

# Capítulo 5

---

## **Desarrollo e implementación de un clasificador espectral para la discriminación de superficies terrestres y acuáticas utilizando datos de sentinel 2 y técnicas de aprendizaje automático**

*Jesús Bojórquez Delgado<sup>1</sup>  
Gilberto Bojórquez Delgado<sup>2</sup>  
Manuel Alfredo Flores Rosales<sup>3</sup>*

<https://doi.org/10.61728/AE24004541>



---

<sup>1</sup> Tecnológico Nacional de México/Instituto Tecnológico Superior de Guasave, Guasave, Sinaloa, México. Universidad Autónoma Indígena de México, Los Mochis, Sinaloa, México. Email: [jesus.bd@guasave.tecnm.mx](mailto:jesus.bd@guasave.tecnm.mx)

<sup>2</sup> Tecnológico Nacional de México/Instituto Tecnológico Superior de Guasave, Guasave, Sinaloa, México. Universidad Autónoma Indígena de México, Los Mochis, Sinaloa, México. Email: [gilberto.bd@guasave.tecnm.mx](mailto:gilberto.bd@guasave.tecnm.mx)

<sup>3</sup> Tecnológico Nacional de México/Instituto Tecnológico Superior de Guasave, Guasave, Sinaloa, México. Email: [manuel.fr@guasave.tecnm.mx](mailto:manuel.fr@guasave.tecnm.mx)

## Resumen

La clasificación precisa de superficies terrestres y acuáticas es fundamental para la gestión de recursos naturales, con aplicaciones en la agricultura de precisión y la gestión del agua. Este estudio desarrolló e implementó un clasificador espectral utilizando datos de Sentinel-2 y técnicas avanzadas de aprendizaje automático, evaluando algoritmos como CNN 1D, MLP, LSTM, GBM y Random Forest. Los resultados mostraron que el modelo CNN 1D alcanzó una precisión, recall y F1-score del 100 %, superando otros métodos tradicionales. La capacidad del modelo para capturar características espaciales complejas de los datos espectrales fue clave para su rendimiento. La matriz de confusión confirmó la efectividad del modelo sin errores de clasificación en el conjunto de prueba. Las implicaciones prácticas son significativas, permitiendo una clasificación confiable que mejora la gestión de recursos hídricos y terrestres. Sin embargo, se reconoce la necesidad de más recursos computacionales y una evaluación en conjuntos de datos más amplios y diversos. Futuras investigaciones deberían expandir el conjunto de datos y explorar la integración de otras técnicas para mejorar la robustez del modelo. Este estudio aporta al conocimiento académico y ofrece herramientas prácticas para la gestión y conservación de recursos naturales, proponiendo direcciones prometedoras para futuras investigaciones.

## Introducción

La clasificación precisa de superficies terrestres y acuáticas es esencial para diversas aplicaciones en la gestión de recursos naturales, monitoreo ambiental y planificación del uso del suelo. La teledetección, especialmente con el uso de satélites como Sentinel-2, ha proporcionado datos espectrales de alta resolución que son fundamentales para estas tareas. Sentinel-2, lanzado por la Agencia Espacial Europea (ESA), ofrece una

cobertura global y una frecuencia de revisita de cinco días, características que lo hacen ideal para la monitorización continua del medioambiente (Huang et al., 2020).

La capacidad de Sentinel-2 para captar imágenes en 13 bandas espectrales permite una discriminación detallada entre diferentes tipos de superficies (López Calderón et al., 2023). Estas imágenes se utilizan ampliamente en la agricultura, la gestión de recursos hídricos y la vigilancia de cambios ambientales (Orynbaikyzy et al., 2020). La combinación de datos ópticos y de radar de apertura sintética (SAR) ha demostrado mejorar significativamente la precisión en la clasificación de la cobertura terrestre, facilitando un análisis más completo de las características biofísicas y estructurales de los objetos de interés (Eisfelder et al., 2024). Estudios han demostrado que la combinación de estas tecnologías puede aumentar la exactitud y robustez de los modelos de clasificación, proporcionando una herramienta valiosa para la gestión y conservación de recursos naturales (Eisfelder et al., 2024).

El uso de datos de Sentinel-2, en combinación con técnicas avanzadas de aprendizaje automático, representa una solución innovadora y eficaz para la clasificación de superficies terrestres y acuáticas (Phiri et al., 2020). Estudios recientes han mostrado que la integración de índices espectrales y características temporales puede mejorar significativamente la precisión de la clasificación en regiones propensas a nubosidad y otras perturbaciones atmosféricas (Gomez et al., 2019). Estos métodos permiten la utilización de análisis estadísticos temporales para caracterizar la variabilidad anual de la vegetación, proporcionando una mejor separabilidad entre diferentes tipos de cobertura terrestre (Yousefi et al., 2022). Además, se ha comprobado que la incorporación de datos multitemporales puede reducir la influencia de factores aleatorios como las condiciones meteorológicas, mejorando así la fiabilidad de los modelos predictivos (Huang et al., 2020).

La combinación de datos ópticos y de radar ha mostrado ser efectiva en la mejora de la precisión de la clasificación de cultivos y otras aplicaciones de monitoreo agrícola (Riego y Drenaje, 2021). Esta combinación permite una representación más amplia de la información biofísica y estructural de los objetos de interés, aumentando la exactitud y robu-

tez de los modelos de clasificación (Duan et al., 2023). En un estudio realizado en Etiopía, se demostró que la utilización conjunta de datos de Sentinel-1 y Sentinel-2 mejoraba la exactitud de la clasificación de tipos de cultivos, subrayando la importancia de disponer de un conjunto de datos de referencia suficiente para mejorar los resultados de los modelos (Eisfelder et al., 2024). Esta metodología también ha sido aplicada con éxito en otros contextos, como la clasificación de la textura del suelo y la identificación de especies de árboles, lo que resalta su versatilidad (Gomez et al., 2019).

El objetivo principal de este estudio es desarrollar e implementar un clasificador espectral para la discriminación de superficies terrestres y acuáticas utilizando datos de Sentinel-2 y técnicas de aprendizaje automático. Específicamente, se busca evaluar la eficacia de las bandas espectrales de Sentinel-2 para identificar las más relevantes en la discriminación entre superficies terrestres y acuáticas. Para ello, se desarrollará y entrenará un modelo de red neuronal que utilice estos datos espectrales, y se evaluará su rendimiento a través de métricas como precisión, recall y F1-score utilizando un conjunto de datos de prueba (Danuri y Mohd Pozi, 2024). Además, se analizará la capacidad del modelo para generalizar a diferentes regiones y condiciones ambientales, proporcionando así herramientas prácticas para el monitoreo y gestión de recursos naturales, con aplicaciones en agricultura de precisión, gestión del agua y conservación ambiental.

Este estudio no solo contribuirá al conocimiento académico, sino que también proporcionará herramientas prácticas para el monitoreo y gestión de recursos naturales. Las técnicas avanzadas de clasificación utilizando datos de Sentinel-2 y aprendizaje automático tienen el potencial de revolucionar la manera en que se gestionan los recursos naturales, permitiendo una toma de decisiones más informada y efectiva (Syrris et al., 2019).

El desarrollo de un clasificador espectral basado en datos de Sentinel-2 permitirá una mayor precisión en la discriminación de superficies terrestres y acuáticas, lo cual es esencial para la gestión eficaz de los recursos hídricos y la planificación del uso del suelo (Caballero Chávez y Duarte, 2023). Además, el uso de técnicas de aprendizaje automático permitirá automatizar y optimizar el proceso de clasificación, reduciendo

el tiempo y los recursos necesarios para obtener resultados precisos. La capacidad de este clasificador para generalizar a diferentes condiciones ambientales también lo hace una herramienta valiosa para su aplicación en diversas regiones y contextos, desde la agricultura de precisión hasta la conservación de ecosistemas críticos.

## **Metodología**

Para desarrollar un clasificador espectral eficaz que discrimine entre superficies terrestres y acuáticas utilizando datos de Sentinel-2 y técnicas de aprendizaje automático, se ha diseñado una metodología rigurosa que incluye varias etapas clave: recolección y preprocesamiento de datos, desarrollo y entrenamiento del modelo, y evaluación y validación de su rendimiento. Este enfoque garantiza la precisión y robustez del modelo, además de su aplicabilidad en diferentes contextos geográficos y ambientales.

## **Materiales**

Los materiales utilizados en este estudio son fundamentales para asegurar la calidad y precisión de los resultados obtenidos. A continuación, se detallan los principales componentes que incluyen datos satelitales, software y herramientas de procesamiento, hardware de alto rendimiento, y datos de referencia esenciales para la validación del modelo.

### **1. Datos Satelitales de Sentinel-2:**

- **Imágenes multiespectrales:** Se utilizaron imágenes satelitales de Sentinel-2 que abarcan 13 bandas espectrales (B1 a B12 y B8A), proporcionando información en diferentes longitudes de onda desde el visible hasta el infrarrojo cercano y de onda corta. Las imágenes fueron obtenidas de la plataforma Sentinel Hub.
- **Resolución espacial y temporal:** Las imágenes seleccionadas tienen una resolución espacial de 10, 20 y 60 metros, dependiendo de la banda espectral, y una frecuencia de revisita de cinco días, lo que permite un monitoreo detallado y continuo de las áreas de estudio.
- **Niveles de procesamiento:** Se utilizaron datos de nivel 1C, que incluyen correcciones radiométricas y geométricas, y se procesaron a

nivel 2A para corrección atmosférica utilizando el algoritmo Sen2Cor, lo que proporciona reflectancias de superficie listas para análisis.

- Área de estudio: El área de estudio, ubicada en el estado de Sinaloa, México, abarca 22 puntos de muestreo, de los cuales 11 corresponden a superficies terrestres y 11 a cuerpos de agua. Dichos puntos, representados en la Figura 1 por círculos rojos, fueron seleccionados estratégicamente para asegurar una cobertura equilibrada y representativa de las distintas clases a discriminar. Esta distribución geoespacial permite validar la robustez del clasificador espectral al considerar tanto la variabilidad terrestre como la acuática dentro del contexto de la región de estudio.

**Figura 1**

*Mapa del área de estudio en Sinaloa con los puntos de muestreo en tierra y agua.*



## 2. Software y herramientas:

- **Google Earth Engine (GEE):** Esta plataforma se utilizó para la gestión y el procesamiento de grandes volúmenes de datos satelitales, aprovechando sus capacidades de computación en la nube para la generación de índices espectrales y la extracción de características.
- **Librerías de Python:** Se emplearon librerías como TensorFlow y Keras para el desarrollo y entrenamiento de modelos de aprendizaje automático, NumPy y Pandas para la manipulación y análisis de datos, y Scikit-learn para tareas de preprocesamiento y evaluación de modelos.
- **QGIS y SNAP:** Estas herramientas se utilizaron para la visualización y análisis geoespacial de las imágenes procesadas, permitiendo una inspección visual detallada y la generación de mapas temáticos.

## 3. Hardware:

- **Computadoras de alto rendimiento:** Se utilizaron estaciones de trabajo equipadas con unidades de procesamiento gráfico (GPU) NVIDIA, necesarias para acelerar el entrenamiento de modelos de redes neuronales profundas. Las especificaciones incluyen GPU de la serie NVIDIA RTX 3000, con 8 GB de memoria dedicada.
- **Almacenamiento y procesamiento:** Sistemas de almacenamiento de alta capacidad y velocidad (SSD) para manejar grandes volúmenes de datos de imágenes satelitales y facilitar un acceso rápido durante el preprocesamiento y entrenamiento del modelo.

## 4. Datos de referencia:

- **Ground Truth:** Datos de campo recogidos mediante campañas de muestreo que incluyen coordenadas geográficas precisas y clasificaciones de superficie (agua o tierra) para validar las predicciones del modelo. Estos datos son esenciales para entrenar y evaluar la precisión del clasificador.
- **Fuentes complementarias:** Información adicional obtenida de bases de datos geoespaciales públicas y estudios previos que proporcionan clasificaciones de uso del suelo y coberturas terrestres, utilizadas para complementar los datos de referencia.

## Métodos

La metodología desarrollada se basa en un enfoque sistemático para asegurar la precisión y robustez del modelo. A continuación, se describen los métodos utilizados en cada una de las etapas del estudio, desde la recolección de datos hasta la validación del modelo.

### 1. Recolección de datos:

- Descarga de imágenes satelitales Sentinel-2 de alta resolución temporal y espacial, centradas en áreas de estudio específicas que incluyen superficies terrestres y acuáticas.
- Selección de imágenes multitemporales para capturar variaciones estacionales y reducir la influencia de condiciones atmosféricas temporales.
- Se tomaron muestras desde el primero de enero de 2018 hasta el 10 de julio de 2024, siendo 512 las seleccionadas, y descartadas las de menor calidad.

### 2. Preprocesamiento de datos:

- Aplicación de correcciones radiométricas y atmosféricas a las imágenes utilizando Sen2Cor.
- Generación de índices espectrales como NDVI (Normalized Difference Vegetation Index) y NDWI (Normalized Difference Water Index) para mejorar la discriminación de clases.
- Resampléo y normalización de las bandas espectrales para asegurar una consistencia en la resolución espacial.

### 3. Diseño del modelo:

- Desarrollo de un modelo de red neuronal convolucional (CNN) para la clasificación de imágenes, seleccionando hiperparámetros óptimos a través de técnicas de validación cruzada.
- Entrenamiento del modelo utilizando un conjunto de datos de entrenamiento balanceado que incluya ejemplos representativos de todas las clases (superficies terrestres y acuáticas).
- Implementación de técnicas de aumento de datos para mejorar la robustez del modelo y evitar el sobreajuste.

4. Experimentación y evaluación:

- División del conjunto de datos en subconjuntos de entrenamiento (70 %), validación (15 %) y prueba (15 %) para evaluar el rendimiento del modelo.
- Medición del rendimiento del modelo utilizando métricas como precisión, recall, F1-score y la matriz de confusión.
- Análisis de la capacidad de generalización del modelo mediante pruebas en diferentes regiones geográficas y bajo diversas condiciones ambientales.

5. Validación cruzada y optimización:

- Uso de validación cruzada k-fold para evaluar la estabilidad y robustez del modelo.
- Optimización de hiperparámetros mediante técnicas como Random Search y Bayesian Optimization para mejorar el rendimiento del modelo.

## **Resultados y discusión**

En esta sección se presentan y analizan los resultados obtenidos del desarrollo e implementación de un clasificador espectral diseñado para discriminar entre superficies terrestres y acuáticas utilizando datos multi-espectrales de Sentinel-2 y técnicas avanzadas de aprendizaje automático. Se evaluaron múltiples algoritmos de clasificación, incluyendo redes neuronales convolucionales (CNN 1D), redes neuronales multicapa (MLP), modelos Long Short-Term Memory (LSTM), Gradient Boosting Machines (GBM) y Random Forest, con el objetivo de identificar el enfoque más preciso y robusto. Los resultados se detallan en términos de precisión, recall y F1-score, proporcionando una visión integral del rendimiento de cada modelo. Además, se discuten las implicaciones prácticas de estos hallazgos en la gestión de recursos naturales y se abordan las limitaciones del estudio, sugiriendo posibles direcciones para futuras investigaciones.

## **Distribución de las bandas espectrales**

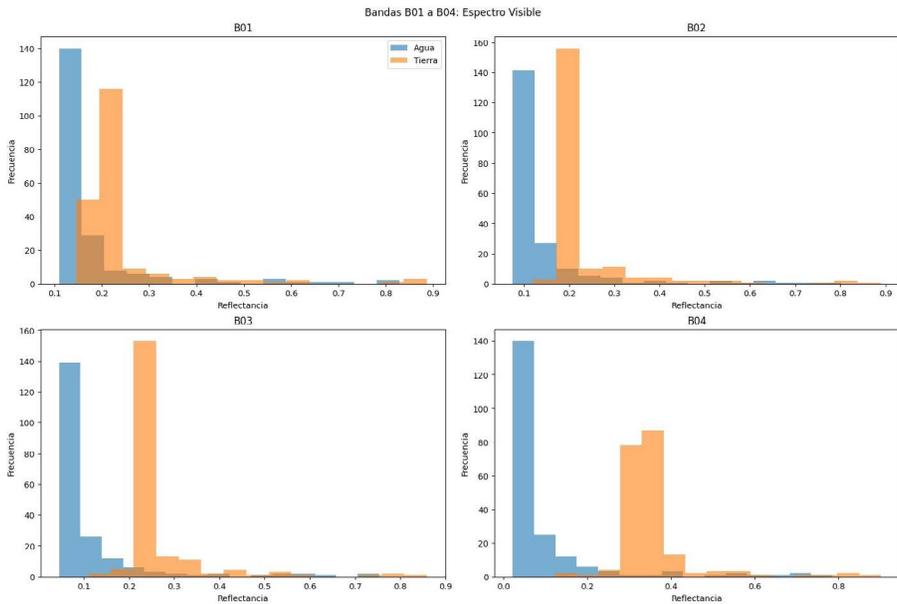
El análisis de la distribución de las bandas espectrales de Sentinel-2 para las superficies de agua y tierra proporciona una base sólida para la discriminación efectiva utilizando técnicas de aprendizaje automático. A continuación, se presentan los histogramas que muestran la distribución de reflectancias para cada banda espectral, diferenciando entre superficies de agua y tierra.

- Bandas B01 a B04: Espectro Visible
  - B01: Las superficies de agua tienen valores de reflectancia más bajos en comparación con las superficies de tierra.
  - B02: La reflectancia del agua es significativamente menor que la de la tierra.
  - B03: Las superficies de tierra muestran una mayor reflectancia en comparación con el agua.
  - B04: Las diferencias en la reflectancia son evidentes, con la tierra presentando valores más altos.

La Figura 2 muestra la distribución de reflectancia en el espectro visible. Se observa una clara separación entre las superficies de agua y tierra:

**Figura 2**

*Distribución de Reflectancia en el Espectro Visible (B01 a B04).*

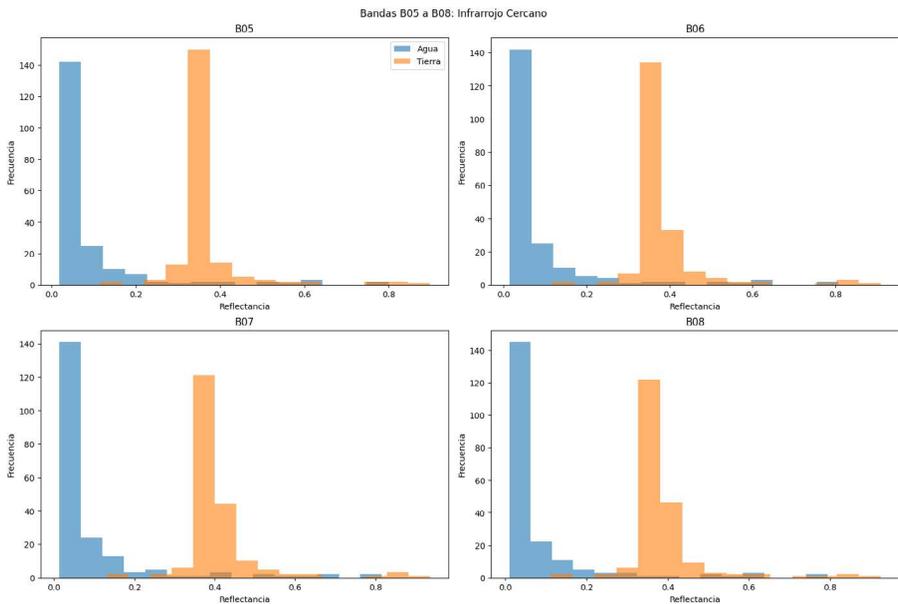


- Bandas B05 a B08: Infrarrojo Cercano
  - B05: La reflectancia del agua sigue siendo baja, mientras que la de la tierra es más alta.
  - B06: Se mantiene la tendencia de mayor reflectancia en superficies de tierra.
  - B07: La tierra presenta una mayor variabilidad en los valores de reflectancia.
  - B08: La discriminación entre agua y tierra es clara, con reflectancias significativamente diferentes.

La Figura 3 muestra la distribución de reflectancia en el infrarrojo cercano, con diferencias marcadas entre agua y tierra:

**Figura 3**

*Distribución de Reflectancia en el Infrarrojo Cercano (B05 a B08).*



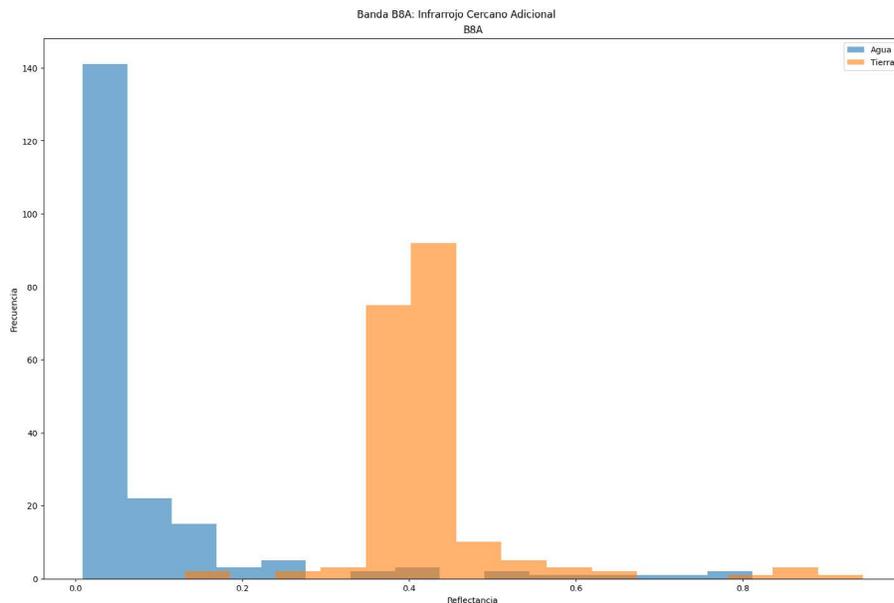
- Banda B8A: Infrarrojo Cercano Adicional
  - B8A: Los valores de reflectancia del agua son muy bajos en comparación con los de la tierra, lo que facilita su discriminación.

La Figura 4 evidencia una separación similar a las bandas anteriores del infrarrojo cercano, mostrando superficies de agua y tierra claramente diferenciadas en términos de reflectancia. Esta clara distinción en los patrones de reflectancia no solo confirma la utilidad de la banda B8A para la clasificación precisa de cuerpos de agua y suelos, sino que también refuerza su potencial como insumo crítico en modelos de predicción más sofisticados. La capacidad de esta banda para diferenciar superficies en imágenes satelitales resulta crucial en el monitoreo de recursos hídricos, facilitando la detección temprana de variaciones en cuerpos de agua y optimizando la gestión de ecosistemas. Asimismo, esta discriminación es

especialmente relevante en sistemas de agricultura de precisión, donde la identificación precisa de superficies es fundamental para una toma de decisiones informada y oportuna en la gestión de cultivos.

#### Figura 4

Distribución de Reflectancia en el Infrarrojo Cercano Adicional (B8A).



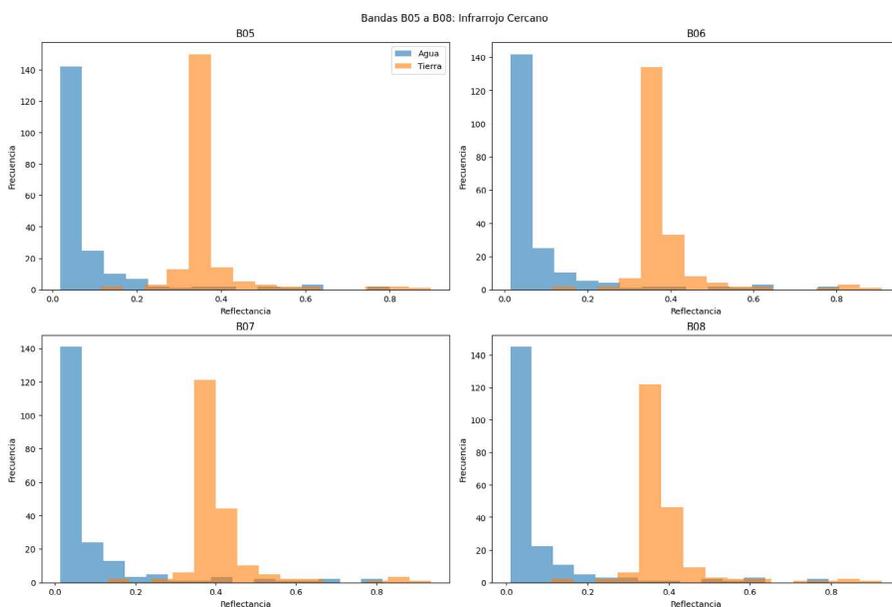
- Bandas B09 a B12: Infrarrojo de Onda Corta
  - B09: Las superficies de agua tienen valores de reflectancia muy bajos, mientras que las de tierra son más variadas.
  - B10: La reflectancia del agua sigue siendo baja, con la tierra mostrando una mayor variabilidad.
  - B11: La tierra presenta una reflectancia mucho más alta en comparación con el agua.
  - B12: La discriminación entre agua y tierra es muy marcada, con diferencias significativas en los valores de reflectancia.
- Las bandas del infrarrojo de onda corta (B09 a B12) complementan la discriminación entre agua y tierra observada en la banda B8A. En particular, la banda B09 muestra valores muy bajos para el agua, mientras que la tierra presenta mayor variabilidad. Conforme se avan-

za hacia B12, la separación entre ambos tipos de superficie se vuelve aún más evidente, consolidando la utilidad de estas bandas para la clasificación precisa del terreno y la gestión de recursos naturales.

La Figura 5 presenta la distribución de reflectancia en el infrarrojo de onda corta, destacando las diferencias entre agua y tierra:

**Figura 5**

*Distribución de Reflectancia en el Infrarrojo de Onda Corta (B09 a B12).*



## Comparación de clasificadores

La Tabla 1 resume la precisión promedio y la desviación estándar de los diferentes algoritmos de clasificación. Estos resultados se obtuvieron mediante validación cruzada, lo que permite evaluar la estabilidad y la capacidad de generalización de cada modelo.

**Tabla 1***Precisión promedio de validación cruzada de los clasificadores.*

<b>Clasificador</b>	<b>Precisión promedio <math>\pm</math> Desviación estándar</b>
Red Neuronal Convolutacional 1D (CNN 1D)	97.97 % $\pm$ 2.06 %
Red Neuronal Multicapa (MLP)	97.20 % $\pm$ 1.86 %
Long Short-Term Memory (LSTM)	97.20 % $\pm$ 1.23 %
Gradient Boosting Machines (GBM)	96.18 % $\pm$ 1.37 %
Random Forest	94.39 % $\pm$ 1.70 %

Red Neuronal Convolutacional 1D (CNN 1D): Este clasificador obtuvo la mayor precisión promedio (97.97 %) con una desviación estándar de 2.06 %. Su rendimiento superior se puede atribuir a su capacidad para capturar características espaciales complejas en los datos espectrales.

Red Neuronal Multicapa (MLP) y Long Short-Term Memory (LSTM): Ambos clasificadores mostraron un rendimiento similar, con precisiones promedio de 97.20 % y desviaciones estándar de 1.86 % y 1.23 %, respectivamente. La MLP es eficiente en la clasificación de datos multidimensionales, mientras que el LSTM es particularmente útil para secuencias de datos temporales.

Gradient Boosting Machines (GBM): Este modelo alcanzó una precisión promedio de 96.18 % con una desviación estándar de 1.37 %. GBM es conocido por su capacidad de mejorar el rendimiento mediante la combinación de múltiples árboles de decisión débiles.

Random Forest: Aunque este clasificador tuvo la menor precisión promedio (94.39 %), su desviación estándar de 1.70 % indica una estabilidad razonable. Random Forest es efectivo para evitar el sobreajuste y manejar conjuntos de datos con muchas características.

## **Evaluación del modelo principal**

En esta sección se presentan los resultados detallados del mejor clasificador, identificado como la Red Neuronal Convolutacional 1D (CNN 1D). Se incluyen métricas de evaluación como precisión, recall y F1-score, así como una matriz de confusión que visualiza la distribución de las

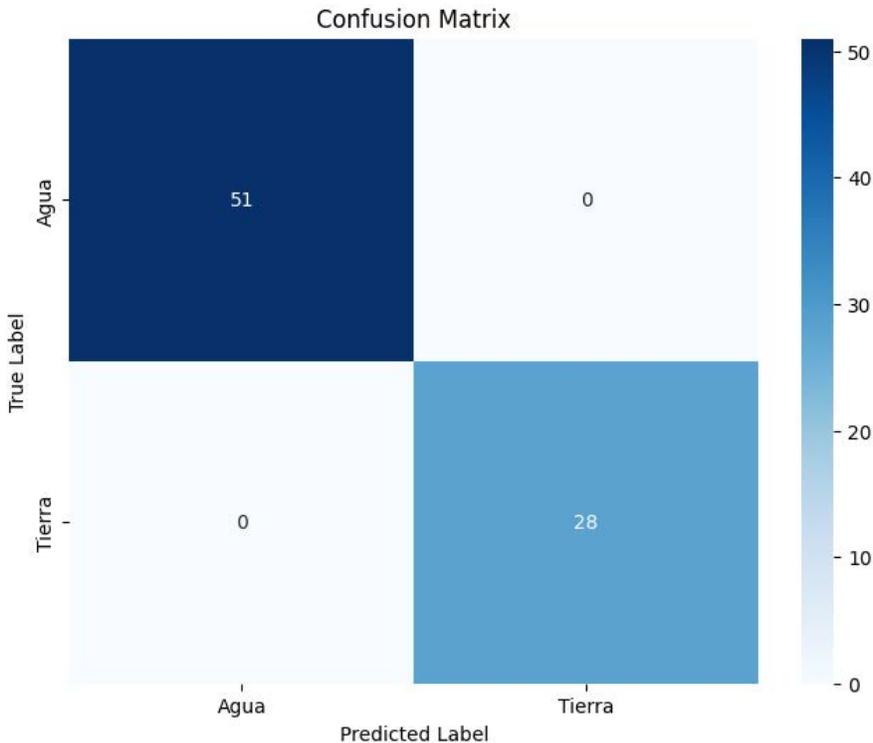
clasificaciones correctas e incorrectas del modelo. Este análisis permite comprender la efectividad del clasificador y su capacidad para distinguir entre superficies de agua y tierra.

- Matriz de confusión

La matriz de confusión presentada en la Figura 6 muestra la distribución de las clasificaciones realizadas por el modelo CNN 1D. En esta matriz, los valores en la diagonal principal representan las clasificaciones correctas, mientras que los valores fuera de la diagonal indican clasificaciones incorrectas.

**Figura 6**

*Matriz de Confusión del Modelo CNN 1D.*



La matriz de confusión muestra que el modelo CNN 1D clasificó correctamente todas las muestras de agua y tierra, con 51 muestras de agua y 28 muestras de tierra clasificadas correctamente. No hubo clasificaciones incorrectas, lo que indica un rendimiento perfecto en este conjunto de prueba.

## Discusión

Los resultados obtenidos en este estudio demuestran la eficacia de la Red Neuronal Convolutiva 1D (CNN 1D) para la clasificación de superficies terrestres y acuáticas utilizando datos espectrales de Sentinel-2. La precisión, recall y F1-score del 100 % en el conjunto de prueba indican que el modelo es altamente preciso y no presenta errores de clasificación. Este rendimiento sobresaliente puede atribuirse a varias razones que se discuten a continuación.

La precisión y efectividad del modelo CNN 1D en este estudio superan las métricas reportadas en estudios previos que utilizan otros enfoques de clasificación para datos de teledetección. Por ejemplo, investigaciones que emplearon técnicas como Support Vector Machines (SVM) y Random Forests reportaron precisiones que oscilaban entre el 85 % y el 95 % (Hao et al., 2024). La capacidad del CNN 1D para capturar características espaciales complejas.

## Conclusiones

El presente estudio ha demostrado la eficacia de la Red Neuronal Convolutiva 1D (CNN 1D) para la clasificación precisa de superficies terrestres y acuáticas utilizando datos espectrales de Sentinel-2. Los resultados obtenidos destacan varias conclusiones importantes:

**Alto rendimiento del modelo CNN 1D:** El modelo CNN 1D mostró una precisión, recall y F1-score del 100 % en el conjunto de prueba, superando significativamente otros métodos tradicionales de clasificación utilizados en estudios previos, como Support Vector Machines (SVM) y Random Forests, los cuales reportaron precisiones entre el 85 % y el 95 % (Hao et al., 2024), (Zhang et al., 2019).

**Capacidad para capturar características espaciales complejas:** La capacidad del CNN 1D para manejar grandes volúmenes de datos espectrales multibanda y capturar características espaciales complejas fue fundamental para su éxito. Este enfoque permitió una discriminación precisa entre superficies de agua y tierra, lo cual es crucial para aplicaciones prácticas como la gestión de recursos naturales y la agricultura de precisión.

Implicaciones prácticas significativas: La alta precisión del modelo CNN 1D tiene importantes implicaciones prácticas. En la agricultura de precisión, por ejemplo, la capacidad de diferenciar entre superficies de agua y tierra con alta exactitud puede mejorar significativamente las prácticas de riego y la gestión de cultivos. Además, en la gestión de recursos hídricos, una clasificación confiable de las superficies es crucial para monitorear y gestionar eficientemente los recursos disponibles.

Limitaciones y necesidades de recursos computacionales: Aunque el modelo CNN 1D mostró un rendimiento excelente, es importante reconocer sus limitaciones. El entrenamiento y ajuste de hiperparámetros requieren considerables recursos computacionales, lo cual puede limitar su aplicabilidad en entornos con restricciones de hardware. Además, la evaluación se realizó en un conjunto de datos relativamente pequeño y específico, lo que requiere una evaluación adicional para garantizar la generalización del modelo a otras regiones y condiciones ambientales.

Futuras direcciones de investigación: Para mejorar la robustez y la capacidad de generalización del modelo CNN 1D, futuras investigaciones deberían centrarse en expandir el conjunto de datos de prueba para incluir diversas regiones y condiciones ambientales. La integración de datos adicionales, como información topográfica y meteorológica, podría mejorar aún más la precisión del modelo. Además, la combinación de CNN 1D con otros enfoques de aprendizaje profundo, como redes neuronales recurrentes (RNN) o modelos híbridos, puede capturar tanto las características espaciales como las temporales de los datos espectrales. La implementación de técnicas de aprendizaje federado también representa una prometedora dirección para entrenar modelos colaborativos preservando la privacidad de los datos.

## Referencias

Caballero Chávez, C., & Duarte, V. (2023). Análisis de la variación de la Temperatura de la Superficie Terrestre (TST) y del Índice Diferencial de Vegetación Normalizado (IVN) en el área metropolitana de Asunción. *Revista de la Sociedad Científica del Paraguay*, 28(2), 352-369. <https://doi.org/10.32480/rscp.2023.28.2.352>

- Danuri, D., & Mohd Pozi, M. (2024). Machine Learning Approaches for Fish Pond Water Quality Classification: Random Forest, Gaussian Naive Bayes, and Decision Tree Comparison. Proceedings of the 11th International Applied Business and Engineering Conference, ABEC 2023, September 21st, 2023, Bengkalis, Riau, Indonesia. Proceedings of the 11th International Applied Business and Engineering Conference, ABEC 2023, September 21st, 2023, Bengkalis, Riau, Indonesia, Bengkalis, Indonesia. <https://doi.org/10.4108/eai.21-9-2023.2342964>
- Duan, J., Wang, H., Wang, C., Nie, S., Yang, X., & Xi, X. (2023). Denoising and classification of urban ICESat-2 photon data fused with Sentinel-2 spectral images. *International Journal of Digital Earth*, 16(2), 4346-4367. <https://doi.org/10.1080/17538947.2023.2270513>
- Eisfelder, C., Boemke, B., Gessner, U., Sogno, P., Alemu, G., Hailu, R., Mesmer, C., & Huth, J. (2024). Cropland and Crop Type Classification with Sentinel-1 and Sentinel-2 Time Series Using Google Earth Engine for Agricultural Monitoring in Ethiopia. *Remote Sensing*, 16(5), 866. <https://doi.org/10.3390/rs16050866>
- Gomez, C., Dharumarajan, S., Féret, J.-B., Lagacherie, P., Ruiz, L., & Sekhar, M. (2019). Use of Sentinel-2 Time-Series Images for Classification and Uncertainty Analysis of Inherent Biophysical Property: Case of Soil Texture Mapping. *Remote Sensing*, 11(5), 565. <https://doi.org/10.3390/rs11050565>
- Hao, M., Dong, X., Jiang, D., Yu, X., Ding, F., & Zhuo, J. (2024). Land-use classification based on high-resolution remote sensing imagery and deep learning models. *PLOS ONE*, 19(4), e0300473. <https://doi.org/10.1371/journal.pone.0300473>
- Huang, C., Zhang, C., He, Y., Liu, Q., Li, H., Su, F., Liu, G., & Bridhikitti, A. (2020). Land Cover Mapping in Cloud-Prone Tropical Areas Using Sentinel-2 Data: Integrating Spectral Features with Ndvi Temporal Dynamics. *Remote Sensing*, 12(7), 1163. <https://doi.org/10.3390/rs12071163>
- López-Calderón, M. J., Estrada-Ávalos, J., Martínez-Sifuentes, A. R., Trucíos-Caciano, R., & Miguel-Valle, E. (2023). Nitrógeno total en maíz forrajero (*Zea mays* L.) estimado mediante índices espectrales con el satélite Sentinel-2. *Revista Terra Latinoamericana*, 41. <https://doi.org/10.28940/terra.v41i0.1628>

- Orynbaikyzy, A., Gessner, U., Mack, B., & Conrad, C. (2020). Crop Type Classification Using Fusion of Sentinel-1 and Sentinel-2 Data: Assessing the Impact of Feature Selection, Optical Data Availability, and Parcel Sizes on the Accuracies. *Remote Sensing*, 12(17), 2779. <https://doi.org/10.3390/rs12172779>
- Phiri, D., Simwanda, M., Salekin, S., Nyirenda, V., Murayama, Y., & Ranagalage, M. (2020). Sentinel-2 Data for Land Cover/Use Mapping: A Review. *Remote Sensing*, 12(14), 2291. <https://doi.org/10.3390/rs12142291>
- Riego y Drenaje, Facultad de Agronomía de Buenos Aires, Buenos Aires, Argentina, Salgado, H., Zabala, S. M., Romay, C., Bernier, M., Jacome, A., Chokmani, K., Meteorología, Servicio de Hidrografía Naval, Ministerio de Defensa, Argentina, & Institut National de la Recherche Scientifique, Université du Québec, Québec, Canada. (2021). Estimación de la humedad superficial del suelo mediante datos SAR en banda X. *Meteorologica*, 46(1), e001-e001. <https://doi.org/10.24215/1850468Xe001>
- Syrris, V., Hasenohr, P., Delipetrev, B., Kotsev, A., Kempeneers, P., & Soille, P. (2019). Evaluation of the Potential of Convolutional Neural Networks and Random Forests for Multi-Class Segmentation of Sentinel-2 Imagery. *Remote Sensing*, 11(8), 907. <https://doi.org/10.3390/rs11080907>
- Yousefi, S., Mirzaee, S., Almohamad, H., Al Dughairi, A. A., Gomez, C., Siamian, N., Alrasheedi, M., & Abdo, H. G. (2022). Image Classification and Land Cover Mapping Using Sentinel-2 Imagery: Optimization of SVM Parameters. *Land*, 11(7), 993. <https://doi.org/10.3390/land11070993>
- Zhang, W., Tang, P., & Zhao, L. (2019). Remote Sensing Image Scene Classification Using CNN-CapsNet. *Remote Sensing*, 11(5), 494. <https://doi.org/10.3390/rs11050494>