determinen con sumo cuidado, dado que tienen una presencia pequeña en regiones como BB. Las tierras agrícolas y los pastos predominan en estas regiones, mientras que los cuerpos de agua y los asentamientos humanos son escasos. Para la región BG, L8-MSV tuvo el más alto. El uso de la banda azul profundo parece mejorar el AC obtenido a partir de la determinación de masas de agua. En regiones con climas similares al de BG (alta nubosidad y precipitación), el uso de S1 con DM y MSV es una opción, con el mayor número posible de bandas y técnicas de posprocesamiento. Aunque en nuestro estudio estas combinaciones resultaron con acuerdos cercanos al 50 %, lo que se atribuye a que se ocuparon imágenes con poca nubosidad (< 3 %), en condiciones de mayor nubosidad los resultados deben mejorar y en tales casos no es posible realizar estudios con imágenes ópticas. En este tipo de región, las coberturas vegetación sumergida, agricultura-pastizal y las zonas de inundación tienen las PC más grandes; mientras que el suelo desnudo y los asentamientos humanos tienen las más pequeñas. Dado que L8-SAM obtuvo los mejores resultados para VM, recomendamos esta opción para regiones similares (climas templados con predominancia de zonas urbanas). S2 también es recomendable. Para este tipo de regiones debe evitarse el uso de S1 y el algoritmo MP.

La selección de la imagen ideal para la determinación de CT es una decisión que debe tener en cuenta los siguientes factores: disponibilidad,

RT, RE, RS, periodo de estudio, tipo de CT y su dinámica, clima y tamaño del área de estudio. Se debe considerar lo siguiente:

- Disponibilidad histórica de datos con RT: la serie Landsat es útil para análisis a largo plazo, mientras S1 y S2 para análisis actuales.
- Periodicidad del análisis para RT: S2 es útil para estudios semanales y los otros tres sensores para periodos más largos.
- Escala del proyecto y RE: todos los sensores estudiados funcionan para proyectos regionales y locales.
- Tipo de CT y bandas espectrales (RS). Los sensores estudiados son capaces de distinguir los cuatro grupos determinantes de CE: agua, suelo desnudo, asentamientos humanos y vegetación. Para otras clases recomendamos hacer el análisis de bandas que se presentó en este estudio.
- Solo se pueden usar sensores de radar para regiones con alta nubosidad, a pesar del bajo AG encontrado en nuestro estudio.

Al utilizar este método para determinar CE se obtuvieron valores más precisos y actuales con una resolución de hasta 10 m en una escala continua. Esto representa una ventaja sobre la información oficial en países como México cuya carta hidrológica de INEGI agrupa las regiones en clases con valores de 0 a 5 %, de 5 a 10 %, etcétera. El uso de los mapas de CE obtenidos por este estudio mejora tanto los resultados de los análisis de hidrología espacial como el proceso para tomar decisiones espacialmente diferenciadas.

Agradecimientos

Agradecemos al Fondo Institucional de Fomento Regional para el Desarrollo Científico, Tecnológico y de Innovación, FORDECYT 2018-10. Clave 297259 por el apoyo financiero del proyecto, y al Consejo Nacional de Ciencia y Tecnología, proyecto No. 739125/596725, así como al Programa de Posgrado en Energía y Medio Ambiente de la Universidad Autónoma Metropolitana, Iztapalapa.

Referencias

- Abdikan, S., Sanli, F. B., Ustuner, M., & Calò, F. (2016). Land cover mapping using sentinel-1 SAR data. *The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 41, 757. DOI:10.5194/isprsarchives-XLI-B7-757-2016
- Baldrige, A. M., Hook, S. J., Grove, C. I., & Rivera, G. (2009). The ASTER spectral library version 2.0. *Remote Sensing of Environment*, 113(4), 711-715. DOI: 10.1016/j.rse.2008.11.007
- Bruzzone, L., & Prieto, D. F. (2001). Unsupervised retraining of a maximum likelihood classifier for the analysis of multitemporal remote sensing images. *IEEE Transactions on Geoscience and Remote Sensing*, 39(2), 456-460. DOI: 10.1109/36.905255
- Chatziantoniou, A., Psomiadis, E., & Petropoulos, G. (2017). Co-orbital Sentinel 1 and 2 for LULC mapping with emphasis on wetlands in a

Mediterranean setting based on machine learning. *Remote Sensing*, 9(12), 1259. DOI: 10.3390/rs9121259

Che, D., Liang, A., Li, X., & Ma, B. (2018). Remote sensing assessment of safety risk of iron tailings pond based on runoff coefficient. *Sensors*, 18(12), 4373. DOI: 10.3390/s18124373

Chen, J., Chen, J., Liao, A., Cao, X., Chen, L., Chen, X., ... Lu, M. (2015). Global land cover mapping at 30 m resolution: A POK-based operational approach. *ISPRS Journal of Photogrammetry and Remote Sensing*, 103, 7-27. DOI: 10.1016/j.isprsjprs.2014.09.002

Chuvienco, E. (1991). Fundamentos de teledetección espacial. *Estudios Geográficos*, 52(203), 371.

Conagua, Comisión Nacional del Agua-Subdirección General Técnica. (2007). *Subregiones Hidrológicas, escala 1:250 000. República Mexicana en formato vectorial*. México, DF, México: Comisión Nacional para el Conocimiento y Uso de la Biodiversidad.

Congedo, L. (2016). Semi-automatic classification plugin documentation. *Release*, 4(0.1), 29.

Cotler, H., Garrido, A., Bunge, V., & Cuevas, M. L. (2007). *Las cuencas hidrográficas de México: priorización y toma de decisiones. Planeación Territorial* (2ª ed.). México, DF, México: Comisión Nacional para el Conocimiento y Uso de la Biodiversidad.

- Cuervo-Robayo, A. P., Téllez-Valdés, O., Gómez-Albores, M. A., Venegas-Barrera, C. S., Manjarrez, J., & Martínez-Meyer, E. (2014). *Precipitación anual en México (1910-2009), datos vectoriales escala: 1:1000000, modificado por Conabio (2015)*. México, DF, México: Comisión Nacional para el Conocimiento y Uso de la Biodiversidad.
- DOF, Diario Oficial de la Federación. (2015). *Comisión Nacional para el Conocimiento y Uso de la Biodiversidad*. México, DF, México. 10-14.
- Eastman, J. R. (2003). *IDRISI Kilimanjaro: guide to GIS and image processing* (14 ed.). Worcester, USA: Clark University.
- ESA, European Space Agency. (2013a). *Sentinel-1 User Handbook*. Recuperado de <https://sentinel.esa.int/web/sentinel/user-guides/sentinel-1-sar>
- ESA European Space Agency. (2013b). *Sentinel-2 User Handbook*. Recuperado de https://sentinel.esa.int/documents/247904/685211/Sentinel-2_User_Handbook
- Estoque, R. C., Pontius Jr, R. G., Murayama, Y., Hou, H., Thapa, R. B., Lasco, R. D., & Villar, M. A. (2018). Simultaneous comparison and assessment of eight remotely sensed maps of Philippine forests. *International Journal of Applied Earth Observation and Geoinformation*, 67, 123-134. DOI: 10.1016/j.jag.2017.10.008

García, E. (1998). *Climas (clasificación de Köppen, modificado por García). Escala 1:1000000. Formato de representación geográfica Shapefile: Formato vectorial compuesto por 4 archivos (shp, shx, dbf, prj)*. México, DF, México: Comisión Nacional para el Conocimiento y Uso de la Biodiversidad.

Goldewijk, K. K. (2001). Estimating global land use change over the past 300 years: The HYDE database. *Global Biogeochemical Cycles*, 15(2), 417-433. DOI: 10.1029/1999GB001232

Grizonnet, M., Michel, J., Poughon, V., Inglada, J., Savinaud, M., & Cresson, R. (2017). Orfeo ToolBox: Open source processing of remote sensing images. *Open Geospatial Data, Software and Standards*, 2(1), 15. DOI: 10.1186/s40965-017-0031-6

Herold, M., Latham, J. S., Di-Gregorio, A., & Schullius, C. C. (2006). Evolving standards in land cover characterization. *Journal of Land Use Science*, 1(2-4), 157-168. DOI: 10.1080/17474230601079316

Huang, B., Huang, J., Pontius, R. G., & Tu, Z. (2018). Comparison of intensity analysis and the land use dynamic degrees to measure land changes outside versus inside the coastal zone of Longhai, China. *Ecological Indicators*, 89, 336-347. DOI: 10.1016/j.ecolind.2017.12.057

Immerzeel, W. W., Droogers, P., De-Jong, S. M., & Bierkens, M. F. P. (2009). Large-scale monitoring of snow cover and runoff simulation

in Himalayan River basins using remote sensing. *Remote Sensing of Environment*, 113(1), 40-49. DOI: 10.1016/j.rse.2008.08.010

INEGI, Instituto Nacional de Estadística y Geografía. (2015). *Encuesta Intercensal (2015)*, 2ª ed. Aguascalientes, México: Instituto Nacional de Estadística y Geografía.

INEGI, Instituto Nacional de Estadística y Geografía. (2013). *Conjunto de datos vectoriales de uso de suelo y vegetación escala 1:250 000, serie V (capa unión), escala: 1:250 000*. Aguascalientes, México: Instituto Nacional de Estadística y Geografía.

INEGI, Instituto Nacional de Estadística y Geografía. (2010). *Cartas hidrográficas de México, datos vectoriales escala: 1:250 000*, 2ª ed. Aguascalientes, México: Instituto Nacional de Estadística y Geografía.

INEGI, Instituto Nacional de Estadística y Geografía. (2009). *Censos Económicos 2009*. Aguascalientes, México: Instituto Nacional de Estadística y Geografía.

INIFAP, Instituto Nacional de investigaciones Forestales y Agropecuarias. (1995). *Edafología, tipos, suelos, aspecto, físico escala 1:1 000 000 formato vectorial compuesto*. Recuperado de http://www.conabio.gob.mx/informacion/metadatos/gis/eda251mgw.xml?_httpcache=yes&_xsl=/db/metadatos/xsl/fgdc_html.xsl&_indent=no

- Jia, K., Liang, S., Zhang, N., Wei, X., Gu, X., Zhao, X.,... Xie, X. (2014). Land cover classification of finer resolution remote sensing data integrating temporal features from time series coarser resolution data. *ISPRS Journal of Photogrammetry and Remote Sensing*, 93, 49-55. DOI: 10.1016/j.isprsjprs.2014.04.004
- Jiménez, A., & Maderey, L. E. (1992). Escurrimiento medio anual. En: *Hidrogeografía IV.6.4. Atlas Nacional de México. Vol. II, Escala 1:4000000*. México, DF, México: Universidad Nacional Autónoma de México, Instituto de Geografía. Recuperado de http://www.conabio.gob.mx/informacion/metadatos/gis/esmea4mgw.xml?_xsl=/db/metadatos/xsl/fgdc_html.xsl&_indent=no
- Kruse, F. A., Lefkoff, A. B., Boardman, J. W., Heidebrecht, K. B., Shapiro, A. T., Barloon, P. J., & Goetz, A. F. H. (1993). The spectral image processing system (SIPS)—interactive visualization and analysis of imaging spectrometer data. *Remote Sensing of Environment*, 44(2-3), 145-163. DOI: 10.1016/0034-4257(93)90013-N
- Kurczyn-Robledo, J. A., Kretschmar, T., & Hinojosa-Corona, A. (2007). Evaluación del escurrimiento superficial en el noreste del Valle de Guadalupe, BC, México, usando el método de curvas numeradas y datos de satélite. *Revista Mexicana de Ciencias Geológicas*, 24(1), 1-14.

- Lei, G., Li, A., Bian, J., Zhang, Z., Jin, H., Nan, X., ... Tan, J. (2016). Land cover mapping in southwestern China using the HC-MMK approach. *Remote Sensing*, 8(4), 305. DOI: 10.3390/rs8040305
- Liu, M., & Tian, H. (2010). China's land cover and land use change from 1700 to 2005: Estimations from high-resolution satellite data and historical archives. *Global Biogeochemical Cycles*, 24(3). DOI: 10.1029/2009GB003687
- Loperfido, J. V., Noe, G. B., Jamagin, S. T., & Hogan, D. M. (2014). Effects of distributed and centralized stormwater best management practices and land cover on urban stream hydrology at the catchment scale. *Journal of Hydrology*, 519, 2584-2595. DOI: 10.1016/j.jhydrol.2014.07.007
- Manning, C., Raghavan, P., & Schuetze, H. (2009). *Introduction to information retrieval*. Cambridge, UK: Cambridge University Press.
- Maderey, L. E. (1990). Evapotranspiración real. En: *Hidrogeografía IV.6.6. Atlas Nacional de México. Vol. II Datos vectoriales Escala 1:400 0000*. México, DF, México: Universidad Nacional Autónoma de México, Instituto de Geografía. Recuperado de http://www.conabio.gob.mx/informacion/metadatos/gis/evapr4mgw.xml?_httpcache=yes&_xsl=/db/metadatos/xsl/fgdc_html.xsl&_indent=no

Merz, R., Blöschl, G., & Parajka, J. (2006). Spatio-temporal variability of event runoff coefficients. *Journal of Hydrology*, 331(3-4), 591-604. DOI: 10.1016/j.jhydrol.2006.06.008

Milewski, A., Sultan, M., Yan, E., Becker, R., Abdeldayem, A., Soliman, F., & Gelil, K. A. (2009). A remote sensing solution for estimating runoff and recharge in arid environments. *Journal of Hydrology*, 373(1-2), 1-14. DOI: 10.1016/j.jhydrol.2009.04.002

Mountrakis, G., Im, J., & Ogole, C. (2011). Support vector machines in remote sensing: A review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 66(3), 247-259. DOI: 10.1016/j.isprsjprs.2010.11.001

Pontius Jr, R. G., & 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. DOI: 10.1080/01431161.2011.552923

Pontius Jr, R. G., & Santacruz, A. (2014). Quantity, exchange, and shift components of difference in a square contingency table. *International Journal of Remote Sensing*, 35(21), 7543-7554. DOI: 10.1080/2150704X.2014.969814

Rascón, L. E. M., & Rivera, J. J. C. (2005). *El recurso agua en México: un análisis geográfico* (vol. 3). México, DF, México: Universidad Nacional Autónoma de México.

- Rawat, K. S., Mishra, A. K., & Ahmad, N. (2017). Surface runoff estimation over heterogeneous foothills of Aravalli mountain using medium resolution remote sensing rainfall data with soil conservation system-curve number method: A case of semi-arid ungauged Manesar Nala watershed. *Water and Environment Journal*, 31(2), 262-276. DOI: 10.1111/wej.12243
- Richards, J. A., & Xiuping, J. (2013). *Remote sensing digital image analysis: An introduction* (5^a ed.). Berlin, Germany: Springer-Verlag.
- Rogan, J., & Chen, D. (2004). Remote sensing technology for mapping and monitoring land-cover and land-use change. *Progress in Planning*, 61(4), 301-325.
- Savenije, H. H. G. (1996). The runoff coefficient as the key to moisture recycling. *Journal of Hydrology*, 176(1), 219-225. DOI: 10.1016/0022-1694(95)02776-9
- Sivapalan, M., Blöschl, G., Merz, R., & Gutknecht, D. (2002). Linking flood frequency to long-term water balance: Incorporating effects of seasonality. *E&G Quaternary Science Journal*, 27. DOI: 10.1029/2004WR003439
- Solís, A. Y., González, R. D., Lafragua, C. J., Gutiérrez-López, L. A., Bahena, H. A., Santos, J. F. Alfaro, M., Brindis, P. J. G. (2005). *Estudio de actualización de la disponibilidad y balance hidráulico de aguas superficiales de la Región Hidrológica No. 12, Cuencas*

Cerradas de Sayula y Región Hidrológica No. 15, Costa de Jalisco, Considerando las Concesiones del REPDA. México, DF, México: Instituto Mexicano de Tecnología del Agua y Comisión Nacional del Agua.

Song, C., Woodcock, C. E., Seto, K. C., Lenney, M. P., & Macomber, S. A. (2001). Classification and change detection using Landsat TM data: When and how to correct atmospheric effects? *Remote sensing of Environment*, 75(2), 230-244. DOI: 10.1016/S0034-4257(00)00169-3

Stisen, S., & Sandholt, I. (2010). Evaluation of remote-sensing-based rainfall products through predictive capability in hydrological runoff modelling. *Hydrological Processes: An International Journal*, 24(7), 879-891. DOI: 10.1002/hyp.7529

Sudhakar, S., Sridevi, G., Ramana, I. V., Rao, V. V., & Raha, A. K. (1999). Techniques of classification for landuse/landcover with special reference to forest type mapping in Jaldapara Wildlife Sanctuary, Jalpaiguri District, West Bengal—a case study. *Journal of the Indian society of Remote Sensing*, 27(4), 217.

Tapia-Silva, F. O. (2019). Geostatistical integration to improve representativeness of satellite precipitation estimates and field measurements. *Kalpa Publications in Computing* 13. In: *Proceedings of the 1st International Conference on Geospatial Information Sciences* (pp. 1-11). DOI:10.29007/glj1

Theodoridis, S., & Koutroumbas, K. (2008). *Pattern recognition*. (4a ed.). San Diego, USA: Elsevier Inc.

Tran, T., Julian, J., & De-Beurs, K. (2014). Land cover heterogeneity effects on sub-pixel and per-pixel classifications. *ISPRS International Journal of Geo-Information*, 3(2), 540-553. DOI: 10.3390/ijgi3020540

USGS, U.S. Geological Survey. (2016). *Landsat 8 (L8) Data Users Handbook*. Recuperado de <https://www.usgs.gov/land-resources/nli/landsat/landsat-8-data-users-handbook>

Wacker, A. G., & Landgrebe, D. A. (1972). Minimum distance classification in remote sensing. *Purdue University - LARS Technical Report*, 1(1)2-13.

Weng, Q. (2001). Modeling urban growth effects on surface runoff with the integration of remote sensing and GIS. *Environmental Management*, 28(6), 737-748. DOI: 10.1007/s002670010258

Yu, L., & Gong, P. (2012). Google Earth as a virtual globe tool for Earth science applications at the global scale: Progress and perspectives. *International Journal of Remote Sensing*, 33(12), 3966-3986. DOI: 10.1080/01431161.2011.636081

Zeng, Z., Tang, G., Hong, Y., Zeng, C., & Yang, Y. (2017). Development of an NRCS curve number global dataset using the latest geospatial remote sensing data for worldwide hydrologic applications. *Remote*

Sensing Letters, 8(6), 528-536. DOI:
10.1080/2150704X.2017.1297544

Zhao, Z. Z., & Zhao, K. (2013). Remote sensing image classification based on a modified self-organizing neural network with a priori knowledge. *Sensors & Transducers*, 153(6), 29-36.

Zuhlke, M., Fomferra, N., Brockmann, C., Peters, M., Veci, L., Malik, J., & Regner, P. (2015). SNAP (sentinel application platform) and the ESA sentinel 3 toolbox. *Sentinel-3 for Science Workshop*, (734), 21.