

ANÁLISIS ESPACIAL DE LA CONCENTRACIÓN DE NUTRIENTES EN LA RED FLUVIAL DE LA CUENCA LAGUNA DE BUSTILLOS, CHIHUAHUA

SPATIAL ANALYSIS OF NUTRIENT CONCENTRATION IN THE RIVER NETWORK OF THE LAGUNA DE BUSTILLOS WATERSHED, CHIHUAHUA

Miryam Leal-Ponce¹, Víctor Manuel Salas-Aguilar^{1‡}, Hugo Rojas-Villalobos¹, María Elena Torres-Olave¹, Luis Alatorre-Cejudo¹ y Luis Bravo-Mena¹

¹ Geoinformática, Universidad Autónoma de Ciudad Juárez. Km. 3.5 Carretera Anáhuac S/N, C.P. 31600, Cuauhtémoc, Chihuahua.

[‡] Autor para correspondencia: victor.salas@uacj.mx

RESUMEN

El inapropiado manejo de las fuentes de agua dulce ha propiciado una crisis poco entendida a escala global. La calidad de agua para uso agronómico implica un problema biogeoquímico que afecta directamente al crecimiento de las plantas, estructura del suelo y propicia la contaminación en los cuerpos de agua. El objetivo de este trabajo fue analizar la concentración espacial de fosfatos dentro de red fluvial de la cuenca Laguna de Bustillos, Chihuahua, México. Se realizaron dos muestreos en la red hídrica de la cuenca con el propósito de calibrar y validar en el entorno espaciotemporal. Para la calibración se levantaron 32 muestras y para la validación 11 muestras. En las muestras se determinó la concentración de fosfatos (PO_4^{3-}) mediante un fotómetro de nutrientes. A través de un modelo de regresión lineal múltiple se modelaron las concentraciones de fosfatos en función de variables fisiográficas y las reflectancias puntuales obtenidas de imágenes satelitales en distintas áreas de influencia (250 m, 500 m, 1000 m, 2000 m, 3000 m, 4000 m y 5000 m). La bondad de ajuste se evaluó a través del coeficiente de determinación (R^2) y el error cuadrático medio (ECM). El área de influencia a 2000 m presentó la mayor certidumbre. El modelo de calibración mostró un R^2 de 74.9% y el ECM 1.45 mg L⁻¹; en la validación temporal el R^2 fue 78.9% y el ECM, 1.72 mg L⁻¹. El modelo de regresión propuesto resultó ser apto para la predicción de fosfatos en la red hídrica de la cuenca. Los resultados de la modelación son útiles para apoyar la toma de decisiones relacionadas al manejo de nutrientes en la parte agrícola, estrategias de protección en amplias regiones, decisiones sobre futuros monitoreos y evaluaciones de las corrientes que son altamente vulnerables a la degradación ambiental en la cuenca de Bustillos.

Palabras Clave: calidad de agua; regresión múltiple; fisiografía; Google Earth Engine; monitoreo

ABSTRACT

Inappropriate management of freshwater sources has led to a poorly understood crisis on a global scale. The quality of water for agronomic use implies a biogeochemical problem that directly affects the growth of plants, soil structure and promotes contamination in water bodies. The objective of this work was to analyze the spatial concentration of phosphates within the fluvial network of the Laguna de Bustillos basin, Chihuahua, Mexico. Two samplings were carried out in the water network of the basin with the purpose of calibrating and validating in the space-time environment. For the calibration, 32 samples were collected and for the validation 11 samples. In the samples, the phosphate concentration (PO_4^{3-}) was determined by means of a nutrient photometer. Through a

multiple linear regression model, phosphate concentrations were modeled as a function of physiographic variables and the reflectances obtained from satellite images in different areas of influence (250 m, 500 m, 1000 m, 2000 m, 3000 m, 4000 m and 5000 m). The goodness of fit was evaluated through the coefficient of determination (R^2) and the mean square error (MSE). The area of influence at 2000 m presented the greatest certainty. The calibration model showed an R^2 of 74.9% and the MSE 1.45 mg L⁻¹; in the temporary validation, R^2 was 78.9% and MSE 1.72 mg L⁻¹. The proposed regression model turned out to be suitable for predicting phosphates in the water network of the basin. The results of the modeling are useful to support decision-making related to the management of nutrients in the agricultural part, protection strategies in wide regions, decisions about future monitoring and evaluations of streams that are highly vulnerable to environmental degradation in the basin of Bustillos.

Index words: water quality; multiple regression; physiography; Google Earth Engine; monitoring

INTRODUCCIÓN

Las estadísticas del agua en México (CONAGUA, 2016) mencionan que el país cuenta con 4999 sitios de monitoreo de calidad del agua, donde se miden parámetros fisicoquímicos y microbiológicos monitoreados por la red de monitoreo. Sin embargo, los altos costos de muestreo y análisis de la calidad de agua (CA), han limitado la duración de campañas de monitoreo (Yang *et al.*, 2017), tanto en México, como en otras partes del mundo.

La disponibilidad del agua a nivel mundial va en decremento (Guerrero *et al.*, 2009), los productores agrícolas se han visto obligados a buscar nuevas alternativas de riego, como lo son el uso de aguas residuales, urbanas, industriales y de drenaje agrícola (Veliz *et al.*, 2009), mismas que por su alto contenido en nitrógeno y fósforo reducen los requerimientos de fertilizantes comerciales (Ruvalcaba, 2015). Sin embargo, al utilizar estas nuevas alternativas de riego puede llegar a implicar un problema en la producción de los cultivos, por el hecho de obtener valores elevados de nutrientes que afectan directamente a la estructura del suelo y al crecimiento de las plantas, además que propicia la eutrofización en los cuerpos de agua (Carrow *et al.*, 2008).

Los tomadores de decisiones en el área agrícola necesitan metodologías robustas que se fundamenten en datos sólidos y que produzcan información espacial y temporal del comportamiento de los flujos bioquímicos que afectan una región (Paz *et al.*, 2019). Por este motivo, a lo largo del tiempo se han utilizado distintas metodologías para el análisis de la calidad de agua (CA) en cuerpos de agua superficiales. Una de las

más empleadas es la regresión ordinaria (Tong y Chen, 2002; Galbraith y Burns, 2007; Bahar *et al.*, 2008; Lee *et al.*, 2009; Sun *et al.*, 2011), que trata de encontrar las variables físicas, edáficas y climáticas que explican la calidad del agua en escurrimientos superficiales. Otros, sin embargo, han optado por la regresión espacial, donde se considera la correlación espacial entre las variables (Su *et al.*, 2013; Mainali y Chang, 2018).

Las estimaciones de los estándares de calidad en los ríos se basan regularmente en las interpretaciones relacionadas a las frecuencias de los datos de monitoreo; pero tales interpretaciones son inválidas cuando las diferencias del muestreo espacio temporal son grandes (Smith *et al.*, 1997).

La aplicación de los sistemas de información geográfica, percepción remota y estadísticas se ha posicionado como una herramienta válida y económica que ha mostrado un gran potencial para modelar la CA en escurrimientos superficiales (Atkinson *et al.*, 2009). Algunas investigaciones, han estudiado la relación de los impactos de la cobertura y usos de suelo con la calidad del agua superficial, para así conocer los efectos de las características fisiográficas de las cuencas hidrográficas sobre la CA (Haidary *et al.*, 2013; Huang *et al.*, 2016; Li *et al.*, 2015).

Los métodos estadísticos como la regresión lineal múltiple han sido utilizados para investigar las relaciones entre los parámetros de CA y características del paisaje, donde la regresión examina la relación entre una sola variable dependiente (parámetro de CA) y un conjunto de variables independientes (Características fisiográficas de la cuenca) para representar mejor la relación en la población (Sliva y Williams 2001; Wang, 2001; Singh *et al.*, 2005; Amiri y Nakane 2009).

La medición de las concentraciones de fosfatos en la red fluvial es un gran desafío debido a la recolección y análisis de muestras en campo. El uso de los SIG, percepción remota y estadística puede proporcionar una herramienta para la evaluación de fosfatos en la red fluvial, ya que se ha utilizado con éxito para monitorear otras variables de CA a grande escala y flujos de carbono (Probst *et al.*, 1994) lo que permite obtener valores a menor costo, puesto que los datos utilizados son abiertos al público (Khorram, 1985; Lathrop, 1992; Wu *et al.*, 2010).

Esta investigación tuvo como objetivo analizar la concentración espacial de fosfatos en la red fluvial de la cuenca Laguna de Bustillos, México. Los mayores beneficiados con esta investigación son los agricultores, otorgándoles una herramienta para análisis diagnóstico de CA previo a los ciclos de fertilización y así una mejor planificación de esta. Esta investigación también beneficia a los tomadores de decisiones al disponer de una herramienta importante para implementar programas integrales del manejo de la cuenca en cuanto a CA se refiere.

MATERIALES Y MÉTODOS

Área de estudio

Los sitios de muestreo se establecieron en la Cuenca Laguna de Bustillos (Latitud 28°58'12" - 28°15'00" N, Longitud 107°09'36" - 106°15'00" W), ubicada al Noroeste del estado de Chihuahua, México (Figura 1). La Cuenca posee una superficie de 3298 Km². Se encuentra limitada geográficamente por las cadenas montañosas de Pedernales, San Juan, Salitrera, Chuchupate, Sierra Azul y Rebote; el único suministro de agua es de lluvia por ser cuenca endorreica. La cuenca tiene una elevación promedio de 2000 metros sobre el nivel del mar (msnm) (Benavides *et al.*, 2008), y está rodeada en el norte, este, oeste y suroeste por varios picos con alturas promedio de 2400 msnm, algunos de ellos alcanzan hasta 2887 msnm. La Comisión Nacional del Agua (CONAGUA) reporta valores de precipitación media anual de 415.7 mm, con un clima templado-semiárido y una temperatura promedio anual de 14.6 °C. Las corrientes de la cuenca se clasifican como efímeras y llevan agua en los meses de agosto a noviembre (CONAGUA, 1991).

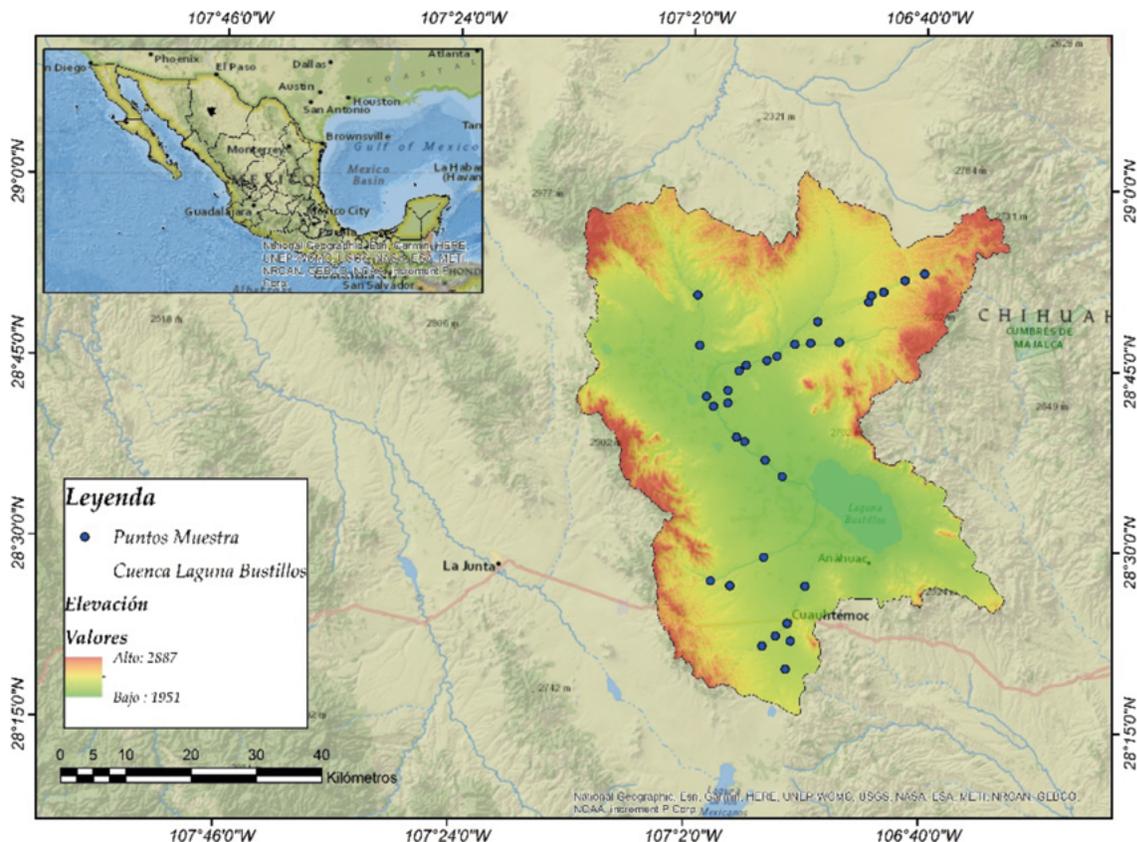


Figura 1. Ubicación del área de estudio y puntos de muestreo.

Muestreo del agua y Análisis

El cuatro de septiembre de 2018 se muestrearon 32 sitios dentro de la red hídrica de la cuenca para hacer la calibración de los modelos de regresión en las distintas áreas de influencia que se explican más adelante. Se analizó la concentración de fosfatos, los cuales se reportaron en mg L^{-1} . Las muestras se analizaron en el fotómetro de análisis de nutrientes.

Datos espaciales

Extracción de variables fisiográficas a diferente escala

La clasificación de usos de suelo se realizó mediante una clasificación supervisada de la imagen Sentinel Nivel 2A con fecha 6 de agosto de 2018, que provee

reflectancias debajo de la atmosfera. Se empleó la capa vectorial de uso de suelo y vegetación serie VI (INEGI, 2016) como referencia para generar la clasificación. Se aplicó el algoritmo Random Forest para discriminar los usos de suelo dentro de la plataforma Google Earth Engine (GEE). Para crear el mapa de pendientes, se utilizó el modelo digital de elevación mundial, disponible en la plataforma GEE (Jarvis *et al.*, 2008). La suma de la precipitación (mm) de 5 y 10 días se obtuvo a partir de los datos diarios de precipitación obtenidos de la plataforma de Google Earth Engine por medio de la colección CHIRPS (Funk *et al.*, 2015). Para cada sitio de muestreo fueron generados siete áreas de influencia (250, 500, 1000, 2000, 3000, 4000 y 5000 m) (Figura 2) en las cuales se extrajo el porcentaje de las variables listadas en el Cuadro 1.

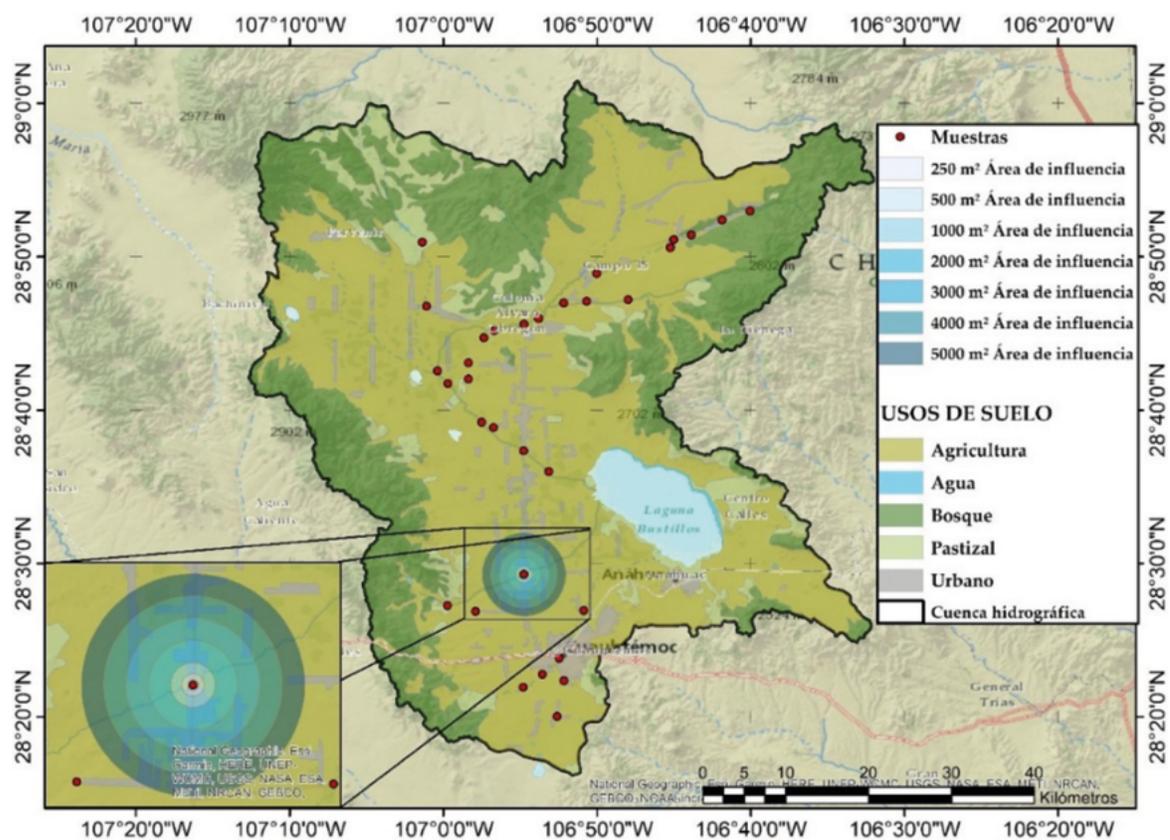


Figura 2. Áreas de influencia para la obtención de variables fisiográficas.

Cuadro 1. Covariables usadas como variables explicativas

Tipo de datos	Fuente	Resolución	Unidad
Concentración de Fosfatos	Muestreo	Dato puntual	mg L-1
Cobertura del suelo:	Google Earth Engine Satélite: Sentinel Nivel 2A	10 metros	%
Agricultura (A)			
Zona urbana (ZU)			
Bosque (B)			
Matorral (M)			
Pastizal (P)			
Sin uso aparente (SU)			
Pendiente (P)	Google Earth Engine (Jarvis <i>et al.</i> , 2008)	30 metros	Valores promedio y máximos (%)
Índices de vegetación y operación entre bandas:	Google Earth Engine Satélite: Sentinel Nivel 2A	20 metros	Valores promedio y máximos del área de influencia
Índice Diferencial de Agua Normalizado (NDWI)			
Índice de vegetación ajustada de suelo modificado (MSAVI)			
Índice de Vegetación de Diferencia Normalizada (NDVI)			
Vegetación de Diferencia Normalizada Verde (GNDVI)			
Verde / Azul (G/B)			
SWIR / VRE3= (SWIRVRED3)			
Imagen satelital, bandas:	Google Earth Engine Satélite: Sentinel Nivel 2A	10 y 20 metros	Valores puntuales de reflectancia
Azul 496.6nm (Blue)			
Verde 560nm (Green)			
Rojo 664.5nm (Red)			
Borde rojo 703.9nm (VRE1)			
Borde rojo 740.2nm (VRE2)			
Borde rojo 782.5nm (VRE3)			
Infrarrojo Cercano 835.1nm (NIR)			
Onda Corta Infrarroja 1613.7nm (SWIR1)			
Onda Corta Infrarroja 2202.4nm (SWIR2)			
Datos de precipitación:	Google Earth Engine	Diario	mm
Suma de 5 días (SUM5)			
Suma de 10 días (SUM10)			

Extracción de reflectancias en datos puntuales

Se eligieron imágenes Sentinel 2A BOA (bottom of atmosphere) del 3 de septiembre de 2018 para obtener las reflectancias puntuales de los sitios de muestreo recolectados el cuatro de septiembre. Se escribió un código en Google Earth Engine para realizar este paso, se verificó que cada punto no estuviera cubierto por nubes y que los píxeles recabados se encontraran en el ancho de la red hídrica. En cada fecha se extrajeron nueve

bandas del satélite Sentinel que sirvieron para alimentar la base de datos como variables independientes. A partir de la información espectral generaron los siguientes índices: MSAVI, NDVI, NDWI, GNDVI, SWIR / VRE3 y Verde / Azul (G/B), que también son añadidos como variables y son señaladas por Frazier (2016) como índices que se correlacionan bien con la concentración de nutrientes en el agua. La Figura 3 presenta un esquema metodológico de este trabajo.

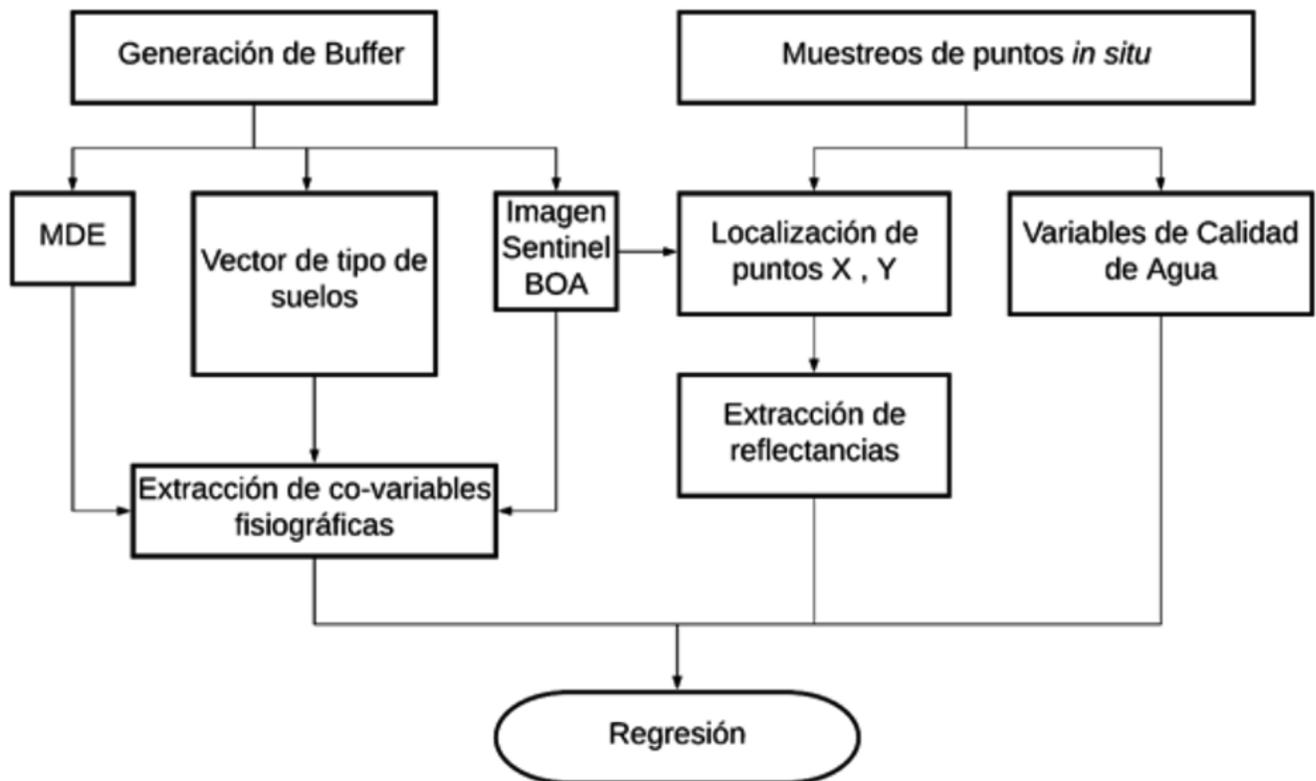


Figura 3. Flujo de trabajo para analizar la concentración de fosfatos con respecto a variables fisiográficas y valores puntuales de reflectancias.

Validación temporal

La imagen Sentinel del 29 de septiembre fue usada para extraer los puntos del muestreo del 2 de octubre que sirvió para hacer la validación del modelo. La validación temporal se realizó con base en las 11 muestras (Figura 4) que se colectaron el día 02 de

octubre. Las variables significativas en el modelo de calibración fueron usadas para ajustar otro modelo de regresión para esta fecha. El propósito de realizar esta validación es corroborar si con menores muestras el modelo es capaz de obtener resultados aceptables y observar el cambio en los coeficientes de regresión.

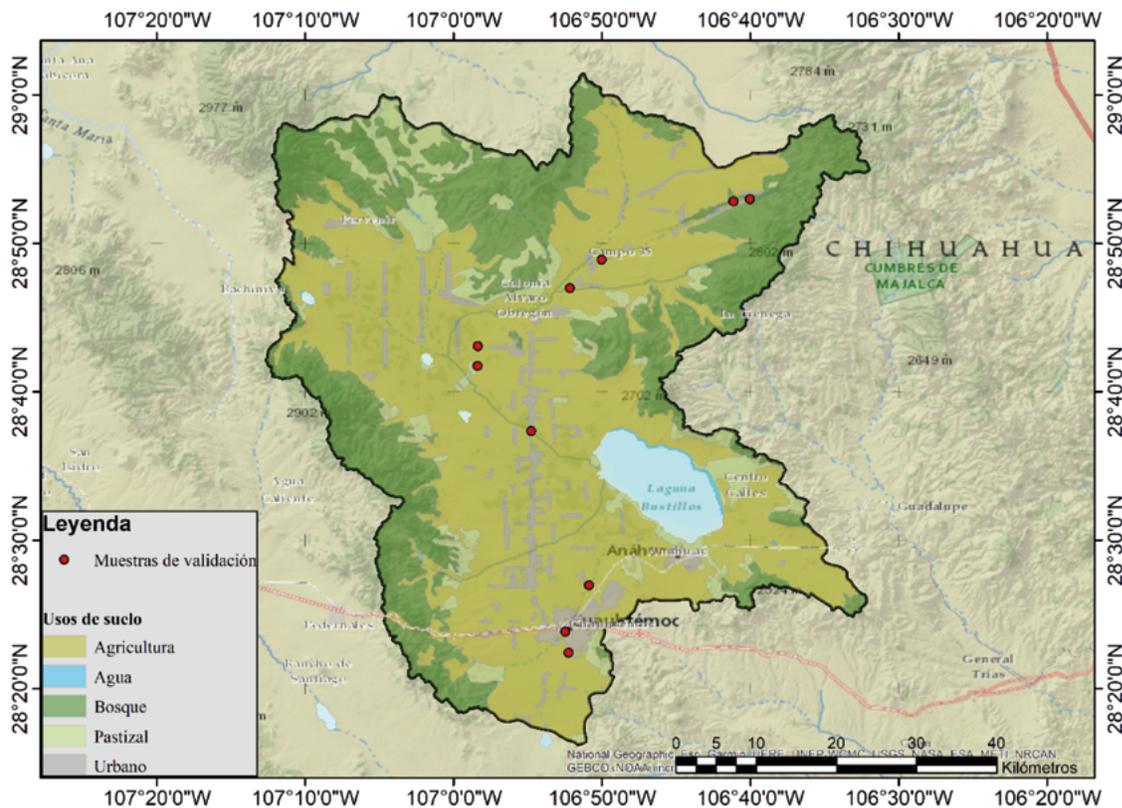


Figura 4. Ubicación de los sitios de muestreo para validación temporal del modelo.

Análisis de regresión: Calibración y Validación

La normalidad de los datos fue realizada a través de la prueba propuesta por Anderson y Darling (1954) ($p < 0.05$). Las variables que no presentaron una distribución normal fueron transformadas a escala logarítmica. Para obtener un modelo que prediga la concentración de nutrientes a través de las variables procesadas, se eligió la regresión lineal múltiple;

$$y = B_0 + \sum_{i=1}^p B_i * x_i + e$$

Donde y es la concentración de nutrientes (fosfatos, Mg L^{-1}), B_0 es el intercepto, B_i son los parámetros estimados para las variables independientes e (variables fisiográficas y de reflectancia) y e es el término del error (Cohen *et al.*, 2014). La calibración del modelo de regresión se realizó para cada área de influencia para observar cual es la distancia que explica la concentración de nutrientes con menos incertidumbre. Se utilizó el método de Stepwise (Thompson, 1995)

para encontrar las variables significativas del modelo ($p < 0.10$). La multicolinealidad de las variables predictoras fue evaluada por el factor de inflación de la varianza (VIF, por sus siglas en inglés) (Kroll *et al.*, 2013). Aquellas variables que obtuvieran un $VIF > 10$ (Fouad *et al.*, 2018), fueron removidas del modelo de regresión. Se usaron el coeficiente de determinación (R^2) y el error cuadrático medio (ECM) para evaluar la certidumbre del modelo. Para la validación espacial se usó el método Jackknife en el que se usan iteraciones para excluir un dato a la vez y evaluar la predicción del modelo (Wu, 1986).

RESULTADOS

Variación espacial y temporal de la concentración de nutrientes

La prueba de Anderson-Darling reveló que los datos de nitratos mantuvieron una distribución normal. Las demás variables de acuerdo a la prueba están normalmente distribuidas. La Figura 5 presenta la variación espacial de la concentración de fosfatos en el primer y segundo muestreo.

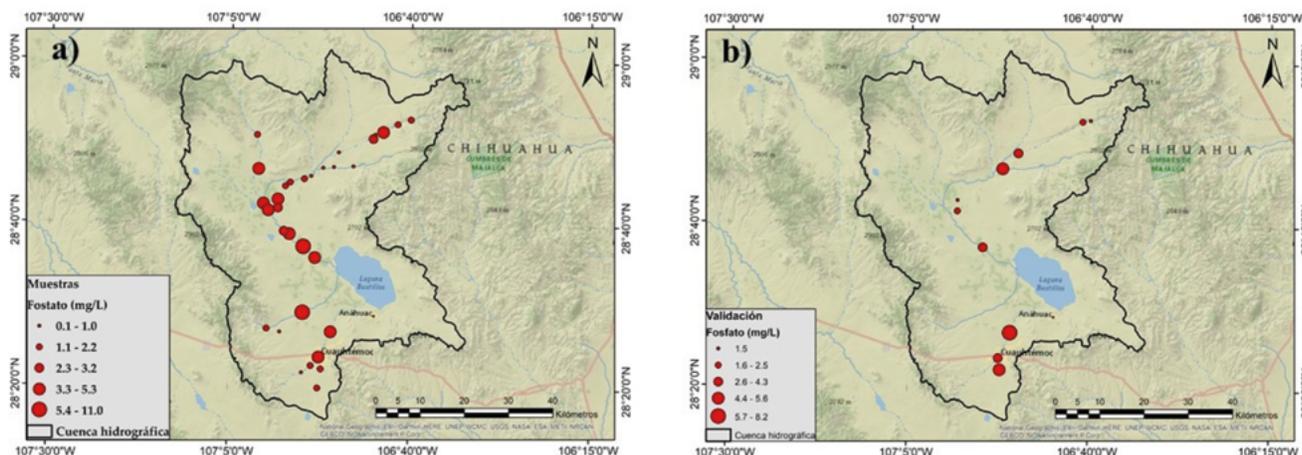


Figura 5. Variación espacial de concentración de nutrientes. Las figuras a y b representan la concentración de fosfatos en el primer y segundo muestreo.

Calibración espacial del modelo

El análisis de varianza de las ecuaciones obtenidas mostró las variables explicativas más significantes en relación a lo que podría aportar la media ($p < 0.05$).

El Cuadro 2 presenta los modelos de regresión para cada área de influencia, las variables en cada modelo fueron significantes para el método de stepwise y no presentaron multicolinealidad ($VIF < 10$).

Cuadro 2. Ecuaciones de predicción de concentración de fosfatos para distintas áreas de influencia

Escala	R ²	ECM	Ecuación
250	45.02	2.02	$-5.79 + 49.9 \text{ Blue} + 0.1583 \text{ SUM10} - 14.58 \text{ SWIR1/VRE3}$
500	54.38	1.88	$-4.98 + 42.9 \text{ Blue} + 0.1490 \text{ SUM10} - 14.58 \text{ SWIRVRE3} + 1.534 \text{ SU}$
1000	59.82	1.76	$-4.97 + 43.7 \text{ Blue} + 0.1480 \text{ SUM10} - 15.72 \text{ SWIRVRE3} + 3.54 \text{ SU}$
2000	74.93	1.45	$-19.91 + 81.4 \text{ Blue} + 0.1944 \text{ SUM10} + 6.53 \text{ NDVI} - 10.87 \text{ SWIRVRED3} + 4.43 \text{ SU} + 12.080 \text{ MAX_MSAVI}$
3000	64.28	1.69	$-14.72 + 60.3 \text{ Blue} + 0.2085 \text{ SUM10} - 12.81 \text{ SWIRVRE3} + 16.96 \text{ MAX_MSAVI} - 0.0206 \text{ MAX_SLOPE}$
4000	57.66	1.81	$-14.93 + 63.5 \text{ Blue} + 0.2026 \text{ SUM10} - 14.70 \text{ SWIRVRE3} + 15.19 \text{ MAX_MSAVI}$
5000	50.48	1.96	$-11.53 + 56.1 \text{ Blue} + 0.1827 \text{ SUM10} - 14.52 \text{ SWIRVRE3} + 10.36 \text{ MAX_MSAVI}$

Se observa que el área de influencia de 2000 m es el que tiene mayor certidumbre en la concentración de este nutriente (R^2 74.93 y ECM 1.45). En esta área seis variables fueron significantes: las variables con coeficiente positivo fueron la reflectancia en el azul (Blue), la suma de la precipitación con 10 días (SUM10), el NDVI, la vegetación sin uso aparente

(SU) y máximo valor del índice MSAVI, por otra parte, el valor puntual de SWIR2/RED3 es el único que presenta con coeficiente negativo.

Validación temporal

El coeficiente de determinación R^2 en la validación

fue de 78.26% y el error cuadrático medio fue de 1.72 (Mg/L). Se comprobó que no existe multicolinealidad en las variables (VIF<10). La incertidumbre al modelo de validación es similar a lo calculado en la calibración.

Los coeficientes de la variable de porcentaje suelo sin uso aparente permaneció estable (Cuadro 3). Las variables que fueron procesadas mediante imágenes

de satélite presentaron cambios importantes en sus coeficientes entre la calibración y la validación. Por su parte la variable SUM10 disminuyó el valor de su coeficiente entre estos dos procesos. Se observa que el valor del error estándar (EE) de cada coeficiente es mayor en la validación debido al menor número de muestras colectadas en estas fechas.

Cuadro 3. Calibración Validación temporal de los Coeficientes de regresión para Fosfatos

Coeficiente	Calibración	EE	Validación	EE
Constante	-19.91	4.25	-4.55	7.05
Blue	81.41	17.21	-23.91	23.11
SUM10	0.19	0.03	0.14	0.103
NDVI	6.53	2.72	16.5	12.4
SWIR/RED3	-10.87	2.67	8.01	10.3
SU	4.43	1.42	4.26	4.94
MAX_MSAVI	12.08	4.68	10.01	11.1

DISCUSIÓN

La calidad del agua depende en gran medida de las características fisiográficas de la cuenca, por lo cual un análisis a distintas áreas de influencia resulta un buen método para analizar las relaciones entre las características del paisaje y la calidad del agua (Xiao *et al.*, 2016). Varios investigadores han analizado las relaciones a nivel cuenca hidrográfica (Woli *et al.*, 2004), mientras otros abogan por el uso de áreas de influencias circulares (buffers) (Li *et al.*, 2009; Sahu y Gu, 2009). Por tanto, los resultados varían dependiendo la escala a la que se realiza el análisis. Diversos investigadores han optado por la caracterización y comparación de los impactos del paisaje a distintas escalas espaciales (Tang *et al.*, 2005; Su *et al.*, 2013).

Este estudio presentó un análisis a diferentes escalas. La regresión a escala 2000 m explicó de manera más precisa las relaciones entre las características fisiográficas de la cuenca, reflectancias y calidad del agua. En los datos presentados por el modelo de regresión se encontró que el índice de la división de las bandas (SWIR2 / VRE 3) fue una variable significativa para la modelación de concentración de nitratos. Esto concuerda con Delegido *et al.* (2011), quien muestra que las bandas de borde rojo de Sentinel son confiables

para estimar los parámetros de calidad de agua. La reflectancia puntual de la banda azul fue la más correlacionada con el contenido de Fosfato en el agua, de acuerdo con la investigación realizada por Satapathy *et al.* (2010), en los sensores IKONOS y Landsat ETM.

El índice de vegetación NDVI mostró ser una variable significativa para la modelación de fosfatos. Este índice al ser creado a través de operaciones entre las bandas NIR y rojo del espectro, resalta las propiedades reflectantes de la clorofila (Teta *et al.*, 2017), debido probablemente a su asociación con la materia orgánica permitió obtener una correlación con este nutriente en dichas longitudes de onda (Chen *et al.*, 2009; Para *et al.*, 2010).

El máximo valor de MSAVI también fue una variable significativa para la modelación de Fosfatos. Este índice también es creado a partir de la operación de las bandas NIR y rojo del espectro electromagnético, pero a diferencia del NDVI que registra el dato puntual sobre el río, el dato del valor máximo de MSAVI es una estadística zonal del área de influencia; por lo tanto, este índice es un indicador de la vegetación circundante a la muestra y exhibe el crecimiento de la vegetación sobre él suelo. También se ha demostrado como el MSAVI es un indicador de la fertilidad del suelo (Liu *et al.*, 2010).

La precipitación como variable explicativa de la concentración de nutrientes, ha mostrado ser un factor de transporte de concentraciones a través del flujo terrestre durante eventos de lluvia (Discroll *et al.*, 2003; Mouri *et al.*, 2011). Sin embargo, el modelo seleccionó esta variable como significativa para la modelación de Fosfatos, lo que puede significar una incongruencia, ya que el fosfato es un elemento poco móvil en el suelo, donde los componentes del suelo restringen su potencial para el transporte (McDowell *et al.*, 2002). Sin embargo, la erosión es un factor que representa la mayor contribución para transportar el fosfato del suelo al agua, lo que justifica la significancia de la variable precipitación para su contribución en el modelo matemático (Heathwaite *et al.*, 1997). El transporte de fósforo disuelto lixiviado percolado a través del perfil del suelo ahora se ve como una preocupación importante (Sims *et al.*, 1998).

Por último, tenemos que el análisis temporal aseguró la estabilidad de la regresión (Psilovikos y Elhag, 2013) basado en la coherencia lineal robusta entre los parámetros de calidad del agua reales y los modelados. Esta investigación es un aporte a los flujos laterales que además de estimar la concentración de nutrientes puede ayudar a la integración de los ciclos biogeoquímicos y flujos de carbono que están asociados con el transporte de sedimentos (Paz *et al.*, 2019)

CONCLUSIONES

La concentración de fosfatos de la red fluvial de la Cuenca Laguna de Bustillos es posible predecirla a través de regresión múltiple con distinta información geográfica. El análisis de concentración de fosfatos se comporta diferente a distintas escalas espaciales. La regresión múltiple a 2000 metros posee mayor certidumbre al estimar la concentración de fosfatos en función las características fisiográficas de la cuenca y las reflectancias puntuales obtenidas de imágenes de satelitales.

Se encontraron seis variables significantes en la predicción de la concentración de fosfatos: las variables con coeficiente positivo fueron la reflectancia en la longitud de onda azul, la suma de la precipitación con 10 días, el NDVI, la vegetación sin uso aparente y máximo valor del índice MSAVI. En cambio, el valor puntual de SWIR2/RED3 mostró un coeficiente negativo, lo que indica que al aumentar el valor de esta variable la concentración de fosfatos disminuye.

La validación temporal mostro congruencia con el ajuste realizado con la calibración y se concluye que es válida su aplicación para la zona de estudio

Para concluir de tiene que uso de los sistemas de información geográfica, la percepción remota y la estadística es una gran una herramienta para el monitoreo de fosfatos en la red fluvial ya que permite un análisis de calidad de agua más constante y con menor presupuesto. Además, ayudaran a entender las relaciones de los flujos laterales epicontinentales que pueden aplicarse en otras áreas de estudio.

También el modelo presentado puede ser usado como apoyo a las políticas públicas dentro de la cuenca para el posible uso de las aguas superficiales para riego y con esto disminuir la presión hídrica que se tiene sobre el acuífero de Cuauhtémoc, Chihuahua

LITERATURA CITADA

- Amiri, B. J. and K. Nakane. 2009. Modeling the linkage between river water quality and landscape metrics in the Chugoku district of Japan. *Water Resources Management* 23:931-956.
- Anderson, T. W. and D. A. Darling. 1954. A test of goodness of fit. *Journal of the American Statistical Association* 49:765-769.
- Atkinson, S., D. Johnson, B. Venables, J. Slye, J. Kennedy, S. Dyer and H. Sanderson. 2009. Use of watershed factors to predict consumer surfactant risk, water quality, and habitat quality in the upper Trinity River, Texas. *Science of the Total Environment* 407:4028-4037.
- Bahar, M. M., H. Ohmori and M. Yamamuro. 2008. Relationship between river water quality and land use in a small river basin running through the urbanizing area of Central Japan. *Limnology* 9:19-26.
- Benavides, A., M. Moreno, M. Sosa, S. Puga, J. Alcalá y C. Quintana. 2008. Evaluación de la calidad del agua en las principales lagunas del estado de Chihuahua. *Revista Latinoamericana de Recursos Naturales* 4:84-88.
- Carrow, R., R. R. Duncan and M. T. Huck. 2008. *Turfgrass and Landscape Irrigation Water Quality: Assessment and Management*. CRC Press. 494 p.
- Chen, S., L. Fang, L. Zhang and W. Huang. 2009. Remote sensing of turbidity in seawater intrusion reaches of Pearl River Estuary—A case study in Modaomen water way, China. *Estuarine, Coastal and Shelf Science* 82:119-127.
- Cohen, P., S. G. West and L. S. Aiken. 2014. *Applied Multiple Regression/Correlation Analysis for the Behavioral Sciences*. Psychology Press. 545 p.

- CONAGUA. 1991. Actualización del estudio geohidrológico, políticas de operación y proyecto de manejo del acuífero del Valle de Cuauhtémoc Chihuahua. Comisión Nacional del Agua
- CONAGUA. 2016. Estadísticas del Agua en México. Comisión Nacional del Agua
- Delegido, J., J. Verrelst, L. Alonso and J. Moreno. 2011. Evaluation of sentinel-2 red-edge bands for empirical estimation of green LAI and chlorophyll content. *Sensors* 11:7063-7081.
- Driscoll, C. T., D. Whitall, J. Aber, E. Boyer, M. Castro, C. Cronan and K. Lambert. 2003. Nitrogen pollution in the northeastern United States: sources, effects, and management options. *BioScience* 53:357-374.
- Fouad, G., A. Skupin and C. L. Tague. 2018. Regional regression models of percentile flows for the contiguous United States: Expert versus data-driven independent variable selection. *Journal of Hydrology: Regional Studies* 17:64-82.
- Frazier, A. E. 2016. Surface metrics: scaling relationships and downscaling behavior. *Landscape ecology* 31(2): 351-363.
- Funk, C., P. Peterson, M. Landsfeld, D. Pedreros, J. Verdin, S. Shukla and J. Michaelson. 2015. The climate hazards infrared precipitation with stations: a new environmental record for monitoring extremes. *Scientific Data* 2:1-21.
- Galbraith, L. M. and C. W. Burns. 2007. Linking land-use, water body type and water quality in southern New Zealand. *Landscape Ecology* 22:231-241.
- Guerrero, T., C. Rives, A. Rodríguez, Y. Saldívar y V. Cervantes. 2009. El agua en la Ciudad de México. *Ciencias* 94:16-23.
- Haidary, A., B. J. Amiri, J. Adamowski, N. Fohrer and K. Nakane. 2013. Assessing the impacts of four land use types on the water quality of wetlands in Japan. *Water Resources Management* 27:2217-2229.
- Heathwaite, A. L., P. Griffiths, P. Haygarth, S. Jarvis and R. Parkinson. 1997. Phosphorus loss from grassland soils: implications of land management for the quality of receiving waters. *IAHS Publications-Series of Proceedings and Reports-Intern Assoc Hydrological Sciences* 243:177-186.
- Huang, Z., L. Han, L. Zeng, W. Xiao and Y. Tian. 2016. Effects of land use patterns on stream water quality: a case study of a small-scale watershed in the Three Gorges Reservoir Area, China. *Environmental Science and Pollution Research* 23:3943-3955.
- INEGI. 2016. Uso del Suelo y Vegetación, Escala 1:250000, Serie VI (continuo nacional).
- Jarvis, A., H. I. Reuter, A. Nelson and E. Guevara. (Cartographer). 2008. Hole-filled SRTM for the Globe Version 4. <http://srtm.csi.cgiar.org>
- Khorram, S. 1985. Remote sensing of water quality in the Mense river estuary, North Carolina. *Photogrammetric Engineering and Remote Sensing* 51:329-341.
- Kroll, C. N. and P. Song. 2013. Impact of multicollinearity on small sample hydrologic regression models. *Water Resources Research* 49:3756-3769.
- Lathrop, R. 1992. Landsat Thematic Mapper monitoring of turbid inland water quality. *Photogrammetric Engineering and Remote Sensing* 58:465-470.
- Lee, S. W., S. J. Hwang, S. B. Lee, H. S. Hwang and H. C. Sung. 2009. Landscape ecological approach to the relationships of land use patterns in watersheds to water quality characteristics. *Landscape and Urban Planning* 92:80-89.
- Li, S., S. Gu, X. Tan and Q. Zhang. 2009. Water quality in the upper Han River basin, China: the impacts of land use/land cover in riparian buffer zone. *Journal of Hazardous Materials* 165:317-324.
- Li, Z., C. Luo, Q. Xi, H. Li, Pan, Q. Zhou and Z. Xi. 2015. Assessment of the AnnAGNPS model in simulating runoff and nutrients in a typical small watershed in the Taihu Lake basin, China. *Catena* 133:349-361.
- Liu, Y., Y. Zhang and L. Guo. 2010. Towards realistic assessment of cultivated land quality in an ecologically fragile environment: A satellite imagery-based approach. *Applied Geography* 30:271-281.
- Mainali, J. and H. Chang. 2018. Landscape and anthropogenic factors affecting spatial patterns of water quality trends in a large river basin, South Korea. *Journal of Hydrology* 564:26-40.
- McDowell, R., A. Sharpley, P. Kleinman and W. Gburek. 2002. Hydrological source management of pollutants at the soil profile scale. *In*: P. M. Haygarth and S. C. Jarvis (Eds.). *Agriculture, Hydrology and Water Quality*. CABI Publishing, Wallingford. 197-220 pp.
- Mouri, G., S. Takizawa and T. Oki. 2011. Spatial and temporal variation in nutrient parameters in stream water in a rural-urban catchment, Shikoku, Japan: Effects of land cover and human impact. *Journal of Environmental Management* 92:1837-1848.
- Para, J., P. Coble, B. Charrière, M. Tedetti, C. Fontana and R. Sempere. 2010. Fluorescence and absorption properties of chromophoric dissolved organic matter (CDOM) in coastal surface waters of the northwestern Mediterranean Sea, influence of the Rhône River. *Biogeosciences* 7:4083-4103.
- Psilovikos, A. and M. Elhag. 2013. Forecasting of remotely sensed daily evapotranspiration data over Nile Delta region, Egypt. *Water Resources Management* 27:4115-4130.
- Ruvalcaba, F. 2015. Calidad agronómica de las aguas residuales que riegan El Valle del Mezquital, Estado de Hidalgo. Tesis de Maestría en Ciencias. Colegio de Posgraduados. Montecillo, Estado de México. 120 p.
- Paz-Pellat, F., J. M. Hernández-Ayón, R. Sosa-Ávalos y A. S. Velázquez-Rodríguez. (eds.). 2019. Estado del Ciclo del Carbono: Agenda Azul y Verde. Programa Mexicano del Carbono. Texcoco, Estado de México, México. 716 p.
- Probst, J. L., J. Mortatti and Y. Tardy. 1994. Carbon river fluxes and weathering CO₂ consumption in the Congo and Amazon river basins. *Applied Geochemistry* 9(1):1-13.

- Sahu, M., and R. R. Gu. 2009. Modeling the effects of riparian buffer zone and contour strips on stream water quality. *Ecological Engineering* 35:1167-1177.
- Satapathy, D. R., R. Vijay, S. R. Kamble and R. A. Sohony. 2010. Remote sensing of turbidity and phosphate in creeks and coast of Mumbai: an effect of organic matter. *Transactions in GIS* 14:811-832.
- Sims, J. T., R. R. Simard and B.C. Joern. 1998. Phosphorus loss in agricultural drainage: Historical perspective and current research. *Journal of Environmental Quality* 27:277-293.
- Singh, K. P., A. Malik and S. Sinha. 2005. Water quality assessment and apportionment of pollution sources of Gomti river (India) using multivariate statistical techniques—a case study. *Analytica Chemical Acta* 538:355-374.
- Sliva, L. and D. D. Williams. 2001. Buffer zone versus whole catchment approaches to studying land use impact on river water quality. *Water Resources Research* 35:3462-3472.
- Smith, R. A., G. E. Schwarz and R. B. Alexander. 1997. Regional interpretation of water-quality monitoring data. *Water Resources Research* 33:2781-2798.
- Su, S., R. Xiao, X. Xu, Z. Zhang, X. Mi and J. Wu. 2013. Multi-scale spatial determinants of dissolved oxygen and nutrients in Qiantang River, China. *Regional Environmental Change* 13:77-89.
- Sun, R., L. Chen, W. Chen and Y. Ji. 2011. Effect of land-use patterns on total nitrogen concentration in the upstream regions of the Haihe River Basin, China. *Environmental Management* 51:45-58.
- Tang, Z., B. Engel, B. Pijanowski and K. Lim. 2005. Forecasting land use change and its environmental impact at a watershed scale. *Journal of Environmental Management* 76:35-45.
- Teta, R., V. Romano, G. Della-Sala, S. Picchio, C. De Sterlich, A. Mangoni and M. Lega. 2017. Cyanobacteria as indicators of water quality in Campania coasts, Italy: a monitoring strategy combining remote/proximal sensing and in situ data. *Environmental Research Letters* 12(2):1-13.
- Thompson, B. 1995. Stepwise regression and stepwise discriminant analysis need not apply here: A guidelines editorial. *Sage Publications* 5(4):525-534.
- Tong, S. T. and W. Chen. 2002. Modeling the relationship between land use and surface water quality. *Journal of Environmental Management* 66:377-393.
- Veliz-Lorenzo, L.O., A. Fernández y B. Venta. 2009. Reúso de aguas residuales domésticas para riego agrícola. *Revista CENIC, Ciencias Biológicas* 40(1):35-44.
- Xiao, R., G. Wang, Q. Zhang and Z. Zhang. 2016. Multi-scale analysis of relationship between landscape pattern and urban river water quality in different seasons. *Scientific Reports* 6:1-10.
- Yang, X., X. Yu, J. Cheng, R. Zheng, K. Wang, Y. Dai and A.T. Chow. 2017. Impacts of land-use on surface waters at the watershed scale in southeastern China: Insight from fluorescence excitation-emission matrix and PARAFAC. *Science of the Total Environment* 627:647-657.
- Wang, X. 2001. Integrating water-quality management and land-use planning in a watershed context. *Journal of Environmental Management* 61:25-36.
- Woli, K. P., T. Nagumo, K. Kuramochi, K. and R. Hatano. 2004. Evaluating river water quality through land use analysis and N budget approaches in livestock farming areas. *Science of the Total Environment* 329:61-74.
- Wu, C., J. Wu, J. Qi, L. Zhang, H. Huang, L. Lou and Y. Chen. 2010. Empirical estimation of total phosphorus concentration in the mainstream of the Qiantang River in China using Landsat TM data. *International Journal of Remote Sensing* 31:2309-2324.
- Wu, C. F. J. 1986. Jackknife, bootstrap and other resampling methods in regression analysis. *The Annals of Statistics* 14:1261-1295.