

Desarrollo de Modelos de Inteligencia Artificial para el Estudio de la Exposición a Inundaciones del río Paraguay en Chaco utilizando Herramientas de Sensoramiento Remoto

Augusto González Omahen^{1,2} [0009-0004-6879-6161] gonzalezomahen@gmail.com;

Lucía M. Cappelletti³ lcappelletti@fund.ar;

Diego Fernández Slezak^{1,2} [0000-0001-6348-1559] dfslezak@dc.uba.ar.

¹ Universidad de Buenos Aires. Facultad de Ciencias Exactas y Naturales. Departamento de Computación. Buenos Aires, Argentina.

² CONICET - Universidad de Buenos Aires. Instituto de Ciencias de la Computación (ICC). Laboratorio de Inteligencia Artificial Aplicada (LIAA). Buenos Aires, Argentina.

³ FUNDAR, Buenos Aires, Argentina.

Resumen. La producción agropecuaria es la actividad económica más relevante en la provincia del Chaco, Argentina. Debido a factores ambientales como las altas precipitaciones en la región, su población rural y producción agropecuaria se ve afectada de manera directa por inundaciones. Este trabajo consiste en el desarrollo de modelos de inteligencia artificial (IA) con el propósito de mejorar la identificación de las zonas anegables de la provincia, tomando como sitio de estudio el Departamento de Bermejo. Si bien existen mapas globales para identificar agua en superficie, estos no garantizan su utilidad a escala regional. Es por ello que la identificación de esta variable generaría conocimiento relevante para el monitoreo de inundaciones y planificación de estrategias. Para esto diseñamos herramientas de identificación remota mediante el empleo de imágenes satelitales ópticas. Implementamos tres modelos de segmentación de imágenes: Support Vector Machine (SVM) y Random Forest (RF), modelos de aprendizaje automático tradicionales, y un modelo basado en técnicas de aprendizaje profundo y en la arquitectura U-Net. El objetivo de este trabajo es optimizar la detección de agua superficial mediante redes neuronales convolucionales que consideren la vecindad espacial de los píxeles, en lugar de los modelos clásicos que lo omiten. Se utilizaron imágenes satelitales Landsat para entrenar y evaluar el rendimiento de los modelos. Los resultados en la segmentación y detección de agua en superficie del modelo basado en una arquitectura U-Net mejora un 24% el índice DICE y un 17% el *accuracy*, respecto a los modelos de SVM y RF. Estos resultados validan que técnicas de aprendizaje profundo que consideran la vecindad de píxeles potencian la identificación de agua en superficie.

Palabras clave: Inundaciones, Chaco, Imágenes Satelitales, Inteligencia Artificial, U-Net.

Development of Artificial Intelligence Models to Assess Flood Exposure of the Paraguay River in Chaco Using Remote Sensing Tools

Abstract. Agriculture and livestock farming are the main economic activities in the Province of Chaco, Argentina. Due to environmental characteristics such as high regional precipitation, flooding directly affects rural populations and agricultural production.

This study focuses on developing artificial intelligence (AI) models to improve the identification of flood-prone areas, using the Department of Bermejo as a case study. Although global surface water maps exist, they are not always reliable at regional scales. Therefore, generating accurate information on surface water is essential for effective flood monitoring and regional planning. We developed remote sensing tools based on optical satellite imagery and implemented three image segmentation models: Support Vector Machine (SVM) and Random Forest (RF), based on traditional machine learning algorithms, and a deep learning model using the U-Net architecture. The goal of this study is to enhance surface water detection using Convolutional Neural Networks (CNNs) that incorporate spatial pixel context, in contrast to traditional models that ignore this aspect. We used Landsat satellite imagery to train and evaluate model performance. The U-Net-based model achieved a 24% increase in the DICE coefficient and a 17% improvement in accuracy compared to the SVM and RF models. These findings confirm that deep learning techniques that account for spatial context significantly improve the identification of surface water.

Keywords: Floods, Chaco, Satellite Imagery, Artificial Intelligence, U-Net

1 Introducción

Este trabajo tiene como propósito fortalecer la planificación estratégica regional en el marco de temáticas ambientales. El objetivo principal es el desarrollo de modelos de inteligencia artificial (IA) para el estudio de la exposición a inundaciones del río Paraguay en Chaco. Uno de los objetivos específicos consiste en diseñar herramientas de monitoreo operativo remoto sobre uso y cobertura del suelo mediante el empleo de imágenes satelitales. Tenemos particular interés en detectar las regiones inundables, considerando que en el sitio de estudio habitan poblaciones rurales cuyas viviendas, medios de transporte y producciones agrícola-ganaderas son afectadas gravemente por eventos de precipitación o crecida de ríos. En este contexto, resulta relevante implementar, en primer lugar, herramientas que proporcionen información útil para la caracterización del agua superficial, contribuyendo al conocimiento para la planificación de estrategias ambientales a escala regional. Si bien existen mapas globales para identificar agua superficial, su aplicación a escala global no garantiza su utilidad a escala regional (Li et al., 2018; Smichowski et al., 2022). Para alcanzar este objetivo, empleamos datos de teledetección para identificar agua en superficie. Para lograr dicho objetivo en la identificación de estas áreas utilizaremos modelos de aprendizaje profundo, tomamos como base los estudios antecedentes de Li et al., 2018 y Venturini et al., 2023, como base de comparación.

Los trabajos mencionados tienen en común la implementación de modelos de clasificación que no consideran información acerca de la vecindad de los píxeles que componen las imágenes. En este trabajo exploramos si dicha característica es relevante para la detección de agua, por lo que implementamos métodos de Aprendizaje Profundo basados en Redes Neuronales Convolucionales (CNN) que sí tienen en cuenta estas propiedades, empleando imágenes satelitales.

2 Métodos y Materiales

En este trabajo utilizamos imágenes de la misión Landsat 8. Este satélite cuenta con una frecuencia de 16 días. El satélite captura aproximadamente setecientas imágenes cada día y cada escena tiene un cubrimiento de 185 x 180 km con una resolución de 30 metros de resolución espacial. Estas imágenes presentan un total de once bandas, a diferencia de las imágenes comúnmente conocidas como RGB que solo cuentan con las tres bandas rojo, azul y verde. Cada banda permite identificar distintos elementos superficiales según su comportamiento espectral. Esta información espectral permite la identificación y el monitoreo de elementos terrestres, como el agua superficial (Franco, 2017).

Descargamos y pre procesamos escenas Landsat 8, recortando la sección de interés y seleccionando solamente aquellas bandas espectrales de utilidad para nuestro estudio, filtrando aquellas que presentaran un porcentaje de nubosidad mayor al 5%. La nubosidad es un conocido problema (Li et al., 2018), pues las nubes forman una barrera física que impiden la correcta recepción de la superficie terrestre.

El área de estudio comprende las ciudades de La Leonesa y Las Palmas del departamento Bermejo dentro de la provincia del Chaco, abarcando aproximadamente 42 km x 45 km.

Las clases de cobertura terrestre consideradas fueron: agua, área urbana, vegetación, vegetación acuática y otros. Utilizamos estas clases ya que son las que se emplean en los trabajos previos de Smichowski et al., 2022 y Venturini et al., 2023. También estas cuatro clases son claves ya que: la clase agua constituye el elemento principal de las inundaciones; la ciudad, pues son las principales áreas habitadas expuestas a las inundaciones y anegamientos de la región; con la clase vegetación agrupamos pastizales, palmares y bosques, ya que su diferenciación individual no es relevante para los objetivos del estudio; la vegetación acuática fue una clase necesaria porque en esta área de estudio esta vegetación puede ocultar pequeños ríos o áreas inundadas, limitando la capacidad de los sensores para detectar cuerpos de agua (Li et al., 2018; Smichowski et al., 2022; Venturini et al., 2023). Para este trabajo contamos con la colaboración de expertos regionales, quienes no solo asistieron en el etiquetado de clases, sino que también aportaron valiosa información sobre características locales relevantes para su adecuada determinación.

Cada imagen Landsat fue segmentada y asociada con una imagen de igual tamaño que contenía todas las etiquetas correspondientes. Por lo tanto, cada píxel de una imagen estaba etiquetado como agua, ciudad, vegetación, vegetación acuática u otro. Estas imágenes cuentan con 1526 x 1397 píxeles. Con un total de diez imágenes recolectadas entre enero y noviembre de 2022, clasificamos aproximadamente 1.000.000 de píxeles-muestra para las clases ciudad, agua y vegetación, mientras que para la clase vegetación acuática contábamos con solo aproximadamente 8000 píxeles-muestra. Es por esto que eliminamos aleatoriamente muestras de las demás clases para solucionar el desbalance. Esta cantidad se consideró suficiente para poder entrenar los modelos basándonos en los estudios anteriores de Smichowski et al., 2022 y Venturini et al., 2023.

Implementamos tres modelos: dos basados en técnicas de aprendizaje automático, Support Vector Machine (SVM; Noble, 2006) y Random Forest (RF; Breiman, 2001), y un tercer modelo que usa técnicas de aprendizaje profundo,

particularmente basado en la arquitectura U-Net (Du et al., 2020). Para evaluar el desempeño de los modelos, utilizamos las métricas de *accuracy*, *F1-score* y el coeficiente DICE, ya que estos dos últimos son de las métricas más usadas en la segmentación multiclase de imágenes (Jha et al., 2023; Atas, 2023). Para los modelos SVM y RF utilizamos la métrica *F1-score* integrada a la librería Scikit-Learn (Sklearn F1-score, 2025), para el modelo CNN empleamos el coeficiente DICE. Al calcular tanto *F1-score* como DICE, calculamos la métrica por clase y luego tomamos el promedio. Es razonable comparar ambas métricas pues son equivalentes al ser calculadas de igual manera (Setiawan, 2020).

2.1 Implementación de Modelos

Para entrenar los modelos, realizamos una búsqueda de hiperparámetros que nos permitiera ajustar cada algoritmo al problema específico. Para la correcta selección de los mismos implementamos una búsqueda de grilla probando distintas combinaciones de hiperparámetros para identificar la más eficaz. Para esta búsqueda de hiperparámetros utilizamos la herramienta GridSearchCV (Sklearn GridSearchCV, 2025). En cuanto a los modelos de SVM y RF finalmente utilizamos los hiperparámetros por defecto (Sklearn SVM, 2025; Sklearn RF, 2025).

Para el modelo basado en la arquitectura U-Net utilizamos como modelo base a Du et al., 2020 que se utiliza para segmentar imágenes médicas. Este modelo fue adaptado para el uso de imágenes satelitales. La arquitectura de este modelo consta de tres componentes principales: trayecto de codificación, responsable de la extracción y compresión de características; cuello de botella, la parte más profunda de la red donde se concentra la información; y trayecto de decodificación, encargado de la recuperación espacial y reconstrucción de la imagen segmentada. Además, agregamos el uso de bloques residuales, lo que incorpora conexiones de salto.

3 Resultados, Discusión y Conclusiones

Para cada modelo calculamos las métricas por clase: **SVM, *F1-score***: Ciudad: 0.39; Agua: 0.46; Vegetación: 0.66; Vegetación acuática: 0.28. **RF, *F1-score***: Ciudad: 0.43; Agua: 0.48; Vegetación: 0.75; Vegetación acuática: 0.3. **U-Net, DICE**: Ciudad: 0.53; Agua: 0.66; Vegetación: 0.80; Vegetación acuática: 0.44. Además, para cada modelo obtuvimos los siguientes resultados generales: **SVM: *Accuracy* 54%** y un coeficiente *F1-score* del 0.45. **RF: *Accuracy* 59%** y un coeficiente *F1-score* del 0.49. **U-Net: *Accuracy* 69%** y un coeficiente DICE del 0.61.

El modelo U-Net mejoró un 24% el coeficiente DICE y un 17 % el *accuracy*, en comparación con los modelos SVM y RF. Estos resultados validan que las técnicas de aprendizaje profundo que consideran la vecindad de píxeles potencian la identificación de agua en superficie y ciudad. Destacando que el uso de técnicas de aprendizaje profundo puede mejorar las detecciones con respecto a las técnicas clásicas de aprendizaje automático.




Fig 1. A) Imagen Satelital Original, B) Segmentación modelo SVM, C) Segmentación modelo RF, D) Segmentación modelo U-Net.

La **Fig. 1** muestra cómo el modelo U-Net optimiza la detección de todas las clases respecto a los modelos SVM y RF. Al observar las métricas por clase, estas presentan mejoras para el modelo U-Net en todas las clases, especialmente la clase agua y la clase vegetación acuática, en comparación con el modelo RF.

Este estudio presenta algunas limitaciones que deben considerarse. En primer lugar, el marcado desbalance de clases entre las etiquetas -especialmente la escasa representación de la clase vegetación acuática con solo ~8.000 píxeles frente a ~1.000.000 para las demás- puede sesgar el entrenamiento y limitar la capacidad del modelo para generalizar sobre escenas con baja presencia de esa categoría. Además, la restricción de uso de imágenes con nubosidad superior al 5% reduce la cobertura temporal de datos y puede generar variaciones en la calidad de la evaluación en períodos con mayor nubosidad, limitando la disponibilidad de escenas a emplear y aumentando la probabilidad de artefactos en la segmentación.

En cuanto a trabajo futuro, tras optimizar la detección de agua en superficie, planeamos desarrollar un modelo específico para la detección de zonas inundables.

4 Referencias

Atas, I. (2023). Performance evaluation of jaccard-dice coefficient on building segmentation from high resolution satellite images. *Balkan Journal of Electrical and Computer Engineering*, 11(1), 100-106. Breiman, L. (2001). Random forests. *Machine learning*, 45, 5-32.

Du, G., Cao, X., Liang, J., Chen, X., & Zhan, Y. (2020). Medical image segmentation based on U-net: A review. *Journal of Imaging Science & Technology*, 64(2).

Franco, R. (2017). Composiciones LANDSAT en ArcGis. Guía básica. *Revista de Teledetección*, 10.

Jha, S., Kumar, R., Priyadarshini, I., Smarandache, F., & Long, H. V. (2019). Neutrosophic image segmentation with dice coefficients. *Measurement*, 134, 762-772.

Li, J., Yang, X., Maffei, C., Tooth, S., & Yao, G. (2018). Applying independent component analysis on Sentinel-2 imagery to characterize geomorphological responses to an extreme flood event near the non-vegetated Río Colorado terminus, Salar de Uyuni, Bolivia. *Remote Sensing*, 10(5), 725.

Noble, W. S. (2006). What is a support vector machine?. *Nature biotechnology*, 24(12), 1565-1567.

Setiawan, A. W. (2020). Image segmentation metrics in skin lesion: accuracy, sensitivity, specificity, dice coefficient, Jaccard index, and Matthews correlation coefficient. In *2020 International Conference on Computer Engineering, Network, and Intelligent Multimedia (CENIM)* (pp. 97-102). IEEE.

Smichowski, H., Contreras, F. I., & Giese, A. C. (2022). Seguimiento de la extensión areal de los humedales subtropicales del noreste de Argentina mediante la aplicación de Google Earth Engine. *Investigaciones Geográficas*, (78), 131-152.

Venturini, V., Marchetti, Z. Y., Fagioli, G., & Walker, E. (2023). Análisis del desempeño de técnicas de aprendizaje automático para identificar vegetación acuática con bandas de Sentinel-2. *Ecología Austral*, 33(3), 743-756.

Scikit-Learn F1-score.
https://scikit-learn.org/stable/modules/generated/sklearn.metrics.f1_score.html
 (último acceso 16 de junio, 2025).

Scikit-Learn GridsearchCV.
https://scikit-learn.org/stable/modules/generated/sklearn.model_selection.Grid

SearchCV.html (último acceso 16 de junio, 2025).

Scikit-Learn Linear Support Vector Classification (Linear SVM). Scikit-Learn.
<https://scikit-learn.org/stable/modules/generated/sklearn.svm.LinearSVC.html> (último acceso 16 de junio, 2025).

Scikit-Learn Random Forest Classifier.
<https://scikit-learn.org/stable/modules/generated/sklearn.ensemble.RandomForestClassifier.html> (último acceso 16 de junio, 2025).