

Clasificación de tipos de vegetación con Inteligencia Artificial en datos satelitales en El Salvador

Classification of Vegetation Types Using Artificial Intelligence in Satellite Data in El Salvador

DOI: <https://doi.org/10.51378/ilia.vi2.9653>

C. Archila¹, A. Cerón², H. Cortez³, M. Hernández⁴

¹Departamento de Electrónica e Informática, Universidad Centroamericana José Simeón Cañas, El Salvador.

E-mail: 00145594@uca.edu.sv¹, 00040116@uca.edu.sv², 00095119@uca.edu.sv³ y 00094119@uca.edu.sv⁴

Fecha de recepción: 14 de mayo 2025

Fecha de aprobación: 25 de agosto de 2025

Resumen

Este estudio implementa un proceso de clasificación de vegetación en El Salvador mediante técnicas de teledetección y algoritmos de aprendizaje automático. Se analizaron datos satelitales del municipio de Santa María, Usulután, utilizando redes neuronales convolucionales *U-Net* y el modelo de bosques aleatorios (Random Forest, por su origen en inglés). El objetivo es identificar y segmentar áreas de cultivo y zonas arbóreas a partir de imágenes satelitales de baja y alta resolución. Se procesaron datos multiespectrales y RGB, empleando un conjunto de entrenamiento basado en máscaras de verdad en tierra (“ground truth”) para evaluar la efectividad de cada modelo.

Los resultados muestran que ambos modelos son capaces de clasificar la vegetación con un alto grado de precisión. El modelo *U-Net* obtiene valores más altos de exactitud en las predicciones, mientras que Random Forest ofrece una mejor interpretabilidad de resultados con menor complejidad computacional. Se concluye que una combinación de ambos enfoques podría mejorar la segmentación y detección de vegetación en futuros estudios.

Palabras clave – Teledetección, aprendizaje automático, clasificación de vegetación, imágenes satelitales, *U-Net*, Random Forest.

Abstract

This study implements a vegetation classification process in El Salvador using remote sensing techniques and machine learning algorithms. Satellite data from Santa María, Usulután, were analyzed

using convolutional neural networks (*U-Net*) and the Random Forest model. The objective is to identify and segment agricultural fields and tree-covered areas using low and high-resolution satellite images. Multispectral and RGB data were processed, employing a ground truth-based training set to evaluate each model's effectiveness.

Results show that both models can classify vegetation with high accuracy. The *U-Net* model achieves higher precision in predictions, while Random Forest offers better interpretability with lower computational complexity. It is concluded that a combination of both approaches could enhance vegetation segmentation and detection in future studies.

Keyword – Remote sensing, machine learning, vegetation classification, satellite images, *U-Net*, Random Forest.

I. INTRODUCCIÓN

El monitoreo de la vegetación y el uso del suelo es una tarea fundamental para la gestión ambiental y la planificación territorial. En países como El Salvador, donde los cambios en la cobertura forestal y agrícola pueden impactar significativamente la economía y el medio ambiente, es crucial disponer de métodos eficientes para la identificación y clasificación de las áreas de cultivo y zonas arbóreas.

Para el contexto salvadoreño, contar con metodologías precisas y reproducibles que clasifiquen vegetación es una herramienta estratégica para la gestión territorial y planificación de políticas ambientales. Por esto, se implementaron métodos de teledetección



Publicamos bajo la Licencia de Creative Commons Atribución-NoComercial 4.0 Internacional (CC BY-NC-ND 4.0)

tección y aprendizaje automático para evaluar su desempeño en esta coyuntura.

Los métodos tradicionales de monitoreo requieren inspecciones manuales y toma de datos en campo, lo que resulta en procesos costosos y propensos a errores humanos. En contraste, las técnicas de teledetección y el uso de algoritmos de inteligencia artificial han demostrado ser herramientas efectivas para el análisis automatizado de imágenes satelitales, reduciendo la necesidad de intervención manual y mejorando la precisión de las clasificaciones.

Este estudio se enfoca en la aplicación de dos algoritmos de aprendizaje automático supervisado: redes neuronales convolucionales (*U-Net*) y bosques aleatorios (Random Forest), para la segmentación y clasificación de áreas vegetadas en imágenes satelitales de baja y alta resolución. La investigación se centra en el municipio de Santa María, Usulután, utilizando imágenes satelitales de la misión Sentinel-2 para ambos tipos de resoluciones trabajadas así como archivos vectoriales como referencia para evaluar la efectividad de los modelos propuestos.

El objetivo principal es desarrollar un proceso automatizado para la detección de áreas de interés mediante la combinación de técnicas de procesamiento de imágenes y aprendizaje automático. Se evalúa el desempeño de cada modelo en función de métricas de precisión, *recall* y *F1-score*, con el fin de determinar cuál ofrece mejores resultados para la clasificación de vegetación en el contexto salvadoreño.

La presente investigación busca contribuir al desarrollo de herramientas innovadoras para la gestión y monitoreo del territorio en El Salvador, facilitando la toma de decisiones basadas en información geoespacial precisa y actualizada.

II. METODOLOGÍA

La metodología utilizada en este estudio se basa en la aplicación de técnicas de teledetección combinadas con algoritmos de aprendizaje automático para la clasificación de vegetación en imágenes satelitales [1],[2]. A continuación, se describen las etapas principales del proceso.

A. Adquisición y preprocesamiento de datos

Para el desarrollo del estudio, se emplearon imágenes satelitales provenientes del satélite Sentinel-2, las cuales contienen información multiespectral con trece bandas en baja resolución (10 m por

píxel) y datos en alta resolución en formato RGB (50 cm por píxel) [3]. Como referencia, se utilizaron archivos vectoriales (o ground truth) con la delimitación de áreas de cultivo y zonas arbóreas.

El preprocesamiento de los datos incluyó [4],[5]:

- Corrección geométrica y radiométrica de las imágenes.
- Alineación de las diferentes bandas espectrales.
- Normalización de los valores de reflectancia.
- Conversión de los datos en matrices de entrada adecuadas para los modelos de aprendizaje automático. para los modelos de aprendizaje automático.

B. Algoritmos de aprendizaje automático

Utilizando las funciones de vulnerabilidad descritas previamente se determinó el índice de daño probable para tres escenarios de sismos: Intensidad VI, VII y VIII del sistema MSK. En las Figuras 21 a 23 se muestran los mapas de daños obtenidos para las diferentes tipologías considerando los escenarios de daño mencionados de Intensidad VI, VII y VIII (MSK) respectivamente.

Se implementaron y compararon dos modelos de clasificación:

Redes Neuronales Convolucionales (*U-Net*): modelo basado en una arquitectura de codificación-decodificación con convoluciones que permiten segmentar regiones de interés en imágenes satelitales. Se entrenó utilizando un conjunto de datos de entrenamiento y validación, dividiendo las imágenes en parches de 128x128 píxeles [6].

Bosques Aleatorios (Random Forest): algoritmo basado en árboles de decisión que permite clasificar píxeles en función de su reflectancia en distintas bandas espectrales. Se utilizó un conjunto de entrenamiento balanceado para minimizar sesgos y mejorar la generalización del modelo [7],[8].

C. Evaluación de modelos

Para determinar el desempeño de los modelos, se emplearon métricas estándar en clasificación de imágenes, tales como [9],[10]:

- Precisión (*Precision*): proporción de predicciones correctas entre todas las instancias clasificadas como positivas.

- Exhaustividad (*Recall*): capacidad del modelo para identificar correctamente todas las áreas de vegetación.
- F1-score*: medida combinada de precisión y *recall* [11].
- Promedio Ponderado (*Weighted Average*): representación del rendimiento generado por el modelo cuando el peso de cada clase está determinado por la cantidad de muestras de la misma [12].

Adicionalmente, se realizaron comparaciones visuales entre los mapas de predicción y las referencias de ground truth para evaluar la coherencia espacial de los resultados [13].

D. Implementación y pruebas

El desarrollo y entrenamiento de los modelos se llevó a cabo en una máquina virtual con 64 GB de RAM y 8 núcleos de procesamiento, utilizando Python y librerías especializadas como TensorFlow, Scikit-Learn, Rasterio y GeoPandas [14],[15]. Se crearon múltiples iteraciones de prueba para ajustar hiperparámetros y mejorar la precisión de las predicciones.

Con esta metodología, se espera obtener un sistema eficiente y automatizado para la clasificación de vegetación en imágenes satelitales, facilitando su aplicación en estudios de monitoreo ambiental y planificación territorial [16]

III. RESULTADOS

Los resultados constan de la comparación de los diferentes modelos descritos anteriormente para la clasificación arbórea y agrícola. De las 8 predicciones generadas, 4 pertenecen al modelo de *U-Net*, y 4 al modelo de *random forest*, para ambos modelos se hicieron entrenamientos separados para las imágenes de alta y baja resolución, de igual modo haciendo la separación para zonas agrícolas o zonas arbóreas, para este artículo científico, se tomaron como muestra 2 de los 8 modelos disponibles, los cuales son: “Modelo *U-Net - Arboledas - Low definition*” y “Modelo *Random Forest - Arboledas - Low definition*”.

E. Evaluación de los modelos

Modelo *U-Net - Arboledas - Low definition*

Los resultados obtenidos para el modelo *U-Net-Low-Arboledas* fueron:

Tabla 1. Comparación de desempeño de Modelos: modelo *U-Net - Arboledas - Low definition*.

Results threshold 0.5	Class	Precision	Recall	F1-Score	Support
UNET-Low-Arboledas	0 (Rechazado)	0.76	0.87	0.81	1,575,420
	1 (Aceptado)	0.58	0.39	0.46	718,34
	Accuracy			0.72	2,293,760
	Macro Avg	0.67	0.63	0.64	2,293,760
	Weighted Avg	0.70	0.72	0.70	2,293,760

Las imágenes resultantes del modelo fueron las siguientes:

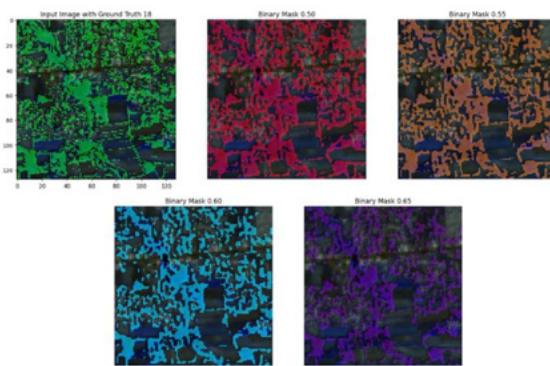


Fig. 1. Resultados Arboledas - U-Net - Low Definition

El modelo *U-Net* identifica con mayor claridad áreas arbóreas densas, reduciendo la confusión con zonas agrícolas dispersas. Mostrando alta coherencia con el *ground truth*, lo que respalda la validez del método en el caso local.

Modelo *RF- Arboledas - Low definition*

Los resultados obtenidos para el Modelo *RF-Arboledas - Low definition* fueron:

Tabla 2. Comparación de desempeño de Modelos: modelo *U-Net - Arboledas- Low definition*.

Results threshold 0.5	Class	Precision	Recall	F1-Score	Support
RF-Low-Arboledas	0 (Rechazado)	0.72	0.88	0.79	1,575,420
	1 (Aceptado)	0.50	0.26	0.34	718,34
	Accuracy			0.69	2,293,760
	Macro Avg	0.61	0.57	0.57	2,293,760
	Weighted Avg	0.65	0.69	0.65	2,293,760

Las imágenes resultantes del modelo fueron las siguientes:

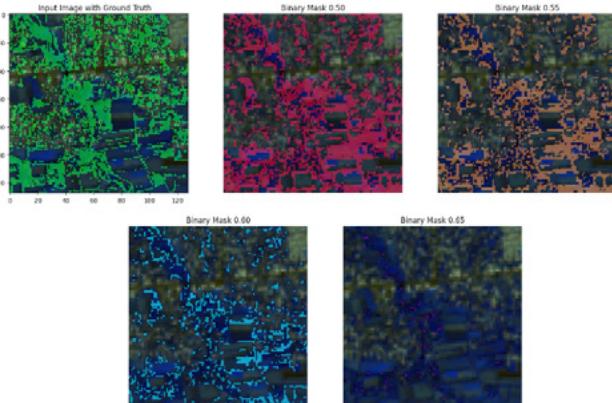


Fig. 2. Resultados Arboledas- *Random Forest - Low Definition*

El modelo *random forest* presenta mayor confusión en bordes y transiciones entre coberturas, afectando el *recall* positivo o áreas aceptadas. No obstante, su simplicidad computacional lo vuelve una alternativa viable para despliegues con recursos limitados.

F. Comparación entre los modelos

Para realizar la comparación entre modelos cuando se trata de la misma clasificación (arbórea o agrícola) y resolución, se binariza el resultado del modelo *U-Net* a través de *thresholds* con valores de 0.5, 0.55, 0.6 y 0.65. Estos fueron los resultados que se contrastaron con el resultado generado por el modelo de *random forest*.

Entre todas las comparaciones realizadas, se mantuvo la tendencia que en el modelo de *U-Net*, a medida se restringía más el *threshold*, los resultados de sus métricas de evaluación iban decreciendo.

De igual manera se observó que bajo simple análisis visual, el modelo de *U-Net* presentaba resultados más idóneos, para el caso de los modelos de Arboledas.

Sin embargo, los resultados de las métricas mostraron que el modelo de *U-Net*, con el *threshold* de 0.5, presentaba mejores resultados consistentemente sobre los otros *thresholds* y sobre el modelo de *random forest*. Tomando como principal indicador el promedio ponderado, que abarca más datos y proporciona una visión más completa del conjunto de métricas con las que se evaluó la aceptación.

G. Comparación entre los modelos

A continuación, se presentan las abreviaciones y acrónimos utilizados en este documento junto con su definición:

- RGB - Red, Green, Blue (Rojo, Verde, Azul).
- *U-Net* - Red Neuronal Convolucional para Segmentación de Imágenes.
- *Random Forest (RF)* - Algoritmo de clasificación basado en múltiples árboles de decisión.
- MKS - Metro, Kilogramo, Segundo (Sistema Internacional de Unidades).
- CGS - Centímetro, Gramo, Segundo (Sistema de Unidades).
- Sentinel-2 - Satélite de observación terrestre de la Agencia Espacial Europea (ESA).
- TensorFlow - Biblioteca de código abierto para aprendizaje automático.
- Scikit-Learn - Biblioteca de aprendizaje automático en Python.
- Rasterio - Biblioteca para manipulación de datos rasterizados.
- GeoPandas - Extensión de Pandas para el manejo de datos espaciales en Python.
- Ground Truth - Datos de referencia obtenidos mediante observación directa.

H. Evaluación de métricas de desempeño

En esta sección se presentan las ecuaciones utilizadas para evaluar el desempeño de los modelos de clasificación, asegurando la precisión y exhaustividad de los resultados obtenidos.

- Precisión (*Precision*)

La precisión mide la proporción de predicciones positivas correctas sobre el total de predicciones positivas realizadas por el modelo. Se define como:

$$\text{Precision} = \frac{TP}{TP + FP} \quad (1)$$

Donde representa los verdaderos positivos (instancias correctamente clasificadas como positivas) y los falsos positivos (instancias incorrectamente clasificadas como positivas). Una alta precisión indica que la mayoría de los ejemplos clasificados como positivos realmente lo son.

- *Recall* (Sensibilidad o Exhaustividad)

El *recall* mide la capacidad del modelo para identificar todas las instancias positivas reales en el conjunto de datos. Se calcula como:

$$\text{Recall} = \frac{TP}{TP + FN} \quad (2)$$

Donde TP representa los falsos negativos, es decir, las instancias positivas que el modelo no detectó correctamente. Un alto *recall* indica que el modelo identifica la mayoría de los ejemplos positivos.

- *F1 Score*

El *F1 Score* es la media armónica entre precisión y *recall*, lo que proporciona una medida equilibrada entre ambas métricas. Se expresa como:

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (3)$$

Este valor es especialmente útil cuando existe un desbalance en las clases, ya que evita que el modelo optimice únicamente una de las métricas a costa de la otra.

- Exactitud (*Accuracy*)

La exactitud mide la cantidad de predicciones correctas sobre el total de instancias en el conjunto de datos y se define como:

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \quad (4)$$

Donde TP representa los verdaderos negativos, es decir, las instancias correctamente identificadas como negativas. Aunque la exactitud es una métrica general, puede ser engañosa cuando las clases están desbalanceadas.

- Macro Average

Calcula el promedio simple de precisión y *recall* sin considerar el tamaño de cada clase:

$$\text{Macro Avg} = \frac{F1_1 + F1_2}{2} \quad (5)$$

Donde $F1$ y $F2$ representan los valores de *F1 Score* de cada clase.

- Weighted Average

Calcula un promedio ponderado de precisión y *recall*, considerando el tamaño de cada clase:

$$\text{Weighted Avg} = \frac{F1_1 \times S_1 + F1_2 \times S_2}{S_1 + S_2} \quad (6)$$

Donde y representan la cantidad de ejemplos en cada clase. Esta métrica es útil cuando una clase tiene significativamente más ejemplos que otra.

- Support

El *support* indica cuántos ejemplos pertenecen a cada clase en el conjunto de datos de prueba. Un soporte mayor implica que hay más instancias disponibles para evaluar el desempeño del modelo en esa categoría.

Las métricas presentadas permiten una evaluación integral del rendimiento del modelo, asegurando que las predicciones sean precisas y generalizables a diferentes conjuntos de datos.

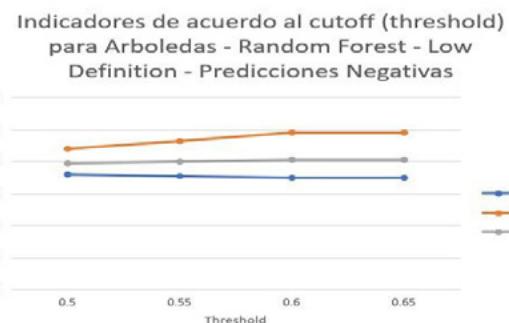


Fig. 3. Indicadores de acuerdo al *threshold* para Arboledas - RF - Low Definition - Predicciones Negativas

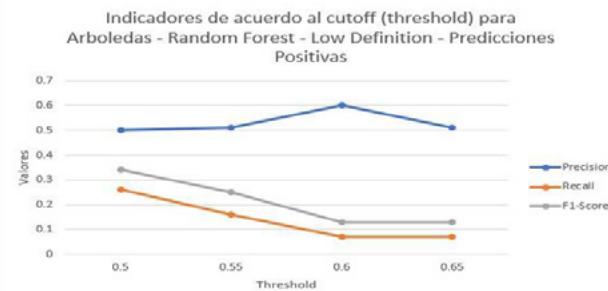


Fig. 4. Indicadores de acuerdo al *threshold* para Arboledas - Random Forest - Low Definition - Predicciones Positivas

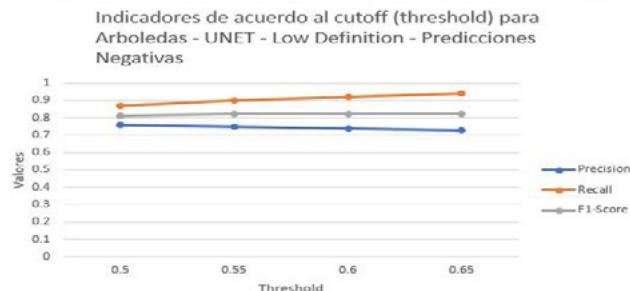


Fig. 5. Indicadores de acuerdo al *threshold* para Arboledas - U-Net - Low Definition - Predicciones Negativas

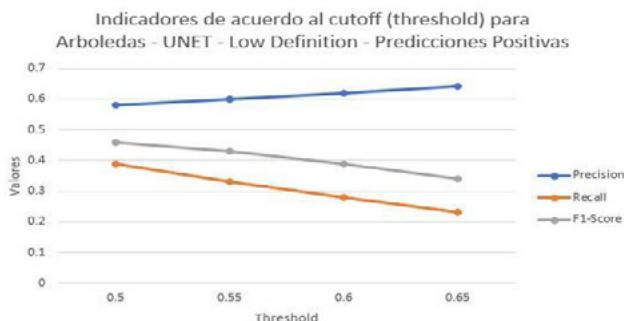


Fig. 6. Indicadores de acuerdo al *threshold* para Arboledas - *U-Net* - *Low Definition* - Predicciones Positivas

V. DISCUSIÓN

El análisis de los resultados evidencia que el modelo *U-Net-Low-Arboledas* presenta un desempeño superior en comparación con *RF-Low-Arboledas*, logrando una mayor precisión y *recall*, especialmente en la detección de áreas arbóreas rechazadas (clase 0). Esto sugiere que la red neuronal convolucional *U-Net* es más efectiva para capturar patrones espaciales complejos en imágenes satelitales.

Por otro lado, el modelo *RF-Low-Arboledas*, basado en árboles de decisión, obtiene una precisión moderada en la clase 0 (0.72) pero muestra un desempeño más bajo en la clase 1, con un *recall* de 0.26 y un *F1-score* de 0.34, lo que indica una mayor dificultad para identificar correctamente las áreas aceptadas como vegetación.

Para el caso de estudio, los resultados permiten identificar patrones de distribución de áreas arbóreas coincidentes con zonas reportadas en inventarios forestales locales. Esto indica que *U-Net*, por su mayor precisión, puede emplearse en programas y estudios de monitoreo de cobertura vegetal en El Salvador.

El desempeño superior de *U-Net* puede atribuirse a su capacidad para analizar relaciones espaciales dentro de las imágenes, mientras que *Random Forest*, al ser un modelo basado en características individuales de los píxeles, carece de la misma capacidad de contextualización. Sin embargo, RF tiene la ventaja de ser un modelo menos costoso en términos computacionales y más interpretable en comparación con *U-Net*.

VI. CONCLUSIONES

U-Net mostró un rendimiento superior en la clasificación de zonas arbóreas, con métricas de *F1-score* y exactitud superiores a las del modelo *Ran-*

dom Forest. Resaltando su potencia para la utilización en programas de monitoreo de cobertura vegetal a nivel nacional.

Por otro lado, *Random Forest*, resulta más ideal en entornos con recursos computacionales limitados, siendo una alternativa válida. Recalcando que la selección debe de considerar el balance entre precisión, costos computacionales y objetivos del proyecto.

Los resultados obtenidos indican que el modelo *U-Net-Low-Arboledas* es más eficiente en la segmentación de áreas arbóreas en imágenes satelitales, logrando valores superiores en *F1-score* y *accuracy* en comparación con *RF-Low-Arboledas*. La capacidad de *U-Net* para extraer patrones espaciales le permite un mejor desempeño en la clasificación de vegetación.

Sin embargo, *Random Forest* sigue siendo una opción válida en escenarios donde se requiere menor demanda computacional y una mayor interpretabilidad de los resultados. Su bajo desempeño en la clase 1 sugiere la necesidad de mejorar su capacidad de generalización mediante técnicas de optimización de hiper parámetros o el uso de enfoques híbridos.

En conclusión, la selección del modelo adecuado dependerá del contexto y de la disponibilidad de datos de entrada, priorizando métodos que optimicen el balance entre precisión y exhaustividad.

VII. AGRADECIMIENTOS

Los autores agradecen a su institución académica y a sus profesores por la orientación y apoyo durante la realización de esta investigación. También expresan su gratitud a sus familias y compañeros por su constante respaldo y motivación. Finalmente, se reconoce la colaboración de la Universidad “José Simeón Cañas” y Geokapti, que facilitaron el acceso a los datos y recursos tecnológicos empleados en este estudio.

VIII. REFERENCIAS

- [1] S. Theodoridis and K. Koutroumbas, *Pattern Recognition*, 4th ed. Academic Press, 2009.
- [2] J. Han, M. Kamber, and J. Pei, *Data Mining: Concepts and Techniques*, 3rd ed. Morgan Kaufmann, 2011.
- [3] T. Lillesand, R. W. Kiefer, and J. Chipman, *Remote Sensing and Image Interpretation*, 7th ed. John Wiley & Sons, 2015.

- [4] Z. Zhu, S. Wang, and C. E. Woodcock, "Improvement and expansion of the Landsat Global Land Survey," *Remote Sensing of Environment*, vol. 238, p. 111123, 2019.
- [5] M. Belgiu and L. Drăguț, "Random forest in remote sensing: A review of applications and future directions," *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 114, pp. 24–31, 2016.
- [6] L. Ma et al., "Deep learning in remote sensing applications: A meta-analysis and review," *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 152, pp. 166–177, 2019.
- [7] P. Ghamisi, J. A. Benediktsson, and X. Zhu, "A review of machine learning approaches for hyperspectral image analysis," *IEEE Geoscience and Remote Sensing Magazine*, vol. 4, no. 2, pp. 99–119, 2016.
- [8] K. G. Liakos, P. Busato, D. Moshou, S. Pearson, and D. Bochtis, "Machine learning in agriculture: A review," *Sensors*, vol. 18, no. 8, p. 2674, 2018.
- [9] C. D. Manning, P. Raghavan, and H. Schütze, *Introduction to Information Retrieval*, Cambridge University Press, 2008.
- [10] Y. LeCun, Y. Bengio, and G. Hinton, "Deep learning," *Nature*, vol. 521, no. 7553, pp. 436–444, 2015.
- [11] A. Kamilaris and F. X. Prenafeta-Boldú, "Deep learning in agriculture: A survey" *Computers and Electronics in Agriculture*, vol. 147, pp. 70–90, 2018.
- [12] F. Pedregosa et al., "Scikit-learn: Machine learning in Python," *Journal of Machine Learning Research*, vol. 12, pp. 2825–2830, 2011.
- [13] R. A. Schowengerdt, *Remote Sensing: Models and Methods for Image Processing*, 3rd ed. Academic Press, 2007.
- [14] M. Abadi et al., "TensorFlow: Large-scale machine learning on heterogeneous distributed systems," in *Proceedings of the 12th USENIX Conference on Operating Systems Design and Implementation (OSDI)*, 2016, pp. 265–283.
- [15] J. D. Hunter, "Matplotlib: A 2D graphics environment," *Computing in Science & Engineering*, vol. 9, no. 3, pp. 90–95, 2007.
- [16] J. Li, J. Lewis, and A. Singh, "Remote sensing with artificial intelligence: A review," *Remote Sensing Applications: Society and Environment*, vol. 19, p. 100350, 2020.

