

Freitas Souza, J.; Ferreira Lopes Machado, A.; Araújo Fonseca de Mendonça, B.; Peña Barragán, J. Clasificación basada en objetos de especies vegetales en áreas de restauración forestal usando imágenes multiespectrales adquiridas con UAV.

Clasificación basada en objetos de especies vegetales en áreas de restauración forestal usando imágenes multiespectrales adquiridas con UAV

Freitas Souza, Jhiorranni ¹ Ferreira Lopes Machado, Aroldo ² Araújo Fonseca de Mendonça, Bruno ² Peña Barragán, José Manuel ¹

¹ CSIC, España

² UFRRJ, Brasil

ORCID: Freitas Souza [0009-0001-6295-9415](https://orcid.org/0009-0001-6295-9415) Ferreira Lopes Machado [0000-0001-6506-9728](https://orcid.org/0000-0001-6506-9728) Araújo Fonseca de Mendonça [0000-0003-0288-0024](https://orcid.org/0000-0003-0288-0024) Peña Barragán [0000-0003-4592-3792](https://orcid.org/0000-0003-4592-3792)

Correspondencia: fjhiorranni@gmail.com aroldomachafo@yahoo.com.br brunoafmendonca@gmail.com
jmpena@ica.csic.es

RESUMEN

La clasificación de imágenes multiespectrales obtenidas por UAV mediante segmentación y análisis de imágenes basado en objetos (OBIA) representa un enfoque prometedor para la cartografía precisa de especies vegetales con el objetivo de diseñar estrategias de gestión más eficientes, selectivas y sostenibles. Este estudio se llevó a cabo en un área de restauración de la Mata Atlántica en la Reserva Ecológica de Guapiaçu (REGUA), en Cachoeiras de Macacu, en Río de Janeiro (RJ), Brasil. Las imágenes multiespectrales se capturaron en mayo de 2024 con un Mavic 3M, a 40 m de altitud, y se evaluaron cuatro clasificadores supervisados (BAYES, KNN, RF y SVM) a partir de la segmentación generada con el algoritmo multi-resolución del programa eCognition Developer. BAYES presentó exactitudes entre 74 % y 100 % con un error de desacuerdo de 0,1, mientras que SVM alcanzó exactitudes entre 74 % y 97 % con un error de desacuerdo de 0,12. KNN y RF mostraron exactitudes ligeramente menores, entre 67–100 % y 79–100 %, respectivamente, enfrentando también confusiones entre clases vegetativas espectralmente similares (FS, VP, CM y UH). En conjunto, BAYES y SVM demostraron ser los más adecuados para el mapeo y monitoreo de la vegetación en áreas de restauración forestal en las condiciones del presente estudio, mientras que KNN y RF constituyen alternativas útiles.



Palabras clave: *gestión agro-forestal; segmentación; modelos supervisados; OBIA.*

Fecha de recepción: 19 febrero 2026 · Fecha de aceptación: 19 febrero 2026


Clasificación basada en objetos de especies vegetales en áreas de restauración forestal usando imágenes multiespectrales adquiridas con UAV

Freitas Souza, Jhiorranni ⁽¹⁾, Ferreira Lopes Machado, Aroldo ⁽²⁾, Araújo Fonseca de Mendonça, Bruno ⁽²⁾, Peña, José Manuel ⁽¹⁾

⁽¹⁾ CSIC, España.

 0009-0001-6295-9415, fjhiorranni@gmail.com ;  0000-0003-4592-3792, jmpena@ica.csic.es

⁽²⁾ UFRRJ, Brasil.

 0000-0001-6506-9728, aroldomachafo@yahoo.com.br

 0000-0003-0288-0024, brunoafmendonca@gmail.com.

Resumen: La clasificación de imágenes multiespectrales obtenidas por UAV mediante segmentación y análisis de imágenes basado en objetos (OBIA) representa un enfoque prometedor para la cartografía precisa de especies vegetales con el objetivo de diseñar estrategias de gestión más eficientes, selectivas y sostenibles. Este estudio se llevó a cabo en un área de restauración de la Mata Atlántica en la Reserva Ecológica de Guapiaçu (REGUA), en Cachoeiras de Macacu, en Río de Janeiro (RJ), Brasil. Las imágenes multiespectrales se capturaron en mayo de 2024 con un Mavic 3M, a 40 m de altitud, y se evaluaron cuatro clasificadores supervisados (BAYES, KNN, RF y SVM) a partir de la segmentación generada con el algoritmo multi-resolución del programa eCognition Developer. BAYES presentó exactitudes entre 74 % y 100 % con un error de desacuerdo de 0,1, mientras que SVM alcanzó exactitudes entre 74 % y 97 % con un error de desacuerdo de 0,12. KNN y RF mostraron exactitudes ligeramente menores, entre 67–100 % y 79–100 %, respectivamente, enfrentando también confusiones entre clases vegetativas espectralmente similares (FS, VP, CM y UH). En conjunto, BAYES y SVM demostraron ser los más adecuados para el mapeo y monitoreo de la vegetación en áreas de restauración forestal en las condiciones del presente estudio, mientras que KNN y RF constituyen alternativas útiles.

Palabras clave: gestión agro-forestal; segmentación; modelos supervisados; OBIA.

Object-based classification of plant species in forest restoration areas using multispectral imagery captured by UAV

Abstract: The classification of multispectral images acquired by UAVs using object-based image analysis (OBIA) represents a promising approach for the accurate mapping of plant species, with the aim of designing more efficient, selective, and sustainable management strategies. This study was conducted in an Atlantic Forest restoration area within the Guapiaçu Ecological Reserve (REGUA) in Cachoeiras de Macacu, Rio de Janeiro (RJ), Brazil. The multispectral images were captured in May 2024 using a Mavic 3M at an altitude of 40 m, and four supervised classifiers (BAYES, KNN, RF, and SVM) were evaluated from the segmentation generated using the multi-resolution algorithm of the eCognition Developer software. BAYES achieved accuracies ranging from 74% to 100% with a misclassification error of 0.1, while SVM achieved accuracies ranging from 74% to 97% with a misclassification error of 0.12. KNN and RF showed slightly lower accuracies, ranging from 67–100% and 79–100%, respectively, and also faced confusion between spectrally similar vegetation classes (FS, VP, CM, and UH). Overall, BAYES and SVM proved to be the most suitable for vegetation mapping and monitoring in forest restoration areas under the conditions of the present study, while KNN and RF constitute useful alternatives.

Keywords: agroforestry management; segmentation; supervised models; OBIA.

1. INTRODUCCIÓN

El manejo de las malas hierbas constituye un desafío recurrente en las áreas de restauración ecológica y los sistemas forestales, debido a la elevada capacidad competitiva de estas especies y a su distribución

espacial heterogénea. Los métodos tradicionales de monitoreo basados en levantamientos de campo suelen ser costosos y limitan la rapidez en la toma de decisiones.

En este contexto, la detección remota se ha destacado como una herramienta estratégica para el mapeo de la vegetación y el desarrollo de estrategias de manejo localizado, lo que permite una mayor eficiencia y precisión en las intervenciones. La teledetección mediante sensores multispectrales en drones permite obtener imágenes de alta resolución que facilitan la identificación de especies nativas y malas hierbas.

Paralelamente, los enfoques de segmentación orientada a objetos asociados a algoritmos de aprendizaje automático han demostrado un alto rendimiento en la clasificación de imágenes de alta resolución. Métodos basados en el aprendizaje profundo se han aplicado ampliamente en la identificación y el mapeo de malas hierbas, lo que permite comparar el rendimiento de diferentes algoritmos y aumentar la solidez de la clasificación (Mesías-Ruiz *et al.*, 2025).

Por lo tanto, en este trabajo se propone la combinación de imágenes multispectrales obtenidas por drones y la aplicación de segmentación y modelos de clasificación supervisada mediante OBIA con el objetivo de cartografiar y diferenciar especies vegetales en áreas de restauración forestal para apoyar su manejo.

2. MATERIAL Y MÉTODOS

2.1. Área experimental

El experimento se llevó a cabo en la Reserva Ecológica de Guapiaçu (REGUA), situada en el municipio de Cachoeiras de Macacu, Río de Janeiro, Brasil, con coordenadas geográficas de referencia 22°25'S y 42°44'W (Fig. 1).

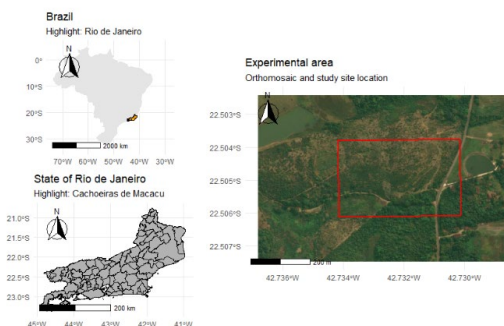


Figura 1. Área experimental en REGUA, en Cachoeiras de Macacu, Río de Janeiro, Brasil (Mayo 2024).

2.2. Adquisición y procesamiento de imágenes multispectrales mediante UAV

El 9 de mayo de 2024 se realizó un vuelo a 40 m de altitud y 80% de solape longitudinal y transversal utilizando el VANT Mavic 3M, con sensor multispectral formado por 4 canales que capturaron imágenes en las bandas verde, rojo, rojo-borde e infrarrojo cercano con una resolución espacial de 1,28 cm/p.

A continuación, se generaron los ortomosaicos con Agisoft Metashape (v. 2.1.4) y se seleccionaron seis clases temáticas basadas en sus patrones espectrales: suelo (SO), especies forestales (FS), *Vernonia polyanthes* (VP), *Chromolaena maximiliani* (CM), *Urochloa humidicola* (UH) y sombras. La identificación

de las clases se realizó sobre el terreno, utilizando bocetos con la ubicación de las plántulas, y posteriormente se cartografiaron en QGIS con la ayuda del ortomosaico. Por último, se recortó el área experimental para centrarse en la región de las especies cartografiadas (Fig. 2).



Figura 2. Superficie experimental recortada y puntos de identificación de las muestras (Mayo 2024).

Se utilizó un conjunto de 580 muestras, en el que cada muestra correspondía a un único píxel representativo de su respectiva clase temática. Las clases presentes alrededor de cada especie arbórea se identificaron, registraron y clasificaron en el ortomosaico digital utilizando el software QGIS (versión 3.4.10).

2.3. Clasificación supervisada

La clasificación digital se realizó a partir de la segmentación generada al aplicar el algoritmo *Multi-resolution segmentation* implementado en el software *eCognition Developer 10.5*, usando los parámetros siguientes: 1) Escala de 570, 2) Forma y color (*shape/colour*) de 0.1 y 0,9, y 3) Compacidad (*compactness*) de 0.5. La segmentación en un entorno OBIA permitió agrupar los píxeles con características espectrales y espaciales similares en segmentos homogéneos.

Seguidamente, para el entrenamiento de los modelos de clasificación se seleccionaron muestras representativas de cada clase, que sirvieron para alimentar los cuatro algoritmos de clasificación supervisada evaluados: bayesiano (BAYES), K-vecinos más próximos (KNN), bosque aleatorio (RF) y máquina de vectores de soporte (SVM).

2.4. Evaluación de la precisión

Para evaluar la precisión de la clasificación, de cada clase se seleccionaron 100 muestras para entrenamiento y 30 muestras para validación. Los clasificadores se evaluaron usando el entorno informático R (versión 4.5.1), mediante la construcción de la matriz de confusión entre los datos previstos y observados de cada clase, y el cálculo de las métricas de precisión global (1), precisión por clase (2) y tasa de error (3) (Foody, 2020).

Se calcularon los índices de desacuerdo cuantitativo (Dc), de asignación (Da) y global (Dg) para identificar si los errores estaban asociados a la cantidad de píxeles por clase o a la distribución espacial de las clases

(Pontius Jr. & Millones, 2011).

Para complementar la evaluación estadística, se realizó un análisis espacial de los resultados de la clasificación a partir de los mapas de cada clase temática y el cálculo del porcentaje de área ocupada por cada clase, lo que permitió realizar una comparación cuantitativa entre los diferentes modelos de clasificación.

3. RESULTADO Y DISCUSIÓN

El análisis comparativo de los cuatro clasificadores indicó que las clases SO y SH presentaron los mejores resultados en todos los modelos, mientras que las mayores tasas de confusión se produjeron entre las clases vegetativas FS, CM y UH (Fig. 3)

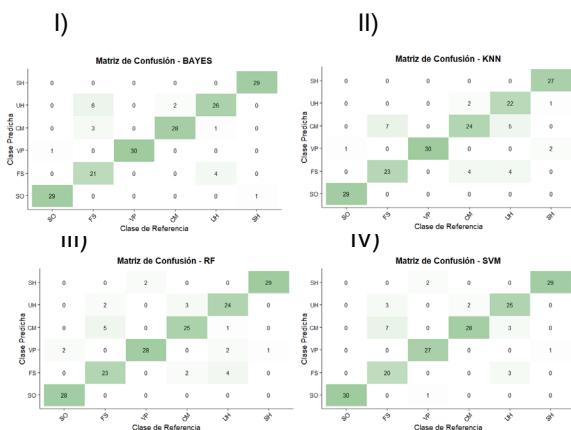


Figura 3. Matriz de confusión de los cuatro clasificadores: I) BAYES; II) KNN; III) RF; IV) SVM.

El modelo Bayes presentó alto rendimiento para clases vegetativas, entretanto la superposición espectral entre formaciones herbáceas y arbustivas fue evidenciada en la matriz de confusión, donde UH se clasificó con frecuencia como FS o CM, lo que coincide con estudios que señalan que clases con comportamientos espectrales similares tienden a confundirse en clasificaciones supervisadas debido a la falta de separación espectral clara (Zhang & Xie, 2019).

Los clasificadores probabilísticos basados en supuestos de independencia condicional, como los basados en Bayes, tienden a presentar un buen rendimiento cuando las clases tienen una clara separabilidad, pero muestran una mayor sensibilidad cuando existe correlación entre las bandas espectrales y la heterogeneidad intracase (Maxwell *et al.*, 2021).

Estudios anteriores que aplicaron clasificadores tradicionales a la identificación de especies forestales también reportaron desafíos similares a los observados en este trabajo. Por ejemplo, Loiola *et al.* (2023) utilizaron RF, SVM, KNN y Bayes para clasificar siete especies forestales a partir de datos espectrales de hojas, evidenciando limitaciones en escenarios de superposición espectral entre clases.

La evaluación del desempeño de los cuatro algoritmos revela diferencias en la clasificación de las clases vegetativas FS, VP, CM y UH (Tabla 1).

En general, UH presentó valores de F1 relativamente altos en todos los modelos (BAYES = 80 %, KNN = 79 %, RF = 80 %, SVM = 82 %), aunque se observó cierta confusión con FS y CM, lo que indica superposición espectral entre formaciones herbáceas y arbustivas. FS mostró F1 de 76 % en BAYES, 75 % en KNN, 78 % en RF y 75 % en SVM, reflejando dificultades similares para diferenciarla de otras clases vegetativas. VP alcanzó los mejores resultados en BAYES y KNN (F1 = 98 % y 95 %, respectivamente) y ligeramente menores en RF y SVM (89 % y 93 %), mientras que CM presentó F1 entre 82 % y 90 % según el algoritmo.

Tabla 1. Evaluación de la exactitud de la clasificación con los modelos BAYES, KNN, RF y SVM.

Modelo	Métricas (%)	Clases temáticas					
		SO	FS	VP	CM	UH	SH
BAYES	Accuracy	97	84	97	88	76	100
	Precision	97	70	100	93	84	97
	Recall	97	84	97	88	76	100
	F1-Score	97	76	98	90	80	98
KNN	Accuracy	100	74	91	67	88	100
	Precision	97	77	100	80	71	90
	Recall	100	74	91	67	88	100
	F1-Score	98	75	95	73	79	95
RF	Accuracy	100	79	85	81	83	94
	Precision	93	77	93	83	77	97
	Recall	100	79	93	83	77	97
	F1-Score	97	78	89	82	80	95
SVM	Accuracy	97	87	96	74	83	94
	Precision	100	67	90	93	81	97
	Recall	97	87	96	74	83	94
	F1-Score	98	75	93	82	82	95

SO: Suelo; FS: Especies Forestales; VP: Vernonia polyanthes; CM: Chromolaena maximiliani; UH: Urochloa humidicola; SH: Sombras.

La evaluación de la descomposición de los errores indicó que Bayes presentó un error total bajo (0,10), con predominio del componente cuantitativo (0,07), lo que evidencia una buena consistencia en la representación proporcional de las clases (Fig. 4).




Figura 4. Componentes de desacuerdo total, cuantitativo y de asignación para los modelos.

El SVM presentó un error total de 0,12, con equilibrio entre los componentes cuantitativo (0,07) y de asignación (0,06), lo que demuestra su capacidad para discriminar espacialmente las especies. RF (0,13) y KNN (0,14) mostraron un rendimiento inferior, combinando errores moderados en los dos componentes. Estos resultados indican que BAYES y SVM proporcionan cartografía más fiables para el manejo de malezas, permitiendo estimaciones precisas de las proporciones de clases y apoyo a la toma de decisiones, mientras que RF y KNN pueden utilizarse de forma complementaria.

Todos los modelos presentaron un error de asignación menor que el cuantitativo, lo que indica que las clases están bien posicionadas espacialmente y que la mayor parte del error se debe a diferencias en la proporción de las clases en el mapa, y no a su distribución en el espacio, comportamiento evidenciado en las matrices de confusión (Pontius Jr. & Millones, 2011).

El análisis espacial de las clases indica que los clasificadores BAYES y SVM presentan una menor variación en la estimación de la ocupación entre las clases, lo que evidencia la consistencia en la representación proporcional de las categorías (Tabla 2).

Tabla 2. Análisis espacial de los modelos y clases temáticas.

Clases	BAYES (%)	KNN (%)	RF (%)	SVM (%)
SO	23	22	19	23
FS	7	6	6	5
VP	13	16	17	15
CM	13	15	15	12
UH	20	18	19	20
SH	23	23	24	25

SO: Suelo; FS: Especies Forestales; VP: *Vernonia polyanthes*; CM: *Chromolaena maximiliani*; UH: *Urochloa humidicola*; SH: Sombras.

KNN y RF presentan pequeñas diferencias, principalmente en VP y CM, lo que sugiere que algunas variaciones en la ocupación pueden atribuirse a la segmentación y sensibilidad del modelo. Es importante destacar que, durante la recolección, VP se encontraba en fase de floración, y el comportamiento espectral de las flores pudo haberse confundido con la clase SO lo que contribuyó a la subestimación observada y a los errores de asignación entre estas clases.

La Figura 5 muestra la distribución espacial de las clases temáticas según los clasificadores BAYES y SVM, destacando la ocupación de las clases y permitiendo identificar las áreas de malas hierbas y especies de interés, lo que facilita la toma de decisiones y el manejo eficiente del territorio.




Figura 5. Distribución espacial de las clases temáticas según los clasificadores BAYES y SVM.

4. CONCLUSIÓN

Entre los clasificadores evaluados, BAYES y SVM mostraron la mayor exactitud y fiabilidad en la diferenciación de clases vegetativas, mientras que KNN y RF también tuvieron un desempeño adecuado, aunque con mayor confusión entre clases espectralmente similares. Los errores de desacuerdo se concentraron principalmente en la asignación espacial de las clases más que en la cuantificación de sus proporciones, lo que refuerza la robustez de BAYES y SVM para el mapeo y monitoreo de la vegetación en áreas de restauración forestal.

5. AGRADECIMIENTOS

Investigación financiada por el proyecto PID2023-150108OB-C31 (MCIU/AEI/10.13039/501100011033 y FSE+). El trabajo de Jhiorranni Freitas está financiado por beca de movilidad del Centro de Perfeccionamiento Personal de Enseño Superior (CAPES) - Doctorado Sándwich en el Extranjero -88881.127227/2025-0.

6. REFERENCIAS

- Foody, G. M. (2020). Remote sensing of tropical forests: Classification and accuracy assessment. Routledge.
- Loiola, T. M., Fantinel, R. A., Santos, F. D., Bastos, F., Schuh, M. S., Fernandes, P., Simões de Oliveira, B. A., & Pereira, R. S. (2023). Use of Machine Learning Algorithms in the Classification of Forest Species. *Anuário do Instituto de Geociências*, 46, 50490. https://doi.org/10.11137/1982-3908_2023_46_50490
- Maxwell, A. E., Warner, T. A., & Fang, F. (2021). Implementation of machine-learning classification in remote sensing: An applied review. *Remote Sensing*, 13(4), 645. <https://doi.org/10.3390/rs13040645>
- Mesías-Ruiz, G. A., Borra-Serrano, I., Peña, J. M., & colaboradores. (2025). Multispecies weed mapping using deep learning on UAV imagery. *Precision Agriculture*. Advance online publication. <https://doi.org/10.11119-025-10309-2>
- Pontius, R. G., & Millones, M. (2011). Death to Kappa: Birth of quantity disagreement and allocation disagreement for accuracy assessment. *International Journal of Remote Sensing*, 32(15), 4407–4429. <https://doi.org/10.1080/01431161.2011.552923>
- Zhang, X., & Xie, Y. (2019). A dynamic classification scheme for mapping spectrally similar classes: Application to wetland classification. *International Journal of Applied Earth Observation and Geoinformation*, 83, 101914. <https://doi.org/10.1016/j.jag.2019.101914>