

ESTIMACIÓN DE VARIACIONES DE VOLÚMENES EN EL SISTEMA CUTZAMALA, MÉXICO POR MEDIO DE APRENDIZAJE PROFUNDO E IMÁGENES DE RADAR SAR

José Rodríguez Rosales^{1*}; Juan Manuel González Camacho²

¹Colegio de Postgraduados Campus Montecillo. Posgrado en Socioeconomía, Estadística e Informática-Cómputo Aplicado. Carretera México-Texcoco km 36.5, Montecillo, Texcoco, Estado de México, México. C. P. 56264.

Correo electrónico. jmgc@colpos.mx (*Autor para correspondencia)

Resumen

La gestión eficiente de los recursos hídricos es fundamental para la sostenibilidad del Sistema Cutzamala que abastece al Valle de México. La estimación precisa de las variaciones de volúmenes de agua en las presas y lagunas de este sistema es un tema relevante. En este estudio se describe la etapa inicial y la metodología propuesta para evaluar el uso de imágenes de Radar de Apertura Sintética (SAR, *Synthetic Aperture Radar*) del satélite Sentinel-1A y el modelo de aprendizaje profundo red U-Net el análisis periódico de las variaciones de volúmenes de las lagunas del Sistema Cutzamala. Las imágenes de radar se procesan en la plataforma SNAP (*Sentinel Application Platform*) y con el modelo U-Net se extraen características topológicas para calcular el área y el perímetro de los cuerpos de agua. Adicionalmente, se emplean datos de altimetría del modelo digital de elevación SRTM (*Shuttle Radar Topography Mission*) para mejorar la precisión de las estimaciones de las variaciones de volúmenes de agua en los embalses. Los resultados contribuirán a mejorar la gestión de los recursos hídricos, en un contexto de cambio climático y creciente demanda de agua en la región promover el uso de nuevas tecnologías con sensores remotos y de los modelos de inteligencia artificial para incrementar la precisión de la disponibilidad de agua en embalses.

Palabras claves: Teledetección, Aprendizaje profundo, Gestión de recursos hídricos, Segmentación de imágenes, Visión artificial.

Introducción

El monitoreo y la gestión eficiente de los recursos hídricos son fundamentales para la sostenibilidad ambiental del sistema Cutzamala que abastece al Valle de México (CONAGUA, 2015). Las lagunas de este sistema desempeñan un papel clave en la regulación del agua, lo que resalta la importancia de contar con estimaciones precisas de los volúmenes almacenados. Las imágenes satelitales se han consolidado como herramientas valiosas para el monitoreo hídrico (Condeça *et al.*, 2022). Sin embargo, la estimación precisa de los volúmenes de agua sigue siendo un desafío significativo. Estudios como el de Pham-Duc *et al.* (2022) muestran que el aprendizaje profundo aplicado a imágenes de satélite Sentinel 1, Sentinel 2 y Jason-3 permite estimar variaciones en los volúmenes de agua con alta correlación ($R = 0.99$) con las mediciones *in situ*. Los modelos de redes neuronales convolucionales (CNN) y recurrentes (RNN) se han aplicado exitosamente en imágenes Landsat para estimar volúmenes hídricos con un error cuadrático medio (RMSE) de 5.95 y un error absoluto medio (MAE) de 4.81 (Zhang *et al.*, 2019; Tao *et al.*, 2022). En este trabajo se describe la etapa inicial y la metodología adoptada para evaluar el uso de imágenes de radar y modelos de aprendizaje profundo para estimar las variaciones en los volúmenes de agua en los embalses del sistema Cutzamala, con el propósito de mejorar la gestión sostenible de los recursos hídricos.

Materiales y Métodos

- **Localización de la zona de estudio**

El sistema Cutzamala es un sistema hídrico de almacenamiento, conducción, potabilización y distribuidor de agua dulce para la población e industria de la Ciudad de México y el Estado de México. Es una de las fuentes de abastecimiento de agua potable más grandes del país, su extensión comprende las aguas de cuenca alta del río Cutzamala, que provienen de las presas Tuxpan y El Bosque, en el estado de Michoacán y Colorines, Ixtapan del Oro, Villa Victoria, Valle de Bravo y Chilesdo en el Estado de México (Santos *et al.*, 2021).

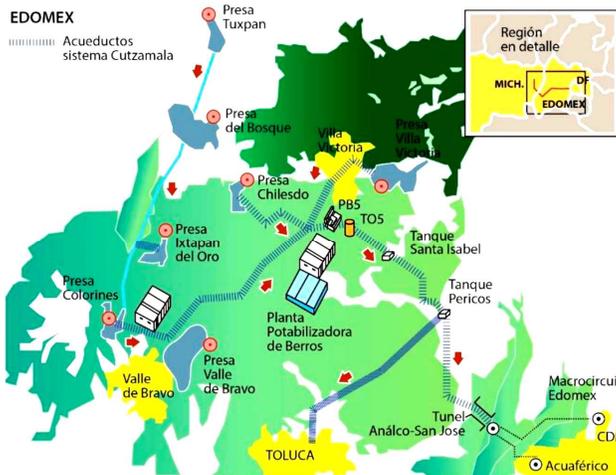


Figura 1. Esquema general del Sistema Cutzamala (Santos *et al.*, 2021).

El uso del suelo en la cuenca se distribuye en 46 % de bosque, 39 % de agricultura de temporal y 8 % de agricultura de riego, con un ligero incremento en las actividades agrícolas y de riego desde 1980. La urbanización desorganizada y la erosión del suelo son problemas importantes que agravan la gestión de los recursos hídricos. La calidad del agua está en riesgo, y se proyecta una reducción en la disponibilidad hídrica de 10 a 17 % debido al cambio climático, mientras que la demanda continúa aumentando en las zonas metropolitanas (CONAGUA, 2015).

El Sistema Cutzamala está compuesto por siete presas: tres de almacenamiento (Tuxpan, Ixtapan del Oro y Colorines) y cuatro derivadoras (El Bosque, Valle de Bravo, Villa Victoria y Chilesdo) (Santos *et al.*, 2021). En este reporte, nos centraremos exclusivamente en la presa derivadora de Valle de Bravo.

• Datos Utilizados

En este estudio se utilizan imágenes SAR (*Synthetic Aperture Radar*) del satélite Sentinel-1A desde la plataforma del Instituto de Geofísica de la Universidad de Alaska, Fairbanks (ASF, 2024) que están a libre disposición. Las características de las imágenes se detallan en la Tabla 1.

Tabla 1. Características y valores de imágenes Sentinel-1A GRD (ESA, 2024).

Característica	Valor/Descripción
Sensor	Sentinel-1A
Modo de adquisición	Interferométrico de Apertura Sintética (InSAR)
Polarización	Dual (HH y VV)
Resolución espacial	10 m x 10 m por pixel
Resolución temporal	Variable, la frecuencia de paso del satélite es por lo general es de 12 días.

Formato de datos	GRD (<i>Ground range detected</i>)
Cobertura espacial	Global
Información radiométrica	Amplitud y fase (para imágenes SLC), amplitud (para imágenes GRD)
Calibración radiométrica	Realizada en el nivel 1 para garantizar la consistencia entre diferentes imágenes
Corrección geométrica	Corrección de rango terrestre, lo que significa que las distancias en la imagen se corresponden con las distancias reales en el terreno

En general, las subcuencas del Sistema Cutzamala presentan un patrón estacional bien definido, caracterizado por una temporada de lluvias concentrada entre mayo y octubre y una temporada seca prolongada (CONAGUA, 2015). Para capturar la máxima variabilidad en los niveles de agua y evaluar la capacidad de almacenamiento de las presas, se ha seleccionado el periodo comprendido entre abril y mayo (pico de la temporada seca) y octubre y noviembre (inicio de la temporada de lluvias) del año 2024.

Se adquirieron dos imágenes del mes de abril y una del mes de mayo 2024.

Tabla 2. Imágenes de radar obtenidas (ESA, 2024).

Producto	Fecha de adquisición
S1A_IW_GRDH_1SDV_20240409T004849	04/09/2024, 00:48:49
S1A_IW_GRDH_1SDV_20240421T004849	04/21/2024, 00:48:49
S1A_IW_GRDH_1SDV_20240503T004849	05/03/2024, 00:48:49

- **Procesamiento de imágenes SAR**

En el estudio se utilizan productos de nivel 1 de la misión Sentinel-1A, los cuales, según la Agencia Espacial Europea (ESA, 2024), representan datos sin procesar. Estas imágenes se procesan en la plataforma SNAP 10.0.0 para realizar la calibración radiométrica, corrección geométrica y filtrado, según las directrices de la ESA y SEOM (2024). Este procesamiento es esencial para garantizar la calidad de los datos y asegurar la comparabilidad entre imágenes.

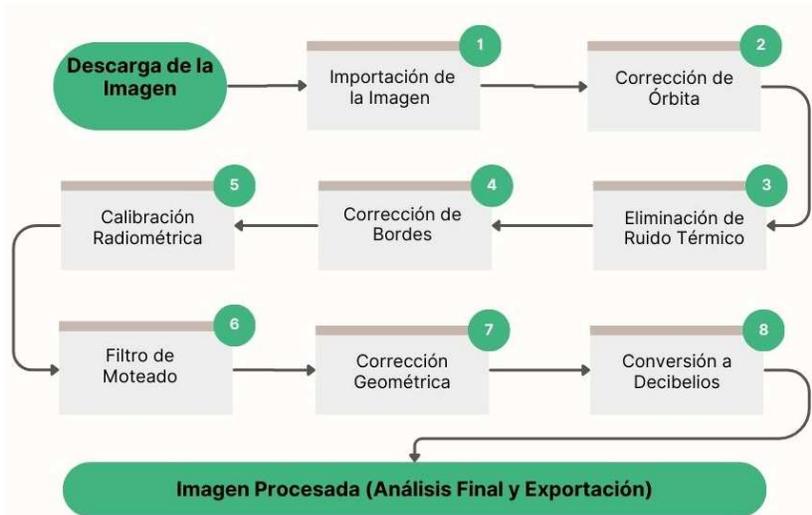


Figura 1. Esquema general del procesamiento de una imagen SAR con el software SNAP 10.0.0.

El procesamiento de una imagen SAR consiste en aplicar un conjunto de técnicas a los datos originales de un radar de apertura sintética para obtener una imagen de alta calidad y georreferenciada. Este proceso implica cargar la imagen en el software SNAP 10.0.0, calibrar los valores de retrodispersión para que sean comparables, corregir las distorsiones geométricas causadas por el terreno y el sensor, y reducir el ruido característico del radar (*speckle*). Al final de este proceso, se obtiene una imagen que se utiliza para diversas aplicaciones, como la cartografía, la vigilancia ambiental y la gestión de desastres (Podest *et al.*, 2017). El preprocesamiento transforma los datos originales de un radar en una imagen interpretable y útil para el análisis.

- **Construcción de conjuntos de datos (Muestreo)**

El conjunto de datos de entrada se crea por medio de una extracción de muestras de 128 x 128 píxeles en las imágenes de radar procesadas. Se usa el algoritmo de Otsu para segmentar la imágenes de muestra y crear las máscaras de entrenamiento, test y validación. Para generar un número de muestras mayor se aplican técnicas de aumento de datos tales como, rotaciones de hasta 30 grados, traslaciones de hasta 10 píxeles, escalados entre 0.9 y 1.1, y cambios de brillo de hasta $\pm 20\%$ (Tensorflow, 2022), esto con el fin de generar nuevas imágenes y aumentar la robustez en el entrenamiento del modelo de aprendizaje profundo debido a que el número de muestras es limitado.

Comentado [Reviewer1]: Duda: ¿se utiliza data augmentation porque no se tienen suficientes datos o es la configuración típica del modelo?

La base de datos se constituye con muestras de imágenes con dos clases: A) cuerpos de agua (ríos, lagunas) y B) áreas terrestres (infraestructura urbana, suelo desnudo, vegetación). Las muestras de la clase A se caracterizan por una textura homogénea y una baja reflectividad, mientras que las muestras de la clase B presentan mayor variabilidad en la textura y una señal de retorno más intensa

• **Red Neuronal Convolutiva (CNN U-Net)**

El modelo de aprendizaje profundo CNN U-Net es una arquitectura de red neuronal convolutiva diseñada para tareas de segmentación de imágenes biomédicas (Ronneberger *et al.*, 2015). La red consta de dos partes principales: una descendente y otra ascendente. En la parte descendente, se aplican de forma sucesiva convoluciones (*conv 3x3*), funciones de activación *ReLU* y operaciones de *pooling (max pool 2x2)* para extraer características de bajo nivel; en la parte ascendente, se emplean convoluciones y operaciones de *upsampling (up-conv 2x2)* para reconstruir la imagen a su resolución original, concatenando en cada nivel las características obtenidas en la parte descendente para preservar los detalles finos. Las conexiones entre ambas partes permiten que la información de contexto se propague a lo largo de la red para mejorar la precisión de la segmentación. La U-Net es especialmente eficaz en tareas que cuentan con conjuntos de datos limitados (Ronneberger, *et al.*, 2015). Si bien el tamaño del conjunto de datos fue un factor importante, otras características de U-Net, como su capacidad de capturar detalles finos, su arquitectura simétrica y su capacidad de generalización, influyeron en la selección de este modelo.

Comentado [Reviewer2]: ¿Es esta la razón por la que se seleccionó el modelo U-Net?

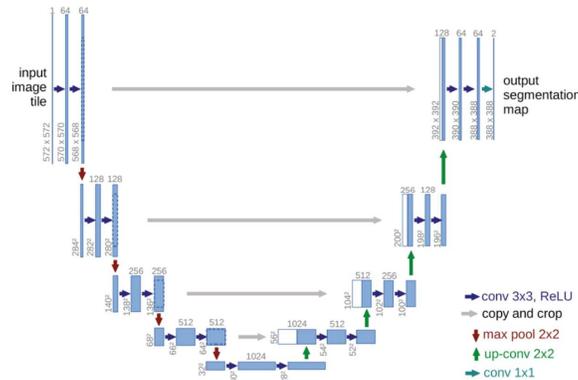


Figura 2. Arquitectura U-Net (ejemplo para 32x32 píxeles en la resolución más baja (Ronneberger, *et al.*, 2015).

• **Segmentación**

El modelo entrenado permite segmentar las imágenes SAR del área de estudio en diferentes fechas. Técnicas de topología de imágenes (algoritmo de Canny) se aplican para calcular el área y perímetro del lago (Sarkar, 2020) para detectar los contornos en las imágenes segmentadas. Posteriormente, se calculan el área y el perímetro en función de la escala espacial.

• **Estimación de Volúmenes**

La estimación de volúmenes se realiza comparando los resultados obtenidos de las imágenes SAR del mes de abril con el mes de octubre 2024 y con los datos de referencia de campo proporcionados por la CONAGUA, con base en curvas de área y capacidad. Adicionalmente, se utilizan los valores de altimetría del modelo digital de elevación SRTM (que se obtienen en la corrección geométrica durante el procesamiento de las imágenes en el software SNAP) para calcular la altura del nivel del agua y estimar los volúmenes mediante gráficas de altitud *versus* capacidad.

Comentado [Reviewer3]: ¿Cuál es el periodo por analizar? y se tienen datos de los tres conjuntos (SAR, CONAGUA, SRTM) para este.

Resultados y Discusión

La segmentación de las imágenes SAR mediante la red U-Net normalmente debe proporcionar resultados precisos en la delimitación de los cuerpos de agua en el Sistema Cutzamala. La combinación de imágenes SAR y altimetría permitirá obtener estimaciones confiables de las variaciones de volumen de las lagunas, con una correlación cercana a los datos *in situ* proporcionados por CONAGUA. Además, se anticipa que el modelo presentará un error cuadrático medio (RMSE) y un error absoluto medio (MAE) comparables a los reportados en estudios previos en otras áreas del conocimiento. Durante el Congreso se pretende presentar los primeros resultados y conclusiones preliminares del estudio.

Conclusiones

Este estudio pretende mostrar la importancia del uso de imágenes SAR y técnicas de aprendizaje profundo, como la red U-Net, como herramientas efectivas y de bajo costo para estimar con mayor precisión los volúmenes hídricos en cuerpos de agua de difícil acceso. Lo cual, conlleva a mejorar la gestión de los recursos hídricos en el Sistema Cutzamala.

Referencias Bibliográficas

- ASF (Alaska Satellite Facility). 2024. ASF Home. Alaska Satellite Facility. <https://asf.alaska.edu/> (Recuperado: septiembre 2024).
- CONAGUA (Comisión Nacional del Agua). 2015. Diagnóstico para el manejo integral de las subcuencas pertenecientes al Sistema Cutzamala. Diagnóstico para el manejo integral de las subcuencas pertenecientes al Sistema Cutzamala | Comisión Nacional del Agua | Gobierno | gov.mx (www.gob.mx) (Recuperado: septiembre 2024).
- Condeça J., Nascimento J., Barreiras N. 2022. Monitoring the storage volumen of water reservoirs using Google Earth Engine. *Water Resources Research*, 58, e2021WR030026. <https://doi.org/10.1029/2021WR030026>
- ESA & SEOM. (European Spatial Agency & Scientific Exploitation of Operational Missions) 2024. Sentinel Application Platform (SNAP 10.0). Programa para el análisis y procesamiento de imágenes satelitales (software). <http://step.esa.int/main/download/snap-download/> (Recuperado: septiembre 2024).

- ESA (European Space Agency). 2024. Open access to Sentinel-1 user products. Recuperado de <https://sentiwiki.copernicus.eu/web/s1-products#S1-Products-Level-1-Products> (Recuperado: septiembre 2024).
- Pham-Duc B., Frappart F., Tran-Anh Q., Tong S., Phan H., Quoc S., Pham A., Do Viet B. 2022. Monitoring Lake Volume Variation from Space Using Satellite Observations - A Case Study in Thac Mo Reservoir (Vietnam). *Remote Sensing*, 2022, 14 (16), pp.1-18. <https://hal.inrae.fr/hal-03770572>
- Podest E., Pinto N., Fielding E. 2017. ARSET - Introduction to Synthetic Aperture Radar. <https://appliedsciences.nasa.gov/join-mission/training/english/arset-introduction-synthetic-aperture-radar> (Recuperado: septiembre 2024).
- Ronneberger O., Fischer P., Brox T. 2015. U-Net: Convolutional Networks for Biomedical Image Segmentation. In: Navab, N., Hornegger, J., Wells, W., Frangi, A. (eds) *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015*. MICCAI 2015. Lecture Notes in Computer Science, vol 9351. Springer, Cham. https://doi.org/10.1007/978-3-319-24574-4_28
- Santos T., R., U., Medina M., R., Rodríguez V., J., M. 2021. Vulnerabilidad del Cutzamala. *Perspectivas IMTA*, 18. <https://doi.org/10.24850/b-imta-perspectivas-2021-18>
- Sarkar, S. 2020. *Python Image Processing Cookbook: Over 60 recipes to help you perform complex image processing and computer vision tasks with ease*. Packt Publishing.
- Tao H., Hameed M., Marhoon H., A., Zounemat-Kermani M., Heddami S., Kim S., Sulaiman S., O., Tan M., L., Sa'adi Z., Mehr A., D., Allawi M., F., Abba S., I., Zain J., M., Falah M., W., Jamei M., Bokde N., D., Bayatvarkeshi M., Al-Mukhtar M., Bhagat S., K., Tiyasha T., Khedher K., M., Al-Ansari N., Shahid S., Yaseen Z., M. 2022. Groundwater level prediction using machine learning models: A comprehensive review. *Neurocomputing*, 489, 271-308. <https://doi.org/10.1016/j.neucom.2022.03.014>
- TensorFlow. 2022. Aumento de datos. https://www.tensorflow.org/tutorials/images/data_augmentation?hl=es-419 (Recuperado: septiembre 2024).
- Zhang D., Shi K., Wang W., Wang X., Zhang Y., Qin B., Zhu M., Dong B., Zhang Y. 2024. An optical mechanism-based deep learning approach for deriving water trophic state of China's lakes from Landsat images. *Water Research*, 252, 121181. <https://doi.org/10.1016/j.watres.2024.121181>