

DETERMINACIÓN DE LA MORTALIDAD POST-INCENDIO DE FRAILEJONES
USANDO IMÁGENES CAPTADAS POR DRON Y MODELOS DE INTELIGENCIA
ARTIFICIAL

PAULA ANDREA UZCÁTEGUI LEÓN

UNIVERSIDAD INDUSTRIAL DE SANTANDER
FACULTAD DE INGENIERÍAS FISICOMECÁNICAS
ESCUELA DE INGENIERÍA DE SISTEMAS E INFORMÁTICA
BUCARAMANGA
2025

DETERMINACIÓN DE LA MORTALIDAD POST-INCENDIO DE FRAILEJONES
USANDO IMÁGENES CAPTADAS POR DRON Y MODELOS DE INTELIGENCIA
ARTIFICIAL

PAULA ANDREA UZCÁTEGUI LEÓN

Trabajo de Grado para optar al título de
Ingeniero de Sistemas

Director:

Hoover Fabián Rueda-Chacón

Ph.D. en Ingeniería Eléctrica y Computación

Codirector:

Björn Reu

Ph.D. en Ciencias Naturales

UNIVERSIDAD INDUSTRIAL DE SANTANDER
FACULTAD DE INGENIERÍAS FISICOMECAÑICAS
ESCUELA DE INGENIERÍA DE SISTEMAS E INFORMÁTICA
BUCARAMANGA

2025

DEDICATORIA

A mi familia amada y querida, gracias a su apoyo incondicional puedo pensar en frailejones todo el día.

PAULA

AGRADECIMIENTOS

Gracias a mi familia por ser mi mayor inspiración. A Sofi, Juli, Caro y mi mamá que me acompañaron al páramo a etiquetar frailejones. A mi papá que me acompaña todos los días a la universidad. A Salua y Tapias por animarme a la distancia. Y a mis directores por siempre responder mis preguntas.

Este trabajo fue realizado gracias al apoyo del grupo de Geomática que nos prestó el dron y a Mateo que lo voló en el frío del páramo. A la AMB por su colaboración. Al Laboratorio de Geoecología y el Semillero Hands-on Computer Vision donde he aprendido muchísimo. Y al Grupo Halley, que es mi hogar en la universidad.

PAULA

CONTENIDO

	pág.
INTRODUCCIÓN	15
1 OBJETIVOS	20
2 MARCO DE REFERENCIA	21
2.1 Ecosistema de páramo y frailejones	21
2.2 Teledetección y monitoreo ecológico	24
2.3 Índices de vegetación y salud vegetal	26
3 MÉTODO PROPUESTO	30
3.1 Datos disponibles para esta investigación	30
3.2 Procesamiento de ortomosaicos y generación de base de datos	36
3.3 Modelo de detección y segmentación de frailejones	38
3.4 Modelo de clasificación de mortalidad	41
3.4.1 Selección de variables predictoras	41
3.4.2 Métodos de clasificación no supervisada	45
3.4.2.1 Método de clasificación usando K-means con PCA	46
3.4.2.1 Método de clasificación por umbral estadístico	48
4 RESULTADOS Y DISCUSIÓN	52
4.1 Base de datos	52
4.2 Detección de frailejones	53
4.3 Resultados de la clasificación de frailejones	62
4.4 Resultados de mortalidad	66
4.4.1 Análisis espacial de la mortalidad	67

4.4.2	Análisis temporal de la mortalidad	69
5	CONCLUSIONES	75
6	TRABAJO FUTURO	76
	BIBLIOGRAFÍA	77

LISTA DE FIGURAS

	pág.
Figura 1 Progreso de recuperación y deterioro de frailejones en el área afectada por el incendio. (A) Febrero de 2024, la yema de la planta sobrevivió al incendio y es capaz de crecer nuevamente, (B) Agosto de 2024, rebrote de hojas y formación de las rosetas. (C) Diciembre de 2024, algunas de las rosetas que habían rebrotado después del incendio se marchitan y se ven decaídas. Fuente: Autor.	16
Figura 2 <i>Espeletia standleyana</i> , frailejón del Páramo de Santurbán, Santander. Fuente: Autor.	22
Figura 3 Flujo de procesamiento de ortomosaicos para predecir el estado de salud de los frailejones.	30
Figura 4 Incendio del Páramo de Santurbán, registrado el 23 de enero de 2024. (Arriba) Mapa de la ciudad de Bucaramanga a la izquierda y la localidad de El Picacho a la derecha, se observa el páramo cubierto por una nube de humo. Fuente: Sensor Sentinel 2 ¹ . (Abajo) Frailejones registrados el 31 de enero de 2024; aunque el exterior se observa completamente quemado, el tejido meristemático, o yema de la planta, sigue viva, por lo que puede volver a crecer nuevas hojas. Fuente: Laboratorio de Geoecología de la Universidad Industrial de Santander.	31

¹ Agencia Espacial Europea (ESA). *Imagen de Sentinel-2 del Copernicus Data Hub*. Accedido: 2025-04-21. 2025.

Figura 5	Localización del área de estudio, y delimitación de perímetros captados con el dron en diferentes momentos del año. Se destacan frailejones en ortomosaicos de distintas resoluciones obtenidos en diferentes vuelos.	33
Figura 6	Correspondencia entre el estado observado en campo (arriba) y la apariencia en el ortomosaico de los frailejones (abajo).	36
Figura 7	Matriz de correlación entre índices de vegetación y variables espectrales. Se observa una alta colinealidad entre varias variables, motivo por el cual se selecciona el NDVI como índice principal y se priorizan aquellas variables con baja correlación entre ellas, estas son la banda verde, los índices ARI1 y SIPI, y el área de la roseta en centímetros.	43
Figura 8	Distribución de valores de la mediana de bandas VNIR, índices de vegetación y área en centímetros de rosetas vivas y muertas, anotadas en campo. Las diferencias entre clases se cuantifican mediante la distancia de Cohen (d), observándose una separación sustancial ($d > 1.0$) en la mayoría de las variables, excepto para la banda <i>red edge</i> .	44
Figura 9	Índices de vegetación NDVI, SIPI y ARI1 en dos frailejones captados en diciembre de 2024: frailejón vivo (arriba) y muerto (abajo)	45
Figura 10	Distribución de las medianas de NDVI de las rosetas dentro de máscaras de segmentación (izquierda) y cajas delimitadoras (derecha).	46
Figura 11	Resultados de clasificación con PCA y K-means. A la izquierda se muestran los clusters y la contribución de cada variable a las componentes principales. A la derecha se muestra la varianza explicada por cada componente.	47
Figura 12	Histogramas de mediana de NDVI de los píxeles de rosetas segmentadas en (Izquierda) zona afectada y (Derecha) no afectada por el incendio.	49

Figura 13	Resultados de clasificación con el método de umbral estadístico usando diferentes índices de vegetación.	50
Figura 14	Metodología planteada de procesamiento áreas de páramo afectadas por el incendio para detectar y clasificar frailejones entre vivos y muertos.	51
Figura 15	Áreas de los mosaicos anotados con cajas delimitadoras, área de entrenamiento en verde y de validación en rosado. Los frailejones etiquetados en campo se muestran en blanco.	52
Figura 16	Distribución de los tamaños de las cajas delimitadoras anotadas en diferentes mosaicos para el conjunto de entrenamiento.	53
Figura 17	Progreso de reducción de función de pérdida de las cajas delimitadoras en el transcurso del entrenamiento para el modelo YOLO.	55
Figura 18	Resultados cualitativos de detección en ortomosaicos de validación, utilizando modelos entrenados con conjuntos de imágenes de distintas resoluciones. Se muestran las anotaciones manuales (rosado) junto con las detecciones obtenidas por YOLOv11 (azul) y RT-DETR (verde).	57
Figura 19	Resultados cualitativos de YOLOv11. Se muestran las etiquetas manuales (rosado), y la comparación entre el modelo entrenado con resoluciones mixtas (azul) y el entrenado únicamente con baja resolución (naranja).	58
Figura 20	Distribución de diámetros de rosetas detectadas por el modelo en imágenes de alta y baja resolución. El diámetro se estimó a partir del área de cada máscara de segmentación, asumiendo la forma de un círculo.	59
Figura 21	Comparación de detección en imágenes de baja y alta resolución: (arriba) error relativo; (abajo) error absoluto. Celdas azules indican mayor detección en baja resolución y rojas en alta resolución.	60

- Figura 22 Ejemplos de diferencias en la detección de frailejones entre mosaicos de alta (GSD 1.3 cm) y baja resolución (GSD 3.6 cm). (A) Dificultad del modelo para detectar frailejones muy próximos entre sí en baja resolución. (B) Falsos positivos en baja resolución por confusión del modelo con rocas o esfagno seco. (C) Zonas donde factores externos a la resolución influyen como la presencia de nubes en la imagen de alta resolución. 61
- Figura 23 Agrupamiento y clasificación con PCA y K-Means en un conjunto de datos obtenido de imágenes de alta resolución (izquierda) y baja resolución (derecha). 62
- Figura 24 Histogramas de frailejones detectados en ortomosaicos de alta (GSD 1.3cm) y baja resolución (GSD 3.6cm) captados en diciembre de 2024. Se muestra la selección del umbral estadístico mediante un modelo de mezcla gaussiana (GMM) de dos componentes. La línea roja discontinua marca el umbral, y la franja sombreada ($\pm 10\%$) la incertidumbre. La bimodalidad es más clara en alta resolución. En los histogramas estandarizados, los umbrales entre resoluciones resultan estadísticamente más comparables. 63
- Figura 25 Mezcla espectral para frailejones vivos y muertos a diferente resolución. Se comparan los mismos dos frailejones: uno vivo, y otro muerto, a diferentes resoluciones en términos de GSD. 65
- Figura 26 Errores de clasificación en imágenes de baja resolución debido a mezcla espectral de los pixeles de la roseta con vegetación circundante o suelo. 66

- Figura 27 Distribución del NDVI estandarizado en el área afectada por el incendio. Se muestran las distribuciones Gaussianas utilizadas en la estimación del umbral para la resolución del ortomosaico analizado (línea discontinua roja) y el umbral derivado del mosaico de alta resolución utilizado como referencia para la clasificación (línea discontinua azul). La franja sombreada en rojo es la zona de incertidumbre. 68
- Figura 28 Distribución del diámetro de rosetas clasificadas como vivas o muertas, en unidades de centímetros, de más de 86,000 frailejones. 69
- Figura 29 Mapas de un área de 83 hectáreas con presencia de frailejones, y distribución de frailejones vivos y muertos un año después del incendio. 70
- Figura 30 Histograma y mapas de mortalidad de los frailejones en las áreas registradas en alta resolución. 71
- Figura 31 Diferencia entre frailejones vivos con diámetro de roseta mayor a 15cm detectados entre diciembre de 2024 y junio de 2025 en áreas de 20m x 20m para una misma región. Valores más negativos (rojo) indican que se detectaron más frailejones vivos en diciembre de 2024, mientras que, valores más positivos (azul) indican una mayor cantidad de vivos en junio de 2025. Ejemplos de los cambios ocurridos en este lapso de seis meses se ilustran en: (A) Frailejones reportados como vivos, mueren. (B) Frailejones previamente clasificados como muertos dejan de ser detectados, ya que están demasiado deteriorados. (C) Frailejones vivos se vuelven visibles por cambios en la cobertura o condiciones de la imagen. 72

LISTA DE CUADROS

	pág.
Cuadro 1 Principales índices de vegetación y sus fórmulas ^{2,3} . R: rojo, G: verde, B: azul, NIR: infrarrojo cercano, RE: <i>red edge</i> .	29
Cuadro 2 Resumen de los ortomosaicos disponibles para la realización del proyecto. Los mosaicos seleccionados para realizar el proyecto se resaltan en verde.	34
Cuadro 3 Ortomosaicos seleccionados para el proyecto y áreas etiquetadas.	54
Cuadro 4 Resultados de modelos de detección de frailejones. * simboliza que el conjunto de datos de entrenamiento contenía únicamente imágenes de baja resolución. El total de las métricas se calcula ponderando las métricas para cada mosaico con el número de frailejones en su respectivo conjunto de validación.	56
Cuadro 5 Resultados de mortalidad en los ortomosaicos seleccionados para la realización del proyecto. Se abarca una mayor área en baja resolución ya que el dron vuela a mayor altura.	67
Cuadro 6 Frailejones detectados vivos y muertos en una misma área con una diferencia temporal de 6 meses, entre diciembre de 2024 y junio de 2025.	73

² J. Xue y B. Su. «Significant remote sensing vegetation indices: A review of developments and applications». En: *Journal of sensors* 2017.1 (2017), pág. 1353691.

³ S. Zhang et al. «Banana Fusarium Wilt Disease Detection by Supervised and Unsupervised Methods from UAV-Based Multispectral Imagery». En: *Remote Sensing* 14.5 (2022). DOI: 10.3390/rs14051231.

RESUMEN

TÍTULO: DETERMINACIÓN DE LA MORTALIDAD POST-INCENDIO DE FRAILEJONES USANDO IMÁGENES CAPTADAS POR DRON Y MODELOS DE INTELIGENCIA ARTIFICIAL *

AUTOR: PAULA ANDREA UZCÁTEGUI LEÓN **

PALABRAS CLAVE: Monitoreo remoto, aprendizaje profundo, monitoreo ecológico, ecología del fuego, frailejones.

DESCRIPCIÓN:

Los páramos andinos, ecosistemas tropicales de alta montaña esenciales para la regulación hídrica, enfrentan crecientes amenazas como los incendios. Su lejanía y difícil acceso dificultan su estudio. Particularmente en Colombia, la respuesta al fuego de los frailejones (*Espeletia spp.*), especies clave en los páramos, ha sido poco estudiada. Este trabajo implementa un flujo de procesamiento de imágenes multispectrales VNIR de alta resolución captadas con dron para evaluar la mortalidad de frailejones un año después de un incendio ocurrido en enero de 2024 en el Páramo de Santurbán (Colombia). Se emplearon modelos de detección de objetos de última generación (YOLOv11, RT-DETR) para identificar frailejones en imágenes RGB con precisiones de 90% para *Ground Sampling Distance* (GSD) \approx 1 cm y de 74% para GSD \approx 3 cm. A partir de estas detecciones, el modelo Segment Anything Model 2 (SAM2) permitió extraer la información multispectral correspondiente únicamente a los píxeles de cada roseta. Se propone un método de clasificación no supervisada de individuos vivos y muertos, basado en un umbral estadístico derivado de un Modelo de Mezcla Gaussiana (GMM) aplicado a los valores de NDVI, con exactitudes validadas en campo del 93.5% (GSD \approx 1 cm) y 76.3% (GSD \approx 3 cm). En 83 ha se detectaron 86,026 frailejones (>20 cm de diámetro), de los cuales entre el 30–40% (más de 25,000) presentaron mortalidad asociada al fuego. El enfoque propuesto permite evaluar el estado de los frailejones a nivel individual en grandes áreas de páramo, proporcionando una herramienta eficaz para monitorear los efectos del fuego, complementar estudios en campo, entender mejor la resiliencia del ecosistema y orientar estrategias de conservación.

* Trabajo de grado

** Facultad de Ingenierías Fisicomecánicas. Escuela de Ingeniería de Sistemas e Informática. Director: Hoover Fabián Rueda-Chacón. Codirector: Björn Reu.

ABSTRACT

TITLE: ASSESSING POST-FIRE MORTALITY OF ESPELETIA PLANTS USING ARTIFICIAL INTELLIGENCE ON DRONE IMAGERY *

AUTHOR: PAULA ANDREA UZCÁTEGUI LEÓN **

KEYWORDS: Remote sensing, deep-learning, ecological monitoring, fire ecology, giant rosette plants.

DESCRIPTION:

Páramos are diverse tropical mountain ecosystems, vital for water regulation but increasingly exposed to fires and other disturbances. The remoteness and inaccessibility of páramos make them challenging to study. In Colombia, the fire response of giant rosette plants (*Espeletia* spp.), keystone species in these ecosystems, has been scarcely studied. Here, we implemented a high-resolution multispectral VNIR image processing pipeline using drone imagery to assess *Espeletia* mortality one year after a fire in January 2024 in the Santurbán Páramo (Colombia). Our workflow combines state-of-the-art detection and segmentation algorithms YOLOv11 and Segment Anything Model 2 (SAM2) to identify *Espeletia* plants in RGB imagery and extract multispectral information from each rosette. Achieving sensitivities and precisions of 90 % for images with a Ground Sampling Distance (GSD) ≈ 1 cm and 74 % for GSD ≈ 3 cm. Plant mortality was assessed through an unsupervised classification approach. Assuming a bimodal distribution in the median NDVI values extracted from individual plant rosettes, a Gaussian Mixture Model (GMM) was fitted to the NDVI data to objectively determine the optimal separation threshold between two distributions. Successfully discriminating between live and dead individuals, achieving high field-validated classification accuracies: 93.5 % for imagery with a GSD ≈ 1 cm and 76.3 % for GSD ≈ 3 cm. Applying this workflow, we detected 86,026 *Espeletia* plants (>20 cm diameter) across 83 ha of páramo, of which 30–40 % (over 25,000 individuals) showed mortality likely associated with fire stress. Our results demonstrate that this approach enables accurate, individual-level assessment of plant health, providing a scalable tool to monitor fire impacts and ecosystem resilience in high-Andean páramos.

* Bachelor's Thesis

** Faculty of Physical-Mechanical Engineering. School of Systems Engineering & Informatics. Advisor: Hoover Fabián Rueda-Chacón. Co-advisor: Björn Reu.

INTRODUCCIÓN

El fuego es una perturbación recurrente en los ecosistemas de páramo; sin embargo, sus efectos han sido poco estudiados debido a la demanda de tiempo que requieren las investigaciones, así como a la inaccesibilidad y dificultad del terreno. En particular, la respuesta de los frailejones (*Espeletia spp.*), especies clave en la captura de agua y la regulación del microclima¹, frente al fuego sigue siendo poco comprendida. Aunque se ha observado que estas plantas pueden resistir el fuego y volver a desarrollar sus hojas, los efectos a largo plazo de los incendios aún no se conocen del todo².

Tras un incendio ocurrido en enero de 2024 en el Páramo de Santurbán, en la localidad El Picacho del municipio de Tona³, Santander, se ha observado que un año después del evento, algunos frailejones que inicialmente mostraban signos de recuperación, como el rebrote de hojas, ahora presentan indicios de deterioro y muerte, cómo se muestra en la Figura 1.

Aplicando instrumentos de teledetección, como drones, es posible captar con gran detalle estos cambios. Al operar a baja altitud, los drones permiten obtener imágenes con alta resolución espacial (a escala de centímetros por píxel) y, al estar equipados con sensores multiespectrales⁴, también registran variaciones espectra-

¹ M. Cárdenas et al. «Ecophysiology of frailejones (*Espeletia spp.*), and its contribution to the hydrological functioning of páramo ecosystems». En: *Plant Ecology* 219 (2018), págs. 185-198.

² P Ramsay. «Giant rosette plant morphology as an indicator of recent fire history in Andean páramo grasslands». En: *Ecological Indicators* 45 (2014), págs. 37-44.

³ Q Septer. *Unprecedented Fire Season Has Raged Through One of Earth's Biodiversity Hotspots*. <https://www.scientificamerican.com/article/unprecedented-fire-season-has-raged-through-one-of-earths-biodiversity-hotspots/>. Accessed: 2025-08-22. Feb. de 2024.

⁴ H. Yao, R. Qin y X. Chen. «Unmanned Aerial Vehicle for Remote Sensing Applications—A Re-




Figura 1. Progreso de recuperación y deterioro de frailejones en el área afectada por el incendio. (A) Febrero de 2024, la yema de la planta sobrevivió al incendio y es capaz de crecer nuevamente, (B) Agosto de 2024, rebrote de hojas y formación de las rosetas. (C) Diciembre de 2024, algunas de las rosetas que habían rebrotado después del incendio se marchitan y se ven decaídas. Fuente: Autor.

les, particularmente en el rango del infrarrojo cercano, lo que permite identificar vegetación estresada mediante el cálculo de índices de vegetación⁵.

En este trabajo de investigación se evaluó de forma automatizada la mortalidad post-incendio de los frailejones. Para ello se construyó un flujo de procesamiento de ortomosaicos, composiciones de imágenes georreferenciadas obtenidas mediante un dron multiespectral en el área afectada por el incendio. El proceso incluyó: (1) la creación de un conjunto de datos anotados de frailejones en imágenes captadas por dron con diferente resolución espacial; (2) la implementación de modelos avanzados de aprendizaje profundo, como *You Only Look Once* versión 11 (YOLOv11)⁶ y *Real-Time Detection Transformer*(RT-DETR)⁷, para la detección de frailejones en imágenes RGB; (3) la aplicación del modelo *Segment Anything Model 2* (SAM2)⁸ para segmentar las rosetas utilizando como guía las cajas delimitadoras obtenidas en el paso anterior; y (4) la evaluación del estado de salud de cada individuo mediante el cálculo de índices de vegetación en cada roseta segmentada, empleando métodos de clasificación como K-means y la selección de un umbral mediante deconvolución de histograma de NDVI por un *Gaussian Mixture Model* (GMM).

La precisión y la sensibilidad de los modelos de detección dependen en gran medida de la resolución de las imágenes. Un mayor valor de la distancia de muestreo en tierra (GSD, del inglés, *Ground Sampling Distance*) permite abarcar áreas más extensas, aunque con menor nivel de detalle. Por ello, en este trabajo se evalúa-

⁵ Z. Sun et al. «UAVs as remote sensing platforms in plant ecology: review of applications and challenges». En: *Journal of Plant Ecology* 14.6 (2021), págs. 1003-1023.

⁶ G. Jocher y J. Qiu. *Ultralytics YOLO11*. Ver. 11.0.0. 2024.

⁷ Y. Zhao et al. «DETRs Beat YOLOs on Real-time Object Detection». En: *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. 2024, págs. 16965-16974.

⁸ N. Ravi et al. *SAM 2: Segment Anything in Images and Videos*. 2024. arXiv: 2408.00714 [cs.CV].

ron ortomosaicos con resoluciones de aproximadamente 1 cm (alta resolución) y 3 cm (baja resolución). Para enfrentar las limitaciones asociadas a la baja resolución se implementaron distintas estrategias: entrenamiento con datos mixtos de diferentes resoluciones, entrenamiento exclusivo con baja resolución y la transferencia de umbrales de clasificación calculados a partir de imágenes de alta resolución.

Finalmente, la aplicación de este flujo de trabajo a grande extensiones de páramo permitió realizar dos tipos de análisis sobre los frailejones. Por un lado, un análisis espacial, que evalúa la distribución de individuos vivos y muertos en un área que abarca casi la totalidad de la zona afectada por el incendio; y por otro lado, un análisis temporal, que compara los resultados obtenidos en un lapso de seis meses para una misma área, permitiendo analizar no solo la mortalidad sino también el crecimiento y la recuperación de los frailejones.

Los resultados indican que, en imágenes de alta resolución, el modelo RT-DETR alcanzó el mejor desempeño, aunque con un mayor costo computacional; mientras que, en baja resolución, YOLOv11 entrenado exclusivamente con datos de dicha resolución presentó la mejor relación entre precisión, sensibilidad y tiempo de procesamiento. En cuanto a la clasificación, el umbral estadístico aplicado al NDVI se mostró como el método más eficaz por su simplicidad y fácil interpretabilidad. En conjunto, se evidencia que la resolución espacial es el factor que ejerce mayor influencia sobre la precisión de los resultados, tanto en detección como en clasificación. La aplicación del flujo de trabajo permitió identificar más de 86.000 frailejones con diámetros superiores a 20 cm, evidenciar su distribución heterogénea en 83 hectáreas de páramo y estimar una mortalidad asociada al estrés por fuego de entre el 30 y el 40%. Finalmente, en un análisis temporal sobre un área de tres hectáreas, se observó que entre diciembre de 2024 y junio de 2025 el crecimiento superó la mortalidad, con un incremento de individuos vivos con diámetros superiores a 15 cm que no habían sido detectados previamente. Estos hallazgos resaltan

la importancia de profundizar en investigaciones futuras sobre la regeneración de los frailejones tras disturbios ambientales, así como en el desarrollo de modelos de detección y clasificación capaces de generalizar de manera más robusta entre diferentes resoluciones espaciales.

1. OBJETIVOS

OBJETIVO GENERAL

Implementar un flujo de procesamiento de imágenes multiespectrales VNIR captadas por dron basado en inteligencia artificial para detectar, segmentar y clasificar frailejones y su estado de salud post-incendio con el fin de determinar su tasa de mortalidad y monitorear su recuperación.

OBJETIVOS ESPECÍFICOS

1. Explorar los ortomosaicos adquiridos con drones mediante la herramienta QGIS para seleccionar los conjuntos de entrenamiento, validación y testeo para su aplicación con modelos de inteligencia artificial.
2. Construir un conjunto de datos anotados de frailejones a partir de los ortomosaicos seleccionados.
3. Implementar y evaluar un algoritmo de aprendizaje profundo para la detección de frailejones en imágenes multiespectrales VNIR mediante cajas delimitadoras, que sirvan como guía para un modelo de segmentación *zero-shot*.
4. Clasificar el estado de salud de frailejones segmentados mediante índices de vegetación y estimar su tasa de mortalidad.

2. MARCO DE REFERENCIA

2.1. ECOSISTEMA DE PÁRAMO Y FRAILEJONES

Los páramos andinos son los ecosistemas de alta montaña más biodiversos del mundo, ubicados a más de 3.000 metros de altura en las montañas de Venezuela, Colombia y Ecuador. En Colombia, los páramos cubren cerca del 2 % del territorio nacional y suministran alrededor del 70 % del agua potable del país⁹. Suelos porosos y ricos en materia orgánica les permiten actuar como esponjas naturales, filtrando y almacenando agua, mientras capturan carbono atmosférico. Sin embargo, la biodiversidad de los páramos se ve amenazada por presiones antrópicas relacionadas con el cambio en el uso del suelo, como la agricultura, la ganadería y la minería, a lo que se suma el impacto del cambio climático, que desplaza las condiciones de temperatura propias de estos ecosistemas hacia mayores altitudes¹⁰.

Los frailejones, pertenecientes a los géneros *Espeletia* y *Espeletiopsis*, son plantas clave de los ecosistemas de páramo, importantes en la regulación hídrica de este¹¹. Se distinguen por una roseta de hojas en la parte superior de un tallo, como se observa en la Figura 2. Para algunas especies de *Espeletia* se ha reportado que las hojas son particularmente sensibles a las bajas temperaturas y evitan la formación de hielo mediante mecanismos de superenfriamiento¹². También, en algunas espe-

⁹ C. Murad, J. Pearse y C. Huguet. «Multitemporal monitoring of paramos as critical water sources in Central Colombia». En: *Scientific Reports* 14.1 (2024), pág. 16706.

¹⁰ W. Buytaert et al. «Cambio climático: la nueva amenaza para los páramos». En: *Avances en investigación para la conservación de los páramos andinos*. CONDESAN, Lima (2014).

¹¹ Cárdenas et al., ver n. 1.

¹² F Rada et al. «Supercooling along an Altitudinal Gradient in *Espeletia schultzei*, a Caulescent Giant Rosette Species». En: *Journal of Experimental Botany* 38.3 (mar. de 1987), págs. 491-497.




Figura 2. *Espeletia standleyana*, frailejón del Páramo de Santurbán, Santander. Fuente: Autor.

cies el tallo está cubierto por hojas secas persistentes, una adaptación conocida como marcescencia. Esta estructura actúa como aislante térmico, protegiendo el tejido interno y el reservorio de agua líquida almacenado en el tallo. Dicho reservorio es esencial para la planta durante períodos de escasez hídrica y debe mantenerse aislado para prevenir su congelación en las bajas temperaturas características del páramo¹³.

DOI: 10.1093/jxb/38.3.491. eprint: <https://academic.oup.com/jxb/article-pdf/38/3/491/1193668/38-3-491.pdf>.

¹³ A. Smith. «Function of dead leaves in *Espeletia schultzii* (Compositae), and Andean caulescent rosette species». En: *Biotropica* (1979), págs. 43-47; G. Goldstein y F. Meinzer. «Influence of insulating dead leaves and low temperatures on water balance in an Andean giant rosette plant». En: *Plant, Cell & Environment* 6.8 (1983), págs. 649-656.

Aunque el fuego es una perturbación recurrente en los páramos, sus efectos permanecen poco estudiados¹⁴, y la respuesta de los frailejones al fuego aún no se comprende completamente. En Colombia¹⁵, se ha documentado el impacto del fuego sobre la especie *Espeletia hartwegiana*: la mayoría de individuos juveniles mueren inmediatamente después de un incendio, mientras que los adultos presentan un mayor riesgo de muerte debido al daño sufrido; no obstante, también se registró un incremento en el reclutamiento de nuevos individuos tras el evento. Hasta el momento de la realización de este proyecto no se conocen estudios más recientes en Colombia; sin embargo, en Ecuador se han llevado a cabo investigaciones posteriores¹⁶, se ha observado que tras un incendio las hojas marcescentes se queman, dejando el tallo expuesto. Si la planta sobrevive, puede regenerar su roseta y las nuevas hojas desarrollan marcescencia, restaurando la capa protectora. No obstante, las plantas más altas, que conservan una mayor porción del tallo expuesto, muestran mayores tasas de mortalidad, posiblemente debido a la pérdida de la protección térmica del reservorio de agua interno. Se ha documentado un fenómeno de “muerte retardada”, donde hasta el 20 % de las plantas mueren hasta dos años después de incendios intensos. Se plantea que la combinación de tallos expuestos, noches extremadamente frías y períodos de sequía, bloquea el acceso al agua almacenada, lo que lleva finalmente a la muerte de la planta.

¹⁴ M. Zomer y P. Ramsay. «Post-fire changes in plant growth form composition and diversity in Andean páramo grassland». En: *Applied Vegetation Science* 24.1 (2021), e12554; P. Ramsay. «Páramo vegetation recovery in the first two years after a fire on Volcán Chiles, Ecuador». En: *The Ecology of Volcán Chiles: high-altitude ecosystems on the Ecuador-Colombia border* (2001), págs. 65-73.

¹⁵ P. Verweij y K. Kok. «Effects of fire and grazing on *Espeletia hartwegiana* populations». En: *Páramo. An Andean ecosystem under human influence. Academic, London, England* (1992), págs. 215-229.

¹⁶ Ramsay, «Giant rosette plant morphology as an indicator of recent fire history in Andean páramo grasslands», ver n. 2.

2.2. TELEDETECCIÓN Y MONITOREO ECOLÓGICO

La teledetección ha revolucionado el estudio de la biodiversidad al posibilitar la obtención remota de datos detallados sobre la superficie terrestre mediante sensores montados en plataformas aéreas y satelitales. En este contexto, los vehículos aéreos no tripulados (drones) se han consolidado como herramientas clave en ecología por su bajo costo, flexibilidad operativa y capacidad para capturar imágenes con alta resolución espacial y temporal¹⁷.

Las imágenes captadas con drones se procesan mediante algoritmos de fotogrametría para generar ortomosaicos georreferenciados. En este proceso se emplean los metadatos registrados por el dron, como la ubicación GPS y la altura de vuelo, y a través de un algoritmo de *Structure from Motion* (SfM)¹⁸ se detectan puntos en común entre imágenes para estimar la posición y orientación de cada cámara. Luego, se construye una nube de puntos tridimensional que representa la geometría del paisaje. A partir de esta información, se ensambla una imagen ortorrectificada (ortomosaico), corrigiendo las distorsiones ocasionadas por la perspectiva y la topografía¹⁹. Para esto existen softwares especializados como Agisoft Metashape²⁰. Además de cámaras RGB, los drones pueden incorporar sensores multispectrales, térmicos y LiDAR, ampliando su utilidad para medir características como la salud vegetal, la humedad del suelo, la temperatura superficial o la estructura tridimensio-

¹⁷ Yao, Qin y Chen, ver n. 4.

¹⁸ S. Ullman. «The interpretation of structure from motion». En: *Proceedings of the Royal Society of London. Series B. Biological Sciences* 203.1153 (1979), págs. 405-426.

¹⁹ S. Deliry y U. Avdan. «Accuracy of unmanned aerial systems photogrammetry and structure from motion in surveying and mapping: a review». En: *Journal of the Indian Society of Remote Sensing* 49.8 (2021), págs. 1997-2017.

²⁰ Agisoft LLC. *Agisoft Metashape*. Version 1.6.5, available at: <https://www.agisoft.com/>. 2020.

nal²¹.

La distancia de muestreo en tierra es la distancia real representada por cada píxel del ortomosaico, y depende de parámetros como la altura de vuelo, resolución del sensor y ángulo de toma. Las imágenes adquiridas por drones con un GSD de unos pocos centímetros (muy alta resolución) permiten identificar detalles a simple vista²². Para automatizar el monitoreo ecológico, se han desarrollado modelos de aprendizaje profundo capaces de identificar, contar y localizar plantas con alta precisión. Modelos como YOLO, Mask-CNN y DINO se han empleado para detectar plántulas de maíz²³, rosas en diferentes estados de maduración²⁴, lichies en árboles²⁵ y para detectar y segmentar copas de árboles en bosques tropicales densos²⁶. Este último trabajo emplea el modelo SAM2, desarrollado por la empresa Meta²⁷, para segmentar las copas de los árboles. Este modelo es capaz de generar máscaras de segmentación a partir de imágenes utilizando un *prompt*, es decir, una indicación que orienta al modelo sobre la ubicación del objeto a segmentar. Dicha indicación puede consistir de coordenadas puntuales o cajas delimitadoras, que pueden ser obtenidas previamente mediante un modelo de detección.

²¹ Sun et al., ver n. 5.

²² Yao, Qin y Chen, ver n. 4.

²³ T. Geng et al. «Research on Segmentation Method of Maize Seedling Plant Instances Based on UAV Multispectral Remote Sensing Images». En: *Plants* 13.13 (2024). DOI: 10.3390/plants13131842.

²⁴ F. Zhao et al. «Smart UAV-assisted rose growth monitoring with improved YOLOv10 and Mamba restoration techniques». En: *Smart Agricultural Technology* 10 (2025), pág. 100730.

²⁵ C. Liang et al. «Enhanced visual detection of litchi fruit in complex natural environments based on unmanned aerial vehicle (UAV) remote sensing». En: *Precision Agriculture* 26.1 (2025), pág. 23.

²⁶ H. Baudchon et al. *SelvaBox: A high-resolution dataset for tropical tree crown detection*. 2025. arXiv: 2507.00170 [cs.CV].

²⁷ Ravi et al., ver n. 8.

En general, estos trabajos del estado del arte comparten la estrategia de entrenar modelos de detección de objetos para localizar plantas mediante cajas delimitadoras o máscaras de segmentación. El desempeño de los modelos depende de la calidad de las anotaciones, la resolución espacial de las imágenes, las características de la especie objetivo y el ecosistema en que se encuentra.

Para la detección de frailejones, estudios previos proponen la arquitectura SS Res U-Net, una modificación de la red U-Net, logrando una precisión del 91.67 % en la segmentación de frailejones, demostrando el potencial de estos modelos para el monitoreo de estas plantas²⁸.

2.3. ÍNDICES DE VEGETACIÓN Y SALUD VEGETAL

La vegetación exhibe una respuesta espectral característica determinada por su composición química y estructura interna. Los índices de vegetación aprovechan esta variabilidad combinando la reflectancia en diferentes bandas para resaltar propiedades fisiológicas de las plantas. Entre ellos, uno de los índices más ampliamente utilizados es el NDVI (Índice de Vegetación de Diferencia Normalizada)²⁹, que compara la reflectancia en el infrarrojo cercano, altamente reflejada por tejidos vegetales sanos, con la del rojo, que es absorbida por la clorofila. Sus valores oscilan entre -1 y $+1$: los valores más altos indican vegetación sana, mientras que valores cercanos a cero o negativos corresponden a vegetación estresada, suelos desnudos o

²⁸ C. Zhang et al. «Identifying and mapping individual plants in a highly diverse high-elevation ecosystem using UAV imagery and deep learning». En: *ISPRS Journal of Photogrammetry and Remote Sensing* 169 (2020), págs. 280-291.

²⁹ F. Kriegler. «Preprocessing transformations and their effects on multispectral recognition». En: *Proceedings of the sixth international symposium on remote sensing of environment*. 1969, págs. 97-131.

cuerpos de agua³⁰.

Para clasificar el estado de salud vegetal a partir de índices de vegetación, diversos estudios han combinado imágenes captadas por drones con modelos de aprendizaje automático. Por ejemplo, se han utilizado métodos supervisados y no supervisados para detectar y clasificar enfermedades en cultivos de plátano, empleando distintos índices de vegetación como variables de entrada³¹. De forma similar, otros trabajos han seleccionado índices específicos para entrenar clasificadores supervisados orientados al monitoreo de musgos y líquenes en ambientes extremos como la Antártida³². En otro enfoque, se ha integrado aprendizaje profundo con imágenes multiespectrales para segmentar árboles individuales y determinar su estado de salud, distinguiendo entre ejemplares vivos y muertos³³.

En la Tabla 1 se presentan las fórmulas del NDVI y de otros índices de vegetación comúnmente utilizados. Muchos de estos índices comparten una estructura similar, con variaciones en ciertos parámetros o normalizaciones que buscan corregir distorsiones del NDVI. Por ejemplo, índices como SAVI, RDVI, WDRVI, TDVI, EVI, GDVI, NLI, MNLI y VDVI también miden el verdor de la vegetación, pero incorporan ajustes

-
- ³⁰ J. Xue y B. Su. «Significant remote sensing vegetation indices: A review of developments and applications». En: *Journal of sensors* 2017.1 (2017), pág. 1353691; S. Huang et al. «A commentary review on the use of normalized difference vegetation index (NDVI) in the era of popular remote sensing». En: *Journal of forestry research* 32.1 (2021), págs. 1-6.
- ³¹ S. Zhang et al. «Banana Fusarium Wilt Disease Detection by Supervised and Unsupervised Methods from UAV-Based Multispectral Imagery». En: *Remote Sensing* 14.5 (2022). DOI: 10.3390/rs14051231; M. Selvaraj et al. «Detection of banana plants and their major diseases through aerial images and machine learning methods: A case study in DR Congo and Republic of Benin». En: *ISPRS Journal of Photogrammetry and Remote Sensing* 169 (2020), págs. 110-124.
- ³² D. Raniga et al. «Monitoring of Antarctica's fragile vegetation using drone-based remote sensing, multispectral imagery and AI». En: *Sensors* 24.4 (2024), pág. 1063.
- ³³ S. Yao et al. «Individual Tree Crown Detection and Classification of Live and Dead Trees Using a Mask Region-Based Convolutional Neural Network (Mask R-CNN)». En: *Forests* 15.11 (2024), pág. 1900.

que compensan factores como la reflectancia del suelo, los efectos atmosféricos, la saturación en áreas con alta biomasa o, en el caso de VDVI, permiten hacerlo únicamente a partir de las bandas RGB. Otros índices se usan para determinar la presencia de pigmentos específicos producidos en las plantas bajo condiciones de estrés. Los índices ARI1 y ARI2 se emplean para detectar la presencia de antocianinas, pigmentos responsables de tonalidades rojizas, azuladas o púrpuras en las plantas, cuya acumulación suele asociarse a diversos tipos de estrés vegetal, como el inducido por la radiación ultravioleta³⁴. De forma similar, el GCI está orientado a estimar el contenido de clorofila verde, un indicador clave del estado fotosintético. Por otro lado, el índice SIPI (*Structure Insensitive Pigment Index*) es sensible a la relación entre carotenoides y clorofila, ambos pigmentos implicados en la fotosíntesis. Valores elevados de SIPI suelen indicar una mayor proporción de carotenoides, lo cual se asocia frecuentemente con condiciones de estrés en las plantas³⁵.

³⁴ M. Gitelson A. and Merzlyak y O. Chivkunova. «Optical properties and nondestructive estimation of anthocyanin content in plant leaves». En: *Photochemistry and photobiology* 74.1 (2001), págs. 38-45.

³⁵ J. Penuelas, F. Baret, I. Filella et al. «Semi-empirical indices to assess carotenoids/chlorophyll a ratio from leaf spectral reflectance». En: *Photosynthetica* 31.2 (1995), págs. 221-230.

Índice	Fórmula
<i>Normalized Difference Vegetation Index (NDVI)</i>	$(NIR - R)/(NIR + R)$
<i>Soil Adjusted Vegetation Index (SAVI)</i>	$1.5 * (NIR - R)/(NIR + R + 0.5)$
<i>Renormalized Difference Vegetation Index (RDVI)</i>	$(NIR - R)/(\sqrt{NIR + R})$
<i>Transformed Difference Vegetation Index (TDVI)</i>	$1.5 * (NIR - R)/(\sqrt{NIR + R + 0.5})$
<i>Simple Ratio Index (SRI)</i>	NIR/R
<i>Modified Simple Ratio Index (MSRI)</i>	$(NIR/R - 1)(\sqrt{NIR/R} + 1)$
<i>Green Difference Vegetation Index (GDVI)</i>	$NIR - G$
<i>Non-Linear Index (NLI)</i>	$(NIR^2 - R)/(NIR + R)$
<i>Modified Non-Linear Index (MNLI)</i>	$1.5 * (NIR^2 - R)/(NIR + R + 0.5)$
<i>Visible-Band Difference Vegetation Index (VDVI)</i>	$(2G - R - B)/(2G + R + B)$
<i>Anthocyanin Reflectance Index 1 (ARI1)</i>	$(1/G) - (1/RE)$
<i>Anthocyanin Reflectance Index 2 (ARI2)</i>	$NIR * ((1/G) - (1/RE))$
<i>Enhanced Vegetation Index (EVI)</i>	$2.5 * (NIR - R)/(NIR + 6R - 7.5B + 1)$
<i>Green Chlorophyll Index (GCI)</i>	$(NIR/G) - 1$
<i>Structure Insensitive Pigment Index (SIPI)</i>	$(NIR - B)/(NIR - R)$

Cuadro 1. Principales índices de vegetación y sus fórmulas^{36,37}. R: rojo, G: verde, B: azul, NIR: infrarrojo cercano, RE: red edge.

3. MÉTODO PROPUESTO

En este trabajo de investigación se desarrolló un flujo de trabajo para detectar y clasificar el estado de salud de frailejones en imágenes de alta resolución captadas por dron. El proceso consta de cuatro etapas principales: (1) la adquisición de las imágenes, (2) el preprocesamiento de ortomosaicos para generar teselas aptas para modelos de aprendizaje profundo; (3) la implementación de un modelo de detección de frailejones y la segmentación de las rosetas guiado por la detección; y (4) la clasificación no supervisada del estado de salud en categorías de vivos o muertos. Esta metodología permitió estimar la mortalidad de frailejones en el área analizada. En la Figura 3 se muestra un esquema del flujo de procesamiento planteado.

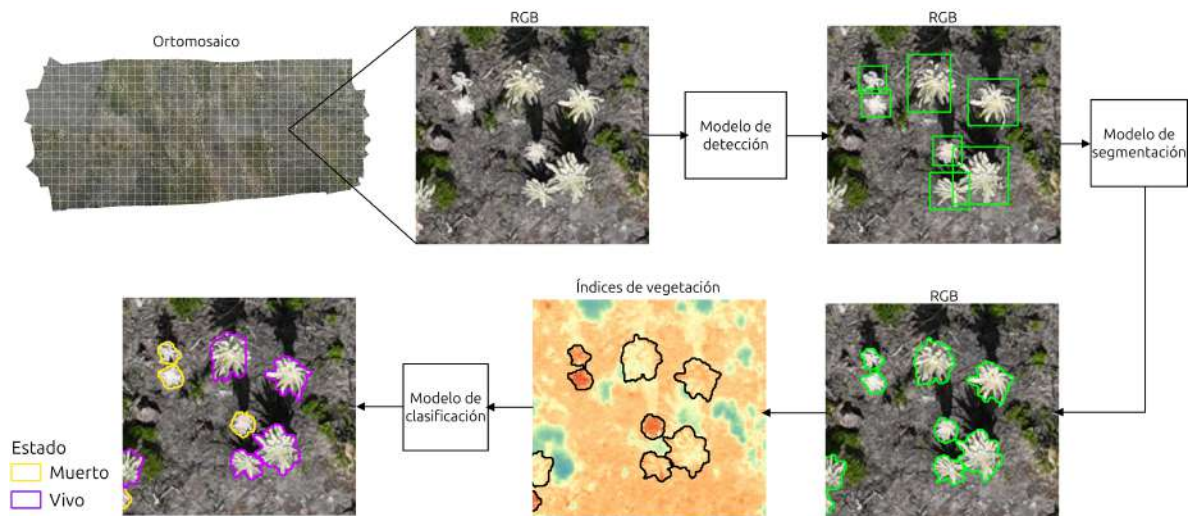


Figura 3. Flujo de procesamiento de ortomosaicos para predecir el estado de salud de los frailejones.

3.1. DATOS DISPONIBLES PARA LA INVESTIGACIÓN

Tras un incendio ocurrido en enero de 2024 que afectó más de 300 hectáreas del Páramo de Santurbán, en la localidad El Picacho en el municipio de Tona, Santander

(latitud 7.120638, longitud -72.9776513,874, elevación entre 3.000 - 3.300 msnm)
(Figura 4), el Laboratorio de Geoecología de la Universidad Industrial de Santander



Figura 4. Incendio del Páramo de Santurbán, registrado el 23 de enero de 2024. (Arriba) Mapa de la ciudad de Bucaramanga a la izquierda y la localidad de El Picacho a la derecha, se observa el páramo cubierto por una nube de humo. Fuente: Sensor Sentinel 2³⁸. (Abajo) Frailejones registrados el 31 de enero de 2024; aunque el exterior se observa completamente quemado, el tejido meristemático, o yema de la planta, sigue viva, por lo que puede volver a crecer nuevas hojas. Fuente: Laboratorio de Geoecología de la Universidad Industrial de Santander.

realizó vuelos con un dron DJI Mavic 3 Multispectral³⁹ en distintos momentos del año para documentar y analizar la zona afectada por el incendio. Este dron está equipado con una cámara RGB de 20 megapíxeles (MP) y un sistema multispectral compuesto por cuatro sensores de 5 MP para las bandas verde, roja, borde rojo (red edge) e infrarrojo cercano (NIR). También, incorpora un sensor de radiación solar en la parte superior que permite realizar la corrección automática de reflectancia de las imágenes adquiridas.

A partir de las imágenes captadas, se generaron ortomosaicos utilizando el software Agisoft Metashape⁴⁰. Los ortomosaicos fueron visualizados y analizados utilizando el software de Sistema de Información Geográfica (SIG) QGIS⁴¹, una herramienta de código abierto ampliamente utilizada para el procesamiento y análisis espacial. El tamaño del píxel, en términos del GSD, depende directamente de la altura de vuelo: a mayor altura, el GSD aumenta, lo que implica una menor resolución espacial, pero permite cubrir un área más extensa por imagen. El aspecto de los frailejones cambia según la resolución: en las imágenes de $GSD \approx 1$ cm (alta resolución) la roseta es claramente distinguible, mientras que en las de $GSD > 3$ cm (baja resolución) resulta más difícil de identificar, como se puede observar en la Figura 5.

En total se realizaron siete vuelos entre enero de 2024 y junio de 2025, que cubren distintas áreas del páramo con diferentes resoluciones. El Cuadro 2 resume las fechas, el área cubierta y el GSD de cada ortomosaico. Algunos vuelos se superponen espacialmente, pero difieren en fecha o resolución (Figura 5). Se generaron cuatro ortomosaicos de alta resolución ($GSD \approx 1$ cm) en enero, agosto y diciembre de

³⁹ DJI. *Mavic 3 Multispectral*. DJI Agriculture. Retrieved February 22, 2025.

⁴⁰ Agisoft LLC, ver n. 20.

⁴¹ QGIS Development Team. *QGIS: Sistema de Información Geográfica*. Accedido: 2025-04-21. 2025.

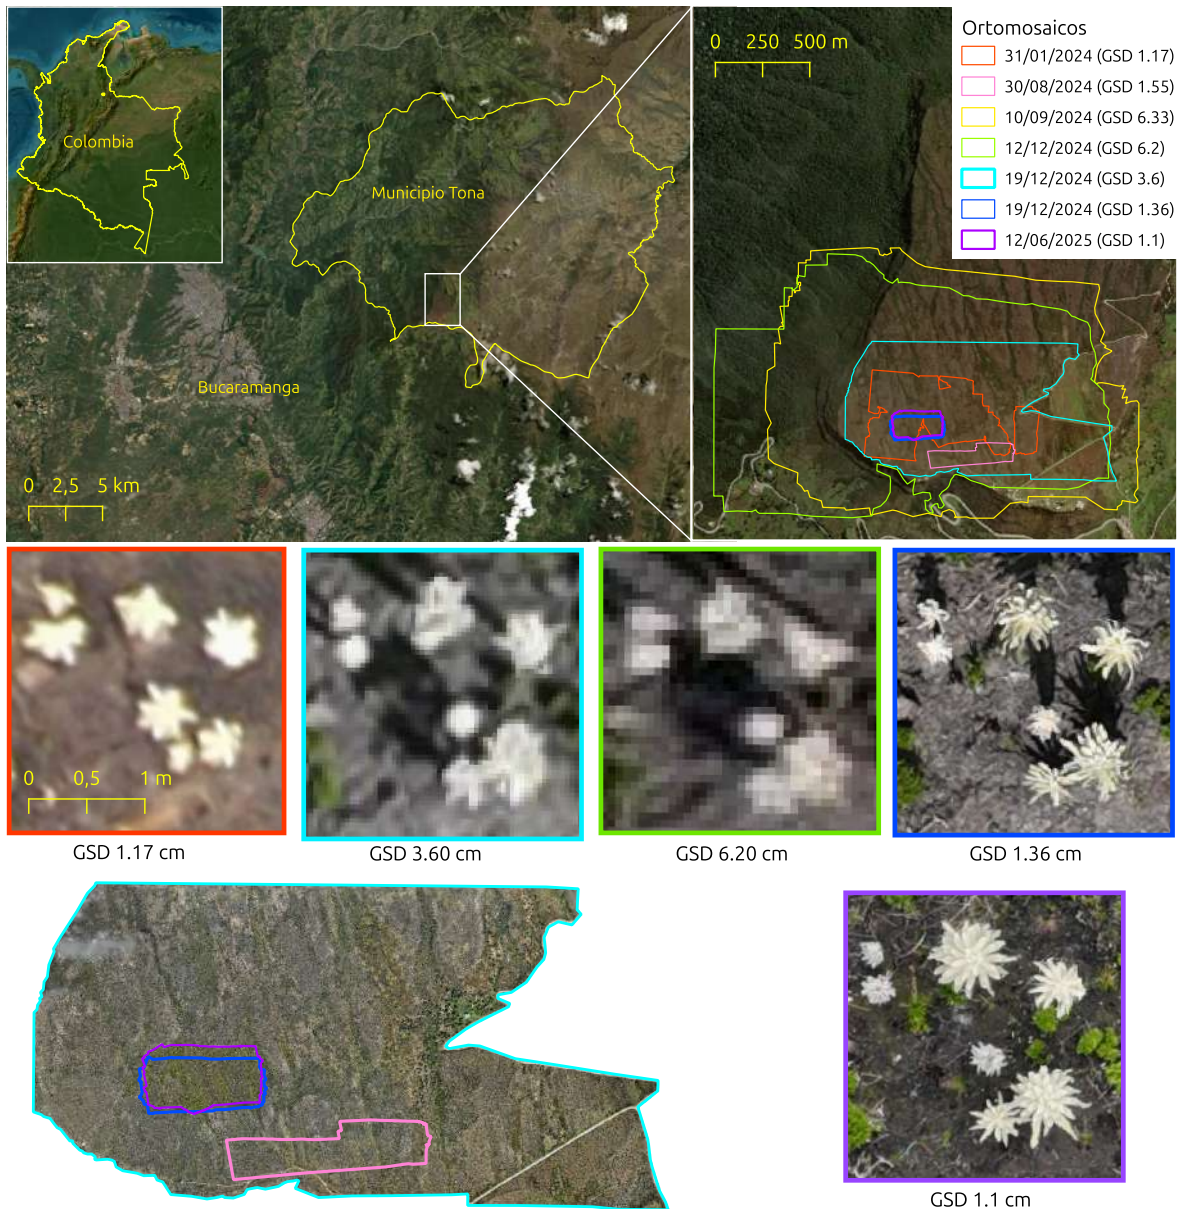


Figura 5. Localización del área de estudio, y delimitación de perímetros captados con el dron en diferentes momentos del año. Se destacan frailejones en ortomosaicos de distintas resoluciones obtenidos en diferentes vuelos.

2024, y en junio de 2025. El ortomosaico de enero no se utilizó debido a artefactos en la imagen y a que algunas rosetas, gravemente quemadas y sin hojas, no podían identificarse. Además, se obtuvieron tres ortomosaicos de baja resolución (GSD >

3 cm) en septiembre y diciembre de 2024; en particular, el del 19 de diciembre aún permite distinguir las rosetas, mientras que con resoluciones cercanas a 6 cm su identificación resulta mucho más difícil. Cabe destacar que el 19 de diciembre de 2024 se realizaron dos vuelos a diferentes alturas, resultando en dos ortomosaicos: uno de alta resolución (3.2 ha, GSD = 1.3 cm) y otro de baja resolución (83 ha, GSD = 3.6 cm).

Debido a lo explicado anteriormente, se seleccionaron cuatro ortomosaicos para el presente proyecto: el de agosto de 2024, los dos del 19 de diciembre de 2024 (alta y baja resolución) y el de junio de 2025. En el caso del ortomosaico de baja resolución (GSD = 3.6 cm), el proceso de etiquetado se apoyó en las imágenes de alta resolución de la misma área, con el fin de asegurar la calidad de las etiquetas. Las anotaciones se realizaron manualmente utilizando QGIS y la herramienta de polígonos tipo *shape*. Para cada frailejón identificado, se dibujaron rectángulos que se guardaron con las coordenadas geográficas (longitud y latitud) de sus esquinas superior izquierda e inferior derecha.

	Fecha	Área (ha)	GSD (cm)
1	31/01/2024	27	1.17
2	30/08/2024	3.8	1.55
3	10/09/2024	228	6.33
4	12/12/2024	219	6.20
5	19/12/2024	83	3.60
6	19/12/2024	3.2	1.36
7	12/06/2025	3.5	1.1

Cuadro 2. Resumen de los ortomosaicos disponibles para la realización del proyecto. Los mosaicos seleccionados para realizar el proyecto se resaltan en verde.

Para obtener datos destinados a la validación de la clasificación del estado de salud

de los frailejones, se empleó la aplicación móvil SW Maps⁴². La aplicación permite cargar un ortomosaico en formato MBTiles y registrar datos sobre este con coordenadas georreferenciadas mediante el GPS del dispositivo móvil, lo cual facilita la recolección de datos directamente en campo, en este caso, asegurando una correspondencia entre la imagen y la realidad observada. En la Figura 6 se presentan ejemplos de estos datos etiquetados, comparando su apariencia en campo con el ortomosaico.

Sobre las imágenes captadas en diciembre, se realizó el etiquetado en campo un mes después, en enero de 2025, con el fin de contrastar el estado real de los frailejones con su apariencia en los mosaicos. Durante un recorrido por el páramo se registraron los individuos visibles a lo largo del trayecto, procurando obtener una muestra representativa. Para cada ejemplar identificado en los ortomosaicos, se asignó la etiqueta de “vivo” o “muerto” según su condición observada *in situ*. Los individuos cuyas hojas se encontraban completamente secas fueron clasificados como muertos. En total se etiquetaron 112 frailejones, de los cuales 59 correspondieron a plantas muertas (53 %) y 53 a plantas vivas (47 %). 77 de estos se etiquetaron sobre el mosaico de alta resolución. Cabe resaltar que, para maximizar la validez de este tipo de comparación, el intervalo de tiempo entre la captura de imágenes con dron, la generación del ortomosaico y la visita de campo debe ser lo más reducido posible, de manera que el estado observado de las plantas refleje fielmente su aspecto en las imágenes empleadas para la clasificación.

⁴² Softwel/Aviyaan Tech. *SW Maps - GIS Data Collector*. https://play.google.com/store/apps/details?id=np.com.softwel.swwmaps&hl=es_CO. Available at: https://play.google.com/store/apps/details?id=np.com.softwel.swwmaps&hl=es_CO. 2025.




Figura 6. Correspondencia entre el estado observado en campo (arriba) y la apariencia en el ortomosaico de los frailejones (abajo).

3.2. PROCESAMIENTO DE ORTOMOSAICOS Y GENERACIÓN DE BASE DE DATOS

Para generar un conjunto de datos adecuado para un modelo de aprendizaje profundo, fue necesario procesar los ortomosaicos mediante su división en teselas de tamaño definido, junto con las etiquetas correspondientes a cada una. Para ello, se desarrolló un código en Python. Se definió un tamaño de $8m \times 8m$ para el área cubierta por cada tesela, que se representa en una imagen de 512×512 píxeles

mediante *upsampling*. Para evitar la pérdida de información en los bordes, se estableció un solapamiento del 20 % entre las teselas, esta estrategia asegura que los frailejones, que pueden alcanzar diámetros cercanos a los 2 m, aparezcan completamente en al menos en una tesela. Sin este solapamiento, un individuo podría dividirse entre dos teselas y ser contabilizado como dos detecciones distintas, lo que introduciría errores en la estimación del número de frailejones, especialmente en grandes extensiones. Para el conjunto de entrenamiento se eliminaron las teselas que presentaban más de un 85 % de píxeles vacíos, así como aquellas sin anotaciones, limitando estas últimas a un máximo del 20 % del tamaño total del conjunto de datos. Adicionalmente se hace una verificación manual de las imágenes generadas y se eliminan imágenes borrosas, que generalmente ocurren en los bordes. Para cada imagen se conservaron las anotaciones que estuvieran en un 60 % dentro de la tesela. Las anotaciones fueron transformadas del formato geoespacial original al formato YOLO, el cual utiliza coordenadas relativas en píxeles dentro de cada tesela y es ampliamente utilizado en visión por computadora por su compatibilidad con modelos de detección de objetos. Paralelamente, se almacenaron metadatos georreferenciados de cada imagen recortada, lo cual permite posteriormente convertir las predicciones del modelo nuevamente a coordenadas espaciales y visualizarlas en QGIS.

El solapamiento de teselas es una práctica común al utilizar modelos de aprendizaje profundo en imágenes de teledetección, sin embargo, esto puede generar detecciones duplicadas de un mismo objeto⁴³. Para solucionar esto, se generan algoritmos como *Non-Maximum Suppression* (NMS); para eliminar las predicciones que se solapen, manteniendo aquellas con el mayor tamaño. Luego de evaluar visualmente

⁴³ Y. Shen et al. «Fast and accurate multi-class geospatial object detection with large-size remote sensing imagery using CNN and Truncated NMS». En: *ISPRS Journal of Photogrammetry and Remote Sensing* 191 (2022), págs. 235-249.

diferentes tamaños, se escogió un solapamiento de 20 %.

Una vez obtenidas las cajas delimitadoras en las imágenes solapadas, estas se transformaron a coordenadas geoespaciales para identificar el número real de frailejones detectados en el área de estudio. Posteriormente, para la segmentación, las cajas se reasignaron a las imágenes, asegurando que cada individuo estuviera contenido en una única tesela. De esta forma se evitó que una misma detección apareciera en más de una imagen debido al solapamiento, lo que habría generado segmentaciones duplicadas.

3.3. MODELOS DE DETECCIÓN Y SEGMENTACIÓN DE FRAILEJONES

La segmentación supervisada requiere etiquetas de máscaras, cuya elaboración suele ser más costosa y demandante en tiempo que la generación de cajas delimitadoras. Por ello, en este proyecto se adoptó un enfoque híbrido: primero la detección de frailejones y, posteriormente, la segmentación guiada a partir de esas cajas mediante el modelo *zero-shot* SAM2. Un modelo *zero-shot* se caracteriza por su capacidad de abordar nuevas clases sin necesidad de un entrenamiento específico. En el caso de SAM, esta capacidad se deriva de su entrenamiento masivo y diverso, que le permite generalizar a objetos no vistos previamente a través del uso de *prompts* (entradas que guían la segmentación), los cuales pueden consistir en puntos, cajas delimitadoras o máscaras previas.

Se seleccionaron dos modelos representativos del estado del arte en tareas de detección de objetos: YOLOv11 y RT-DETR. El modelo YOLOv11, desarrollado por Ultralytics⁴⁴, pertenece a la familia de arquitecturas *You Only Look Once* (YOLO). Estos modelos realizan predicciones directamente sobre una grilla de la imagen, eliminando la etapa de propuestas de regiones característica de modelos de dos fases

⁴⁴ Jocher y Qiu, ver n. 6.

como Mask R-CNN⁴⁵. Según sus autores, YOLOv11 introduce mejoras arquitectónicas⁴⁶ que permiten alcanzar una mayor precisión media promedio (mAP) utilizando al mismo tiempo un menor número de parámetros que la versión anterior YOLOv8⁴⁷. Dado que los modelos YOLO generan múltiples predicciones por cada ancla de la grilla inicial, requieren algoritmos de NMS para eliminar duplicados de un mismo objeto. En este contexto, la función de pérdida para las cajas delimitadoras (*box loss*) se basa en variantes de IoU extendidas, como CloU, que incorporan no solo la superposición entre cajas, sino también la distancia entre centros y la coherencia en la relación de aspecto.

Por otro lado, RT-DETR⁴⁸ se fundamenta en la arquitectura DETR (*DEtection TRansformer*)⁴⁹, que adapta los *Visual Transformers*⁵⁰ a la detección de objetos. A diferencia de YOLO, DETR genera un número fijo de predicciones mediante un bloque *decoder* y utiliza un esquema de emparejamiento bipartito (*Hungarian matching*) para asociarlas con las *ground truths*. La función de pérdida combina un término IoU con la distancia L1 entre las cajas. RT-DETR mejora esta arquitectura mediante mecanismos de atención más eficientes en el *encoder* y estrategias avanzadas

⁴⁵ K. He et al. «Mask R-CNN». En: *Proceedings of the IEEE International Conference on Computer Vision (ICCV)*. 2017; J. Redmon et al. «You only look once: Unified, real-time object detection». En: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. 2016, págs. 779-788.

⁴⁶ R. Khanam y M. Hussain. «Yolov11: An overview of the key architectural enhancements». En: *arXiv preprint arXiv:2410.17725* (2024).

⁴⁷ J. Glenn, C. Ayush y Q. Jing. *Ultralytics YOLOv8*. Ver. 8.0.0. 2023.

⁴⁸ Zhao et al., «DETRs Beat YOLOs on Real-time Object Detection», ver n. 7.

⁴⁹ N. Carion et al. «End-to-end object detection with transformers». En: *European Conference on Computer Vision*. Springer. 2020, págs. 213-229.

⁵⁰ A. Dosovitskiy et al. «An image is worth 16x16 words: Transformers for image recognition at scale». En: *arXiv preprint arXiv:2010.11929* (2020).

de selección de *queries* (candidatos de objetos), lo que acelera la convergencia y reduce el costo computacional, permitiéndole competir con la familia de modelos YOLO.

Ambos modelos se implementaron utilizando la librería de Ultralytics. En el caso de YOLOv11, se empleó la versión *small*, que cuenta con 9.2 millones de parámetros, lo cual resulta adecuado para un dataset de tamaño reducido. Para RT-DETR, en cambio, se utilizó la versión *large*, ya que al momento de la experimentación no se encontraba disponible públicamente una variante más pequeña; esta versión tiene 42 millones de parámetros. La diferencia en el número de parámetros se refleja en la velocidad de inferencia y en el tiempo de entrenamiento requerido por cada modelo. Por esta razón se reporta el valor de FPS (*Frames Per Second*) como medida de velocidad.

Para la evaluación las métricas de desempeño se reportan a escala del ortomosaico completo, en lugar de hacerlo por tesela. Dado que el objetivo final es cuantificar la presencia de objetos a lo largo de toda el área del ortomosaico, la agregación de predicciones previa al cálculo de métricas proporciona una evaluación más coherente con la tarea y con el contexto espacial⁵¹. Por ello, reportamos las métricas de sensibilidad, precisión y F1-Score a nivel de ortomosaico, que en adelante denotamos como *RP* (Precisión), *RR* (Recall) y *RF1* (F1-Score), respectivamente, de acuerdo con las Ecuaciones (1), (2) y (3).

- **Precisión** (*Precision, RP*): mide la proporción de predicciones positivas que realmente corresponden a objetos verdaderos. Se calcula como:

$$RP = \frac{TP}{TP + FP}, \quad (1)$$

⁵¹ Baudchon et al., ver n. 26.

donde TP (*True Positives*) son los verdaderos positivos, es decir, objetos correctamente detectados, y FP (*False Positives*) son los falsos positivos, es decir, detecciones erróneas de objetos inexistentes.

- **Recall** (*Sensibilidad o Exhaustividad, RR*): mide la proporción de verdaderos positivos detectados entre todos los objetos reales. Se expresa como:

$$RR = \frac{TP}{TP + FN}, \quad (2)$$

donde FN (*False Negatives*) representa los falsos negativos, es decir, los objetos reales que el modelo no logró detectar.

- **F1-Score** ($RF1$): corresponde a la media armónica entre la precisión y el recall, y se utiliza cuando se desea equilibrar ambas métricas. Su expresión matemática es:

$$RF1 = 2 \cdot \frac{RP \cdot RR}{RP + RR}. \quad (3)$$

3.4. MODELO DE CLASIFICACIÓN DE MORTALIDAD

Para la tarea de clasificación del estado de salud de los frailejones, se establecieron dos categorías: vivo y muerto, con el fin de simplificar el problema. Sin embargo, como trabajo futuro se puede definir una escala con diferentes niveles de salud o estrés. Con base en los datos etiquetados en campo y los frailejones etiquetados manualmente en los ortomosaicos, se evalúan diferentes criterios estadísticos para la selección de las variables predictoras y los modelos para la tarea de clasificación.

3.4.1 Selección de variables predictoras

A partir de la delimitación de los frailejones, ya sea empleando cajas delimitadoras o mascararas de segmentación, se tienen los píxeles correspondientes a cada roseta en

las bandas visibles y multiespectrales, así como los índices de vegetación derivados de ellas. Usar directamente todos los valores de píxeles como entrada al modelo de clasificación incrementaría de manera considerable el volumen y la redundancia de datos, por lo tanto se optó por utilizar estadísticas resumidas de dichos índices. La mediana se seleccionó por su robustez frente a valores atípicos, ya que es menos sensible que la media aritmética a errores de segmentación como la inclusión de suelo u otra vegetación.

La selección de variables se realizó mediante un análisis de correlación (Figura 7), donde se observó una alta redundancia entre varios índices, esto era de esperarse dado que muchos corresponden a ajustes de las mismas medidas. Adicionalmente, se analizó la capacidad discriminativa de cada variable mediante la distancia de Cohen (d) (Ecuación 4). Esta medida es independiente de la escala de las variables y ofrece un criterio comparativo: valores cercanos a 0.2 se interpretan como un efecto pequeño, alrededor de 0.5 como mediano y próximos a 0.8 como grandes. Matemáticamente este índice está dado por

$$d = \frac{\mu_1 - \mu_2}{\sigma_{\text{pooled}}}, \quad (4)$$

donde μ_1 y μ_2 son las medias de cada distribución y σ_{pooled} la desviación estándar combinada. Esta métrica evalúa el grado de separación entre dos distribuciones normalizadas. En este caso, las distribuciones corresponden a las clases vivo y muerto. Como se puede ver en la Figura 8, a excepción de la banda *red edge*, todas las variables presentaron diferencias superiores a $d > 1.0$, lo que sugiere una separación sustancial entre clases.

A partir de este análisis, se seleccionó el NDVI como variable principal por su alto valor de d , amplia adopción en estudios de vegetación y facilidad de interpretación. Además, se identificaron como variables complementarias aquellas con menor correlación con el NDVI, con influencia en la predicción del estado de salud y que




Figura 7. Matriz de correlación entre índices de vegetación y variables espectrales. Se observa una alta colinealidad entre varias variables, motivo por el cual se selecciona el NDVI como índice principal y se priorizan aquellas variables con baja correlación entre ellas, estas son la banda verde, los índices ARI1 y SIPI, y el área de la roseta en centímetros.

estuvieran poco correlacionadas entre ellas: la banda verde, los índices ARI1 y SIPI, y el área de la roseta en centímetros.

La respuesta de los frailejones vivos y muertos a los tres índices de vegetación seleccionados se puede ver en la Figura 9. Para el NDVI se puede observar una clara diferencia entre los valores de las plantas vivas y muertas, mientras que para el ARI1 la diferencia no es tan marcada. Con el índice SIPI, valores más positivos

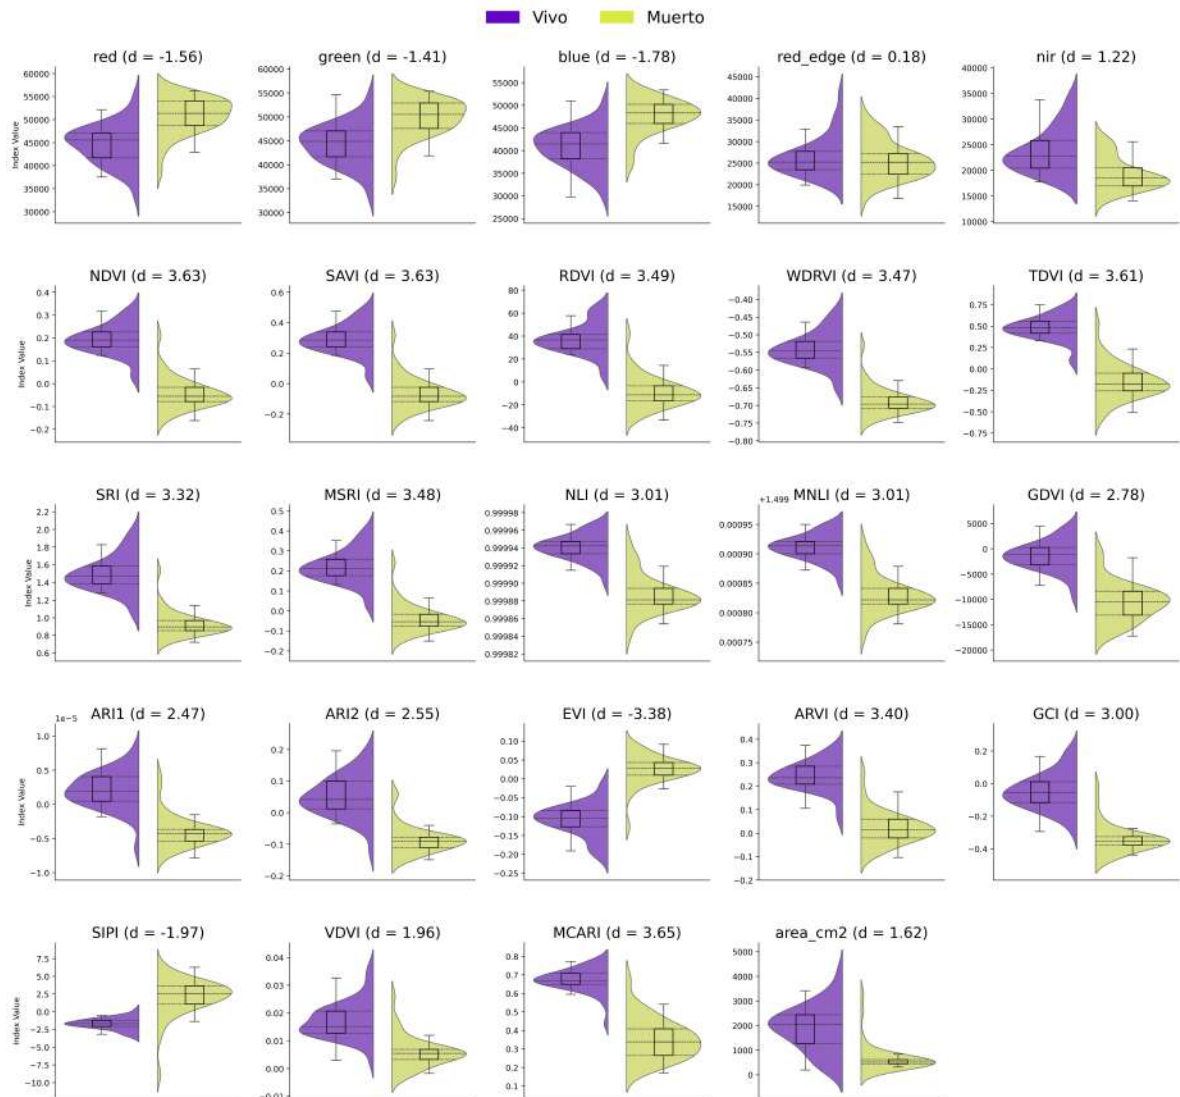


Figura 8. Distribución de valores de la mediana de bandas VNIR, índices de vegetación y área en centímetros de rosetas vivas y muertas, anotadas en campo. Las diferencias entre clases se cuantifican mediante la distancia de Cohen (d), observándose una separación sustancial ($d > 1.0$) en la mayoría de las variables, excepto para la banda *red edge*.

parecen concentrarse en el interior de los frailejones muertos, indicando una mayor presencia de carotenoides.

La segmentación de imágenes permite delimitar con mayor precisión cada roseta, reduciendo la inclusión de suelo o vegetación adyacente y mejorando la estimación

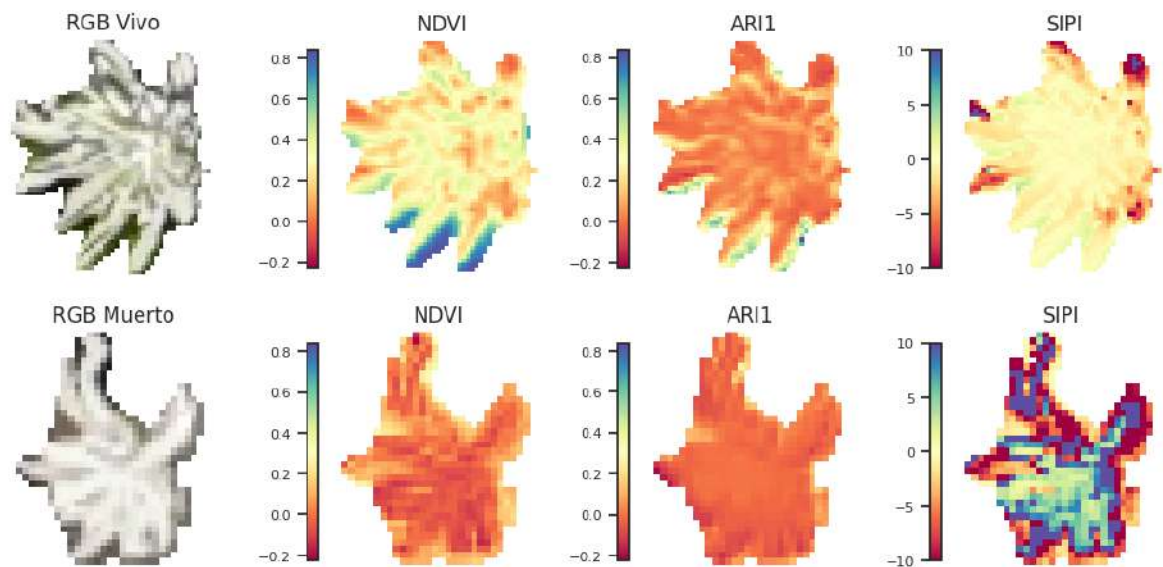


Figura 9. Índices de vegetación NDVI, SIPI y ARI1 en dos frailejones captados en diciembre de 2024: frailejón vivo (arriba) y muerto (abajo)

del tamaño de las plantas. Para evaluar si las máscaras generadas con SAM2 ofrecen una mejor diferenciación del estado de salud frente a las cajas delimitadoras, se comparó la mediana del NDVI en frailejones anotados en imágenes de alta resolución de diciembre, periodo con alta proporción de rosetas muertas observadas en campo. La Figura 10 muestra las distribuciones de mediana de NDVI. Ambos métodos revelan un patrón bimodal (individuos vivos y muertos), pero las cajas delimitadoras presentan un sesgo hacia valores positivos y una menor separación entre las dos modas, posiblemente debido a la inclusión de suelo y vegetación adyacente, lo que puede dificultar la clasificación.

3.4.2 Métodos de clasificación no supervisada

Debido a la disponibilidad limitada de datos etiquetados en campo, la clasificación del estado de salud se aborda con métodos no supervisados, empleando las variables seleccionadas. Se consideran dos enfoques: el primero consiste en el agrupa-

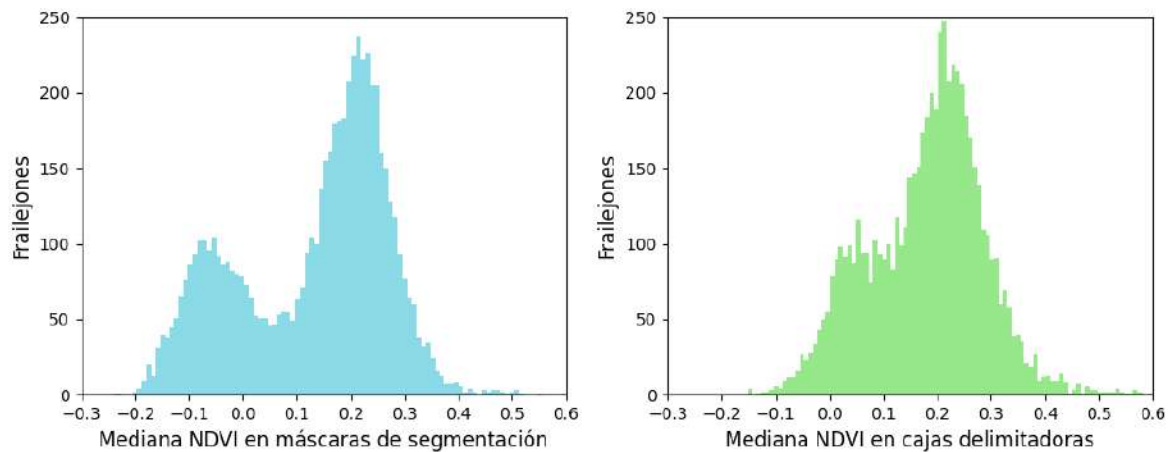


Figura 10. Distribución de las medianas de NDVI de las rosetas dentro de máscaras de segmentación (izquierda) y cajas delimitadoras (derecha).

miento con K-means tras reducción de dimensionalidad con PCA, incorporando así diferentes variables; el segundo es la clasificación mediante un umbral estadístico sobre una única variable predictora. Para evitar sesgos en los métodos por desbalance de clases, se realizan las pruebas usando los frailejones anotados manualmente en el ortomosaico de diciembre, ya que en este se observa una proporción considerable de plantas muertas. Luego, se computa la exactitud (Ecuación (5)) utilizando 77 etiquetas anotadas en campo que se encuentran en este mismo mosaico.

$$\text{Accuracy} = \frac{\# \text{ Predicciones Correctas}}{\# \text{ Total de Observaciones}}. \quad (5)$$

Finalmente, se calcula el porcentaje de mortalidad en el área analizada según la siguiente expresión 6:

$$\text{Mortalidad} = \frac{\# \text{ Muertos}}{\# \text{ Muertos} + \# \text{ Vivos}}. \quad (6)$$

3.4.2.1. Método de clasificación usando K-means con PCA:




Figura 11. Resultados de clasificación con PCA y K-means. A la izquierda se muestran los clusters y la contribución de cada variable a las componentes principales. A la derecha se muestra la varianza explicada por cada componente.

Se aplicó un análisis de componentes principales (PCA)⁵² para reducir la dimensionalidad de los datos y facilitar la visualización de las relaciones entre las variables predictoras. Posteriormente, se realizó un agrupamiento mediante K-means⁵³ sobre las dos primeras componentes principales. Ambos métodos se implementaron con la librería *scikit-learn*⁵⁴. La Figura 11 muestra los resultados de este análisis: cada punto representa un frailejón, coloreado según el cluster asignado por K-means, y las flechas rojas indican la contribución de cada variable a las componentes principales. Los datos de campo se sobreponen con un marcador diferente (*) para evaluar la concordancia con los clusters.

La mayor diferenciación entre los clusters se observa principalmente a lo largo del

⁵² K. Pearson. «On lines and planes of closest fit to systems of points in space». En: *The London, Edinburgh, and Dublin Philosophical Magazine and Journal of Science* 2.11 (1901), págs. 559-572. DOI: 10.1080/14786440109462720.

⁵³ S. Lloyd. «Least squares quantization in PCM». En: *IEEE Transactions on Information Theory* 28.2 (1982), págs. 129-137. DOI: 10.1109/TIT.1982.1056489.

⁵⁴ F. Pedregosa et al. «Scikit-learn: Machine Learning in Python». En: *Journal of Machine Learning Research* 12 (2011), págs. 2825-2830.

eje horizontal (PC1), lo que indica que las variables con mayor carga en PC1 como NDVI (carga positiva) y SIPI (carga negativa) son las más relevantes para la separación. Comparando las asignaciones de K-means con las etiquetas de campo, se obtiene una exactitud del 93.5 %.

La principal desventaja de este enfoque es que los clusters generados por K-means no necesariamente corresponden a las categorías de interés en la clasificación del estado de salud (frailejones vivos y muertos), sino a agrupaciones estadísticas que requieren validación con datos de campo. Esto limita su aplicabilidad en áreas sin información de referencia y aumenta el riesgo de interpretaciones erróneas. Además, cuando la separación entre vivos y muertos no es marcada, K-means tiende a producir fronteras artificiales que no garantizan una clasificación clara ni consistente entre diferentes ortomosaicos.

3.4.2.2. Método de clasificación por umbral estadístico

Este método parte de la suposición de una distribución bimodal de los valores de índices de vegetación dentro de las rosetas. De acuerdo con la teoría, cualquier distribución puede representarse como una combinación de distribuciones Gaussianas⁵⁵. En este caso, se asume que la población está compuesta por dos distribuciones normales: una para los individuos vivos y otra para los muertos. Un ejemplo de esto se ilustra en la Figura 12.

Para modelar las dos distribuciones se emplea un *Gaussian Mixture Model (GMM)*, ajustando los pesos (influencia de las Gaussianas sobre la distribución final), las medias y las desviaciones estándar, a partir de los datos mediante máxima verosi-

⁵⁵ K. Pearson. «Contributions to the Mathematical Theory of Evolution». En: *Philosophical Transactions of the Royal Society of London*. A 185 (1894), págs. 71-110.

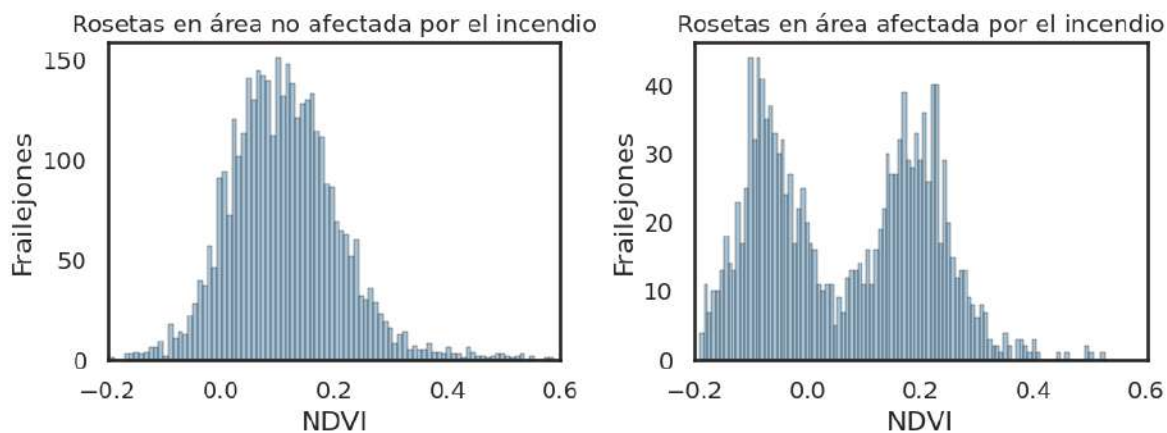


Figura 12. Histogramas de mediana de NDVI de los píxeles de rosetas segmentadas en (Izquierda) zona afectada y (Derecha) no afectada por el incendio.

militud⁵⁶. La implementación se realiza con la librería *scikit-learn*⁵⁷. Una vez estimadas las dos distribuciones Gaussianas que mejor se ajustan a los datos, el umbral de clasificación se define en el punto de intersección entre ambas. Este enfoque puede extenderse a una *fuzzy classification*, aprovechando que el GMM calcula la probabilidad de pertenencia de cada dato a cada distribución. Así, los casos en los que la diferencia entre probabilidades sea menor al 10% se consideran inciertos, y permiten establecer umbrales inferior y superior alrededor del punto de intersección. De esta manera se incorpora la incertidumbre en la separación de los grupos, evitando clasificaciones estrictas en regiones ambiguas.

En la Figura 13 se presentan los resultados del método de umbral estadístico aplicado a las variables seleccionadas: banda verde, NDVI, SIPI, ARI1 y área de la roseta. Entre todas ellas, el NDVI evidenció la mayor separación entre las dos distribuciones ajustadas y alcanzó la exactitud de clasificación más alta (93.5%). Si bien ARI1

⁵⁶ A. Dempster, N. Laird y D. Rubin. «Maximum Likelihood from Incomplete Data Via the *EM* Algorithm». en. En: *Journal of the Royal Statistical Society Series B: Statistical Methodology* 39.1 (sep. de 1977), págs. 1-22. DOI: 10.1111/j.2517-6161.1977.tb01600.x.

⁵⁷ Pedregosa et al., ver n. 54.

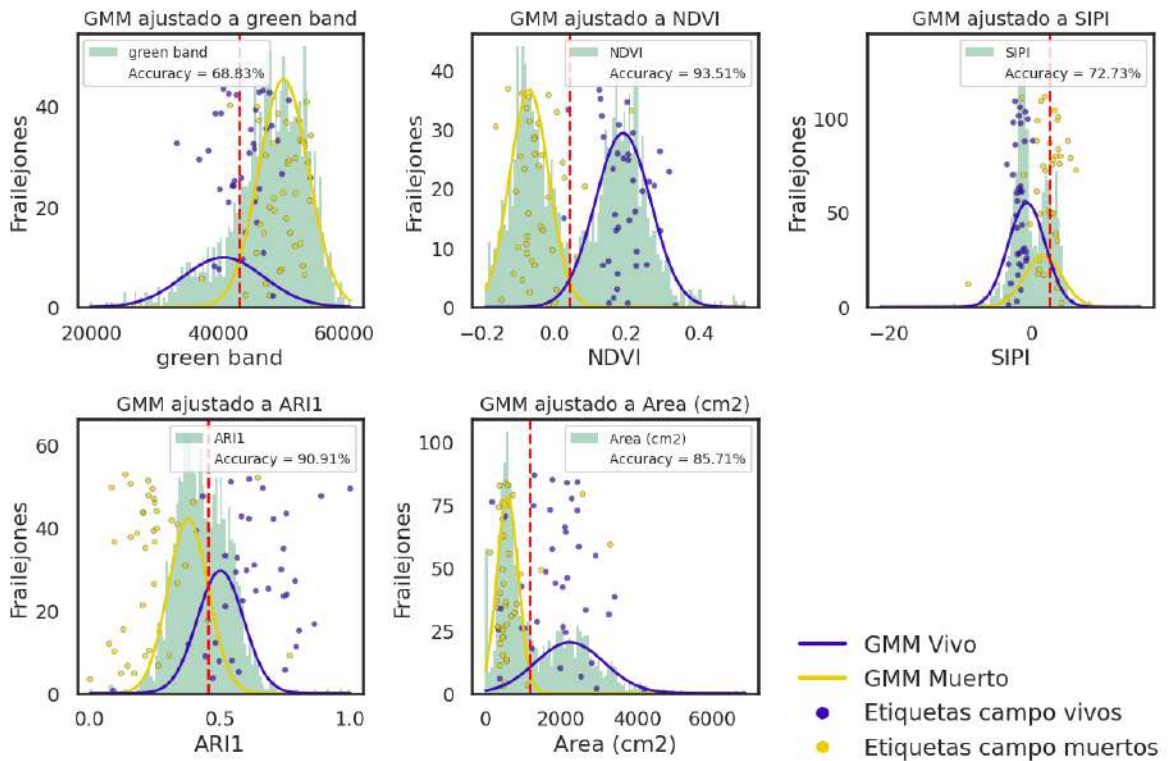


Figura 13. Resultados de clasificación con el método de umbral estadístico usando diferentes índices de vegetación.

y el área de la roseta también mostraron un buen desempeño, la bimodalidad del NDVI es más marcada y, además, se trata de un índice ampliamente utilizado y reconocido. En contraste, el área en centímetros de la roseta presenta la desventaja de excluir a los individuos vivos de menor tamaño, lo cual limita su utilidad como variable clasificatoria.

Con ambos métodos de clasificación se obtiene la misma exactitud; sin embargo, el método del umbral estadístico resulta más adecuado porque ofrece una interpretación directa de los resultados: la curva Gaussiana cuya media está más cercana a cero corresponde a los frailejones muertos, y la separación entre las distribuciones puede incluso sugerir un estado intermedio de daño. Esto convierte al histograma en una especie de firma cuantitativa del estado de los frailejones en el área.

Con base en los pasos descritos anteriormente, la metodología se sintetiza en el diagrama presentado en la Figura 14, el cual resume de manera esquemática el procedimiento seguido en este estudio.

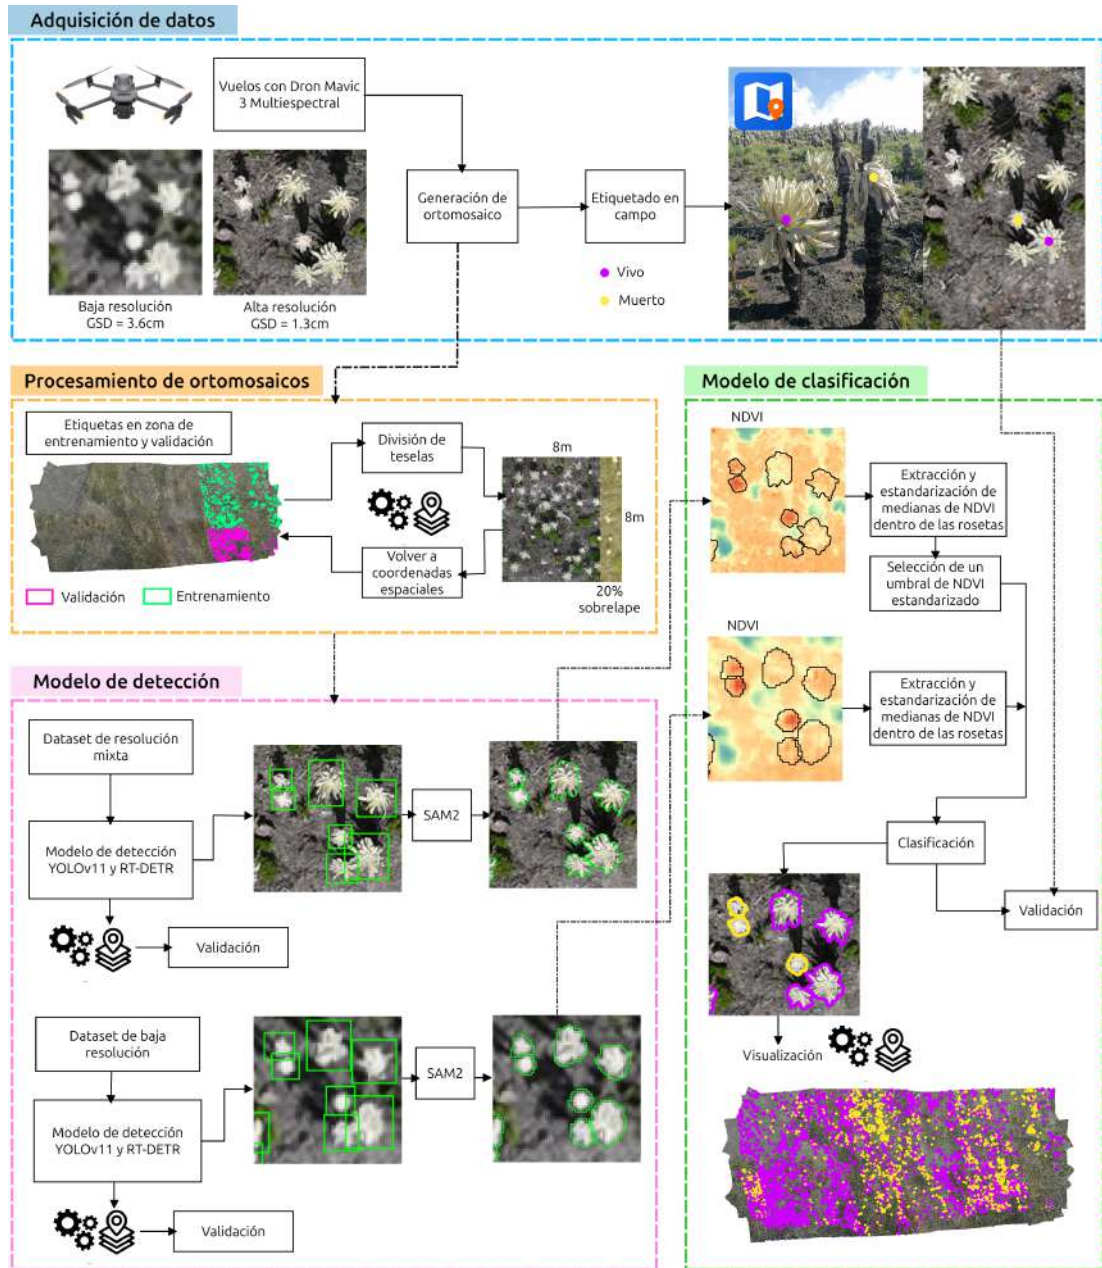


Figura 14. Metodología planteada de procesamiento áreas de páramo afectadas por el incendio para detectar y clasificar frailejones entre vivos y muertos.

4. RESULTADOS Y DISCUSIÓN

4.1. BASE DE DATOS

De los cuatro ortomosaicos seleccionados se hizo la división espacial de los conjuntos de entrenamiento, validación y testeo, esto para evitar que el modelo de detección aprenda patrones espaciales de los datos de entrenamiento, y así poder visualizar y evaluar la capacidad de predicción del modelo sobre áreas nunca antes vistas. En la Figura 15 se muestra la distribución espacial de estas anotaciones en las zonas etiquetadas. En total se etiquetaron manualmente 13.815 frailejones en diferentes mosaicos y resoluciones espaciales.




Figura 15. Áreas de los mosaicos anotados con cajas delimitadoras, área de entrenamiento en verde y de validación en rosado. Los frailejones etiquetados en campo se muestran en blanco.

Para el entrenamiento se generó un conjunto de datos con más de 20.000 anotaciones con cajas delimitadoras de frailejones distribuidos entre los mosaicos de agosto y diciembre en baja y alta resolución (al usar un porcentaje de solapamiento al generar




Figura 16. Distribución de los tamaños de las cajas delimitadoras anotadas en diferentes mosaicos para el conjunto de entrenamiento.

las teselas, la cantidad de etiquetas en las imágenes es mayor que la cantidad de frailejones anotados en el área, debido a las repetición de algunos objetos en las regiones de solapamiento). En la Figura 16 se muestra la distribución de tamaños de las cajas delimitadoras de los frailejones en los mosaicos empleados para el entrenamiento. En el Cuadro 3 se muestran los datos anotados por cada conjunto.

4.2. DETECCIÓN DE FRAILEJONES

Ambos modelos fueron entrenados en la plataforma Google Colaboratory, utilizando una GPU NVIDIA T4. El entrenamiento se realizó con la totalidad de las imágenes anotadas, que incluían datos tanto de alta como de baja resolución. Durante el entrenamiento se aplicaron técnicas de aumento de datos que abarcaron transformaciones fotométricas, como ajustes en matiz, saturación y brillo en el espacio

Conjunto	Mosaico y GSD	Área (ha)	Frailejones	Imágenes
Entrenamiento	Agosto (1.55 cm)	3.7	5398	625
	Diciembre (1.3 cm)	0.62	833	156
	Diciembre (3.6 cm)	3.8	5875	1011
Validación	Agosto (1.55 cm)	0.38	616	127
	Diciembre (1.3 cm)	0.27	645	94
	Diciembre (3.6 cm)	0.38	675	94
	Junio (1.1 cm)	0.27	418	60
Testeo	Diciembre (1.3 cm)	3.2	-	840
	Diciembre (3.6 cm)	83	-	23.552
	Junio (1.1 cm)	3.5	-	1174

Cuadro 3. Ortomosaicos seleccionados para el proyecto y áreas etiquetadas.

HSV, y transformaciones geométricas, como rotaciones, proyecciones en perspectiva, deformaciones tipo *shear*, volteo horizontal aleatorio y la técnica de *mosaic augmentation*, que combina múltiples imágenes en una sola entrada.

El modelo YOLOv11 se entrenó durante 200 épocas, mientras que el modelo RT-DETR se entrenó durante 50 épocas, dado que un mayor número de iteraciones provocaba inestabilidad numérica de la función de pérdida. Además, debido a su mayor número de parámetros, el tiempo de entrenamiento de RT-DETR fue considerablemente más alto. La Figura 17 muestra la evolución de la función de pérdida de las cajas delimitadoras a lo largo de las épocas para el modelo YOLOv11.

Como se muestra en el Cuadro 4, tanto YOLOv11 como RT-DETR mostraron un buen desempeño sobre los mosaicos de alta resolución, alcanzando un RF1 de 0.853 y 0.824 en el mosaico de junio, que no fue incluido en el entrenamiento. Ponderando las métricas por el número de frailejones en cada conjunto de datos, RT-DETR obtuvo los mejores resultados con un RF1 de 0.89. En las imágenes de baja resolución (GSD de 3.6 cm) la precisión y sensibilidad se redujeron considerablemente, lo que evidencia una limitada capacidad de generalización entre escalas.



Figura 17. Progreso de reducción de función de pérdida de las cajas delimitadoras en el transcurso del entrenamiento para el modelo YOLO.

Para mitigar este problema, ambos modelos fueron reentrenados exclusivamente con datos de baja resolución, generados al reducir la calidad espacial de todas las imágenes originales para igualarlas a un GSD de 3.6 cm. Para ello, se calculó un factor de escala como el cociente entre el GSD de la imagen original y el GSD de referencia, y se aplicó dicho factor mediante la función `cv2.resize` de la librería OpenCV⁵⁸, utilizando interpolación cúbica. Posteriormente, las imágenes se reescalaron nuevamente a su tamaño original, de modo que conservaran las mismas dimensiones en píxeles pero con una resolución espacial equivalente a la del mosaico de referencia. Este entrenamiento mejoró el RF1 en un 16 % para YOLOv11, lo que resalta la importancia de mantener una resolución consistente para optimizar el desempeño del modelo. Para RT-DETR la mejora es de tan solo un 3 %.

Entre los dos modelos evaluados, YOLOv11 presentó una velocidad de inferencia promedio de aproximadamente 0.3 FPS, cerca de cuatro veces menor que RT-

⁵⁸ G. Bradski. «The OpenCV Library». En: *Dr. Dobb's Journal of Software Tools* (2000).

Resolución	Modelo	Mosaicos	RF1	RP	RR
Alta (GSD \approx 1cm)	YOLOv11	Agosto	0.837	0.886	0.794
		Diciembre	0.911	0.946	0.879
		Junio 2025	0.853	0.868	0.838
		TOTAL	0.869	0.904	0.837
	RT-DETR	Agosto	0.905	0.930	0.881
		Diciembre	0.939	0.942	0.936
		Junio 2025	0.824	0.873	0.781
		TOTAL	0.897	0.920	0.877
Baja (GSD \approx 3cm)	YOLOv11		0.581	0.666	0.515
	YOLOv11*	Diciembre	0.742	0.748	0.736
	RT-DETR	GSD 3.6 cm	0.696	0.729	0.666
	RT-DETR*		0.730	0.694	0.770

Cuadro 4. Resultados de modelos de detección de frailejones. * simboliza que el conjunto de datos de entrenamiento contenía únicamente imágenes de baja resolución. El total de las métricas se calcula ponderando las métricas para cada mosaico con el número de frailejones en su respectivo conjunto de validación.

DETR, de 1.3 FPS. Esto es relevante al considerar escenarios de procesamiento a gran escala, como la detección en extensas áreas de terreno.

La Figura 18 ilustra resultados representativos en ortomosaicos de distintas regiones. Ambos modelos detectan frailejones en escenarios complejos, aunque presentan limitaciones al separar individuos próximos o al identificar ejemplares pequeños. En imágenes de baja resolución (Figura 20), el modelo entrenado exclusivamente con este tipo de datos reduce los falsos positivos en rocas y suelo frente al modelo entrenado con resoluciones mixtas.

Para evaluar la influencia de la resolución de las imágenes en la detección de frailejones, se compararon dos ortomosaicos adquiridos el mismo día de diciembre de 2024 sobre la misma área de 3.2 hectáreas, pero con resoluciones distintas. En el ortomosaico de alta resolución (GSD = 1.3 cm) se detectaron 6,218 individuos,




Figura 18. Resultados cualitativos de detección en ortomosaicos de validación, utilizando modelos entrenados con conjuntos de imágenes de distintas resoluciones. Se muestran las anotaciones manuales (rosado) junto con las detecciones obtenidas por YOLOv11 (azul) y RT-DETR (verde).

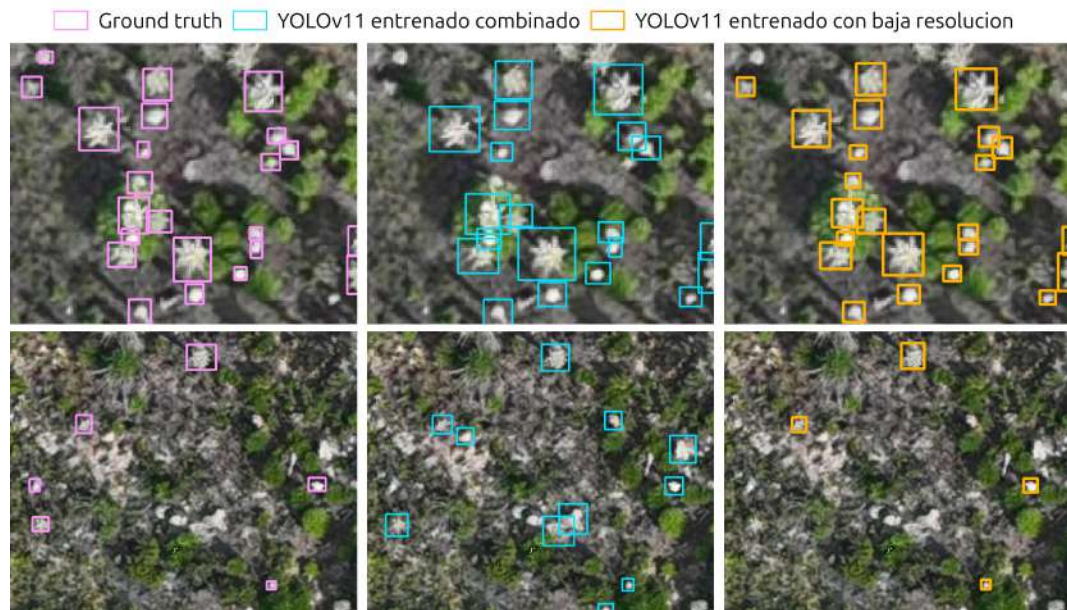


Figura 19. Resultados cualitativos de YOLOv11. Se muestran las etiquetas manuales (rosado), y la comparación entre el modelo entrenado con resoluciones mixtas (azul) y el entrenado únicamente con baja resolución (naranja).

mientras que en el de baja resolución (GSD = 3.6 cm) se identificaron 5,608. Esta diferencia del 9.8% corresponde a 610 frailejones que no fueron detectados en el mosaico de menor resolución, lo cual se explica por la menor sensibilidad del modelo en este tipo de imágenes. Esto está relacionado con el tamaño mínimo de las rosetas que pueden ser reconocidas a diferentes resoluciones.

La Figura 20 muestra la distribución de diámetros de las rosetas detectadas en ambos escenarios. En la misma área, las imágenes de alta resolución permiten detectar rosetas con diámetros mayores a 15 cm, mientras que en las de baja resolución solo se identifican aquellas con diámetros superiores a 30 cm. Es importante resaltar que los individuos más pequeños, con rosetas en etapas tempranas de crecimiento y diámetros de apenas unos pocos centímetros, no logran ser detectados en ninguno de los casos, a pesar de que aportan información clave sobre los procesos de regeneración del páramo.




Figura 20. Distribución de diámetros de rosetas detectadas por el modelo en imágenes de alta y baja resolución. El diámetro se estimó a partir del área de cada máscara de segmentación, asumiendo la forma de un círculo.

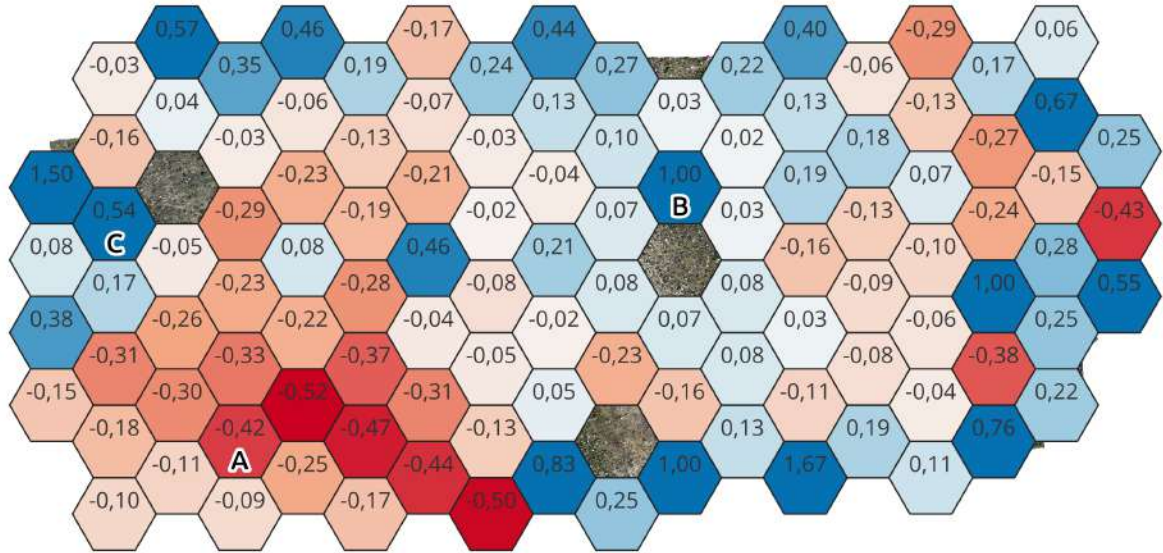
Para profundizar en las diferencias entre ambas resoluciones y visualizar su distribución espacial, en la Figura 21 se presentan los errores relativo (Ecuación (7)) y absoluto (Ecuación (8)), calculados en celdas de 20 m × 20 m. En este análisis se conserva el signo del error, de modo que valores negativos indican una mayor detección en el ortomosaico de alta resolución, mientras que valores positivos señalan una mayor detección en el de baja resolución.

$$Error\ relativo = \frac{(Frailejones\ baja\ resolución - Frailejones\ alta\ resolución)}{Frailejones\ alta\ resolución} \quad (7)$$

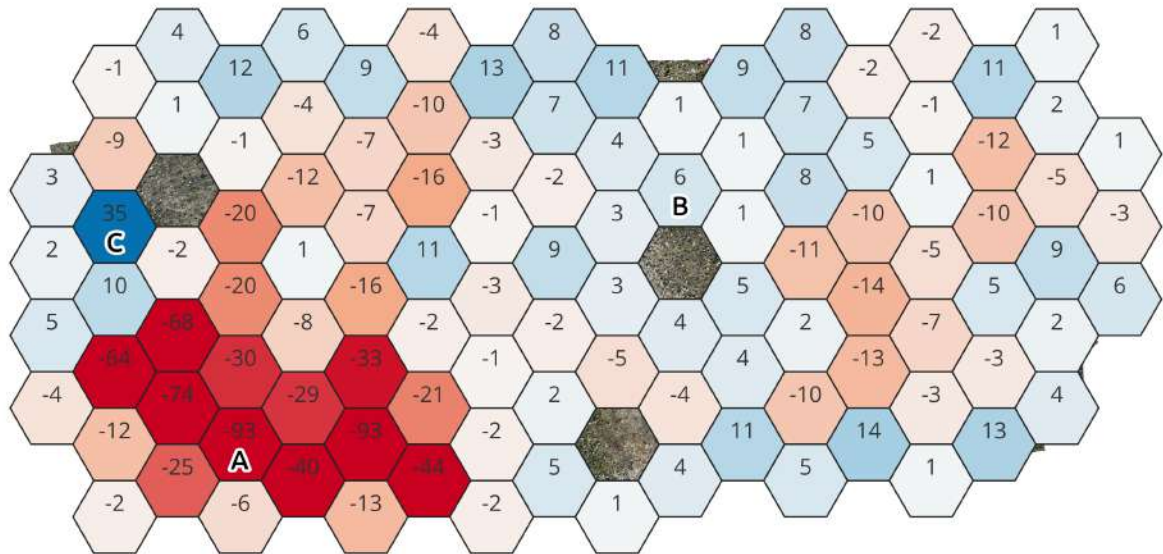
$$Error\ absoluto = (Frailejones\ baja\ resolución - Frailejones\ alta\ resolución) \quad (8)$$

Las discrepancias en el número de frailejones detectados no se distribuyen de manera homogénea en toda el área y responden a condiciones locales, como se ilustra en la Figura 22: (A) en zonas con alta densidad de frailejones, la baja resolución ocasiona la omisión de un mayor número de individuos; (B) en áreas con presencia de esfagnos secos o rocas se incrementan los falsos positivos; y (C) factores asociados a la calidad de la imagen, como la nubosidad, también afectan la detección.

Error relativo de detección de frailejones entre baja y alta resolución.



Error absoluto de detección de frailejones entre baja y alta resolución.



Mayor detección en alta resolución  Mayor detección en baja

Figura 21. Comparación de detección en imágenes de baja y alta resolución: (arriba) error relativo; (abajo) error absoluto. Celdas azules indican mayor detección en baja resolución y rojas en alta resolución.




Figura 22. Ejemplos de diferencias en la detección de frailejones entre mosaicos de alta (GSD 1.3 cm) y baja resolución (GSD 3.6 cm). (A) Dificultad del modelo para detectar frailejones muy próximos entre sí en baja resolución. (B) Falsos positivos en baja resolución por confusión del modelo con rocas o esfagno seco. (C) Zonas donde factores externos a la resolución influyen como la presencia de nubes en la imagen de alta resolución.

4.3. RESULTADOS DE CLASIFICACIÓN DE FRAILEJONES

Para evaluar los dos métodos propuestos para clasificación no supervisada en un conjunto de datos más amplio, se utilizó nuevamente el área de tres hectáreas captada en diciembre de 2024, descrita en la sección anterior. En el caso del método basado en PCA y K-Means, los resultados de la clasificación (Figura 23) muestran que, al aumentar el número de individuos, la separación entre clases deja de ser tan evidente. No obstante, la exactitud de 93.5 % se mantiene en los datos de alta resolución. En contraste, en las imágenes de baja resolución el agrupamiento generado por K-Means no corresponde con la separación observada en los datos anotados en campo, obteniendo un exactitud muy baja de 52.63 %, lo que evidencia la poca confiabilidad de este método en este escenario, especialmente cuando no se dispone de información de referencia para interpretar los resultados.

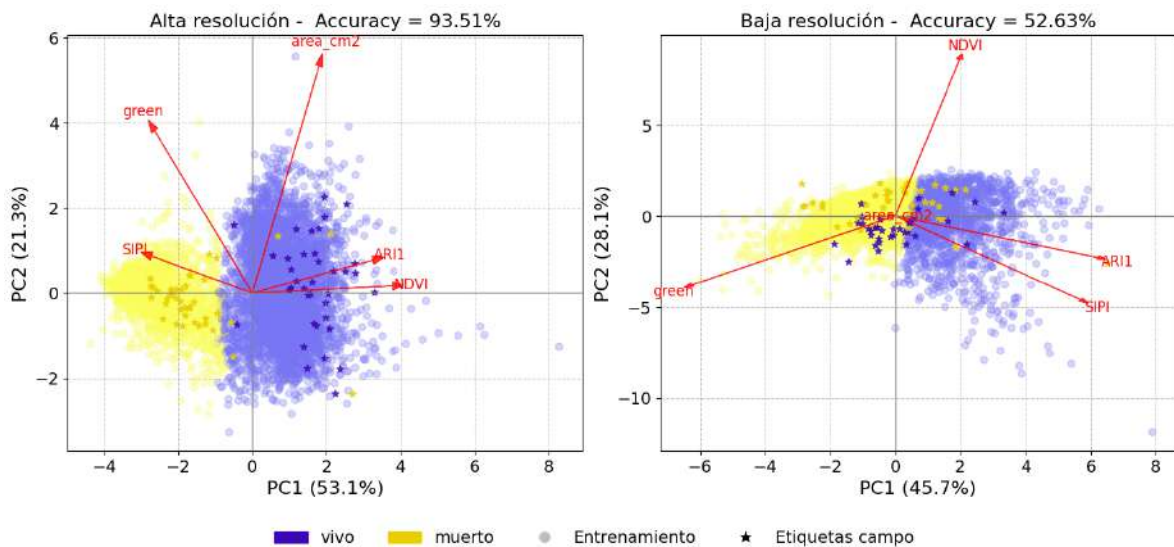


Figura 23. Agrupamiento y clasificación con PCA y K-Means en un conjunto de datos obtenido de imágenes de alta resolución (izquierda) y baja resolución (derecha).

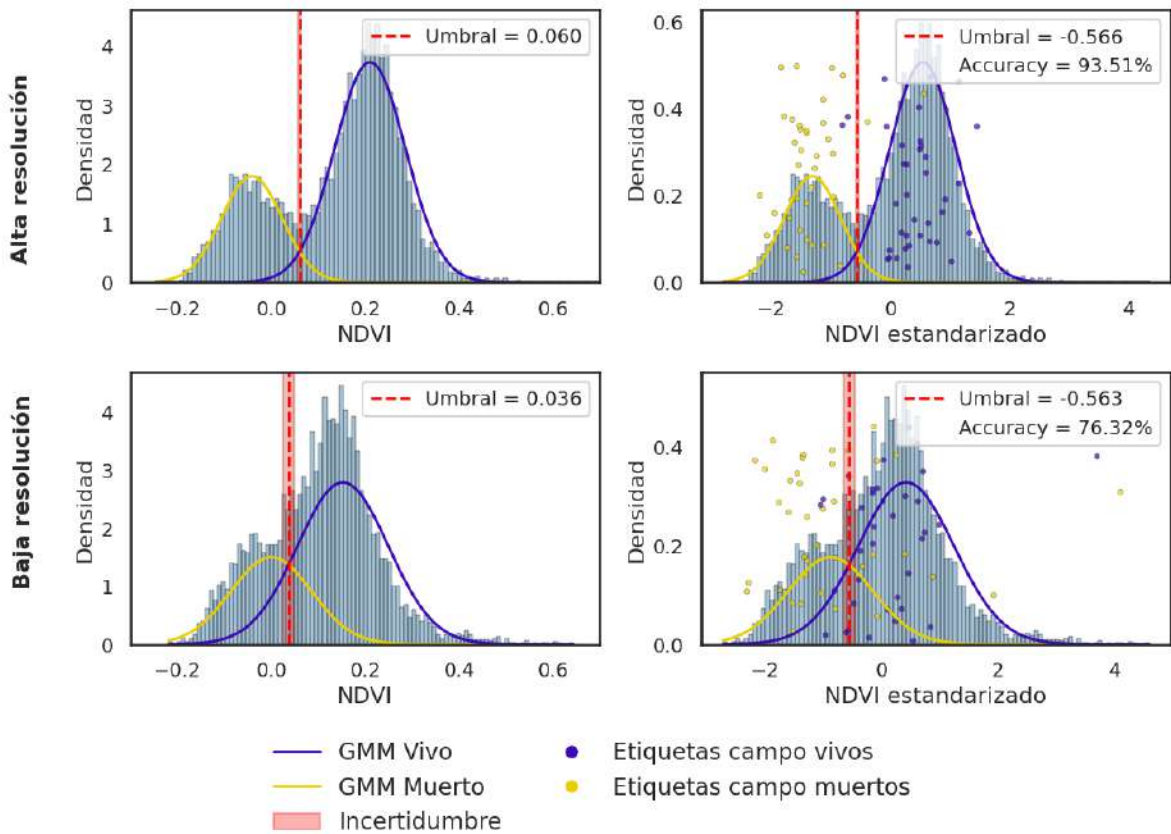


Figura 24. Histogramas de frailejones detectados en ortomosaicos de alta (GSD 1.3cm) y baja resolución (GSD 3.6cm) captados en diciembre de 2024. Se muestra la selección del umbral estadístico mediante un modelo de mezcla gaussiana (GMM) de dos componentes. La línea roja discontinua marca el umbral, y la franja sombreada ($\pm 10\%$) la incertidumbre. La bimodalidad es más clara en alta resolución. En los histogramas estandarizados, los umbrales entre resoluciones resultan estadísticamente más comparables.

Por otro lado, el método basado en el umbral estadístico de NDVI se caracteriza por su simplicidad y fácil interpretación. Como se muestra en la Figura 24, al aumentar el tamaño del conjunto de datos, la distribución de valores de NDVI en las imágenes de alta resolución sigue presentando una bimodalidad marcada. No obstante, en las imágenes de baja resolución esta tendencia se atenúa, lo que dificulta la selección de un umbral confiable, también se observa un corrimiento en los valores de NDVI. Estas diferencias pueden explicarse por dos factores principales: (i) la menor re-

solución espacial, que incrementa la mezcla espectral entre frailejones, vegetación circundante y suelo en el mosaico de baja resolución, suavizando la separación entre clases (Figura 25); y (ii) las variaciones en las condiciones de iluminación o nubosidad entre vuelos, que generan un corrimiento en los valores de NDVI.

En este estudio nos concentramos en la segunda causa, relacionada con los corrimientos en los valores de NDVI. Para mitigar este efecto, proponemos calcular el umbral de clasificación en el mosaico de alta resolución, donde la incertidumbre es menor, y transferirlo al mosaico de baja resolución. Con el fin de asegurar la comparabilidad, se aplica un proceso de estandarización que normaliza los valores de NDVI y permite trasladar de manera más confiable el umbral entre mosaicos con distinta resolución espacial.

En la Figura 24 se muestra la distribución estandarizada y sin estandarizar de valores de NDVI en imágenes de alta y baja resolución; y los umbrales calculados en la intersección de las distribuciones obtenidas del GMM. Para comparar la diferencia se emplea el error relativo (Ecuación (9)).

$$\frac{|Umbral\ baja\ resolución - Umbral\ alta\ resolución|}{Umbral\ alta\ resolución} \cdot 100\% \quad (9)$$

Para histogramas sin estandarizar el error relativo es de 40 %, mientras que en los histogramas estandarizados es de tan solo 0.5 %. Esto nos indica que es posible transferir el umbral de alta resolución al de baja, cuando ambos se estandarizan, sin afectar la clasificación de mortalidad, y disminuyendo así la incertidumbre de la selección del umbral.

Aun así, la exactitud de clasificación en baja resolución continúa siendo menor que en alta resolución (76.32 % frente a 93.5 %, según la comparación con los individuos anotados en campo). Esta diferencia se debe principalmente al problema de la mezcla espectral. Un ejemplo se observa en la Figura 26, donde algunos frailejones clasificados como muertos en alta resolución aparecen como vivos en baja resolución.

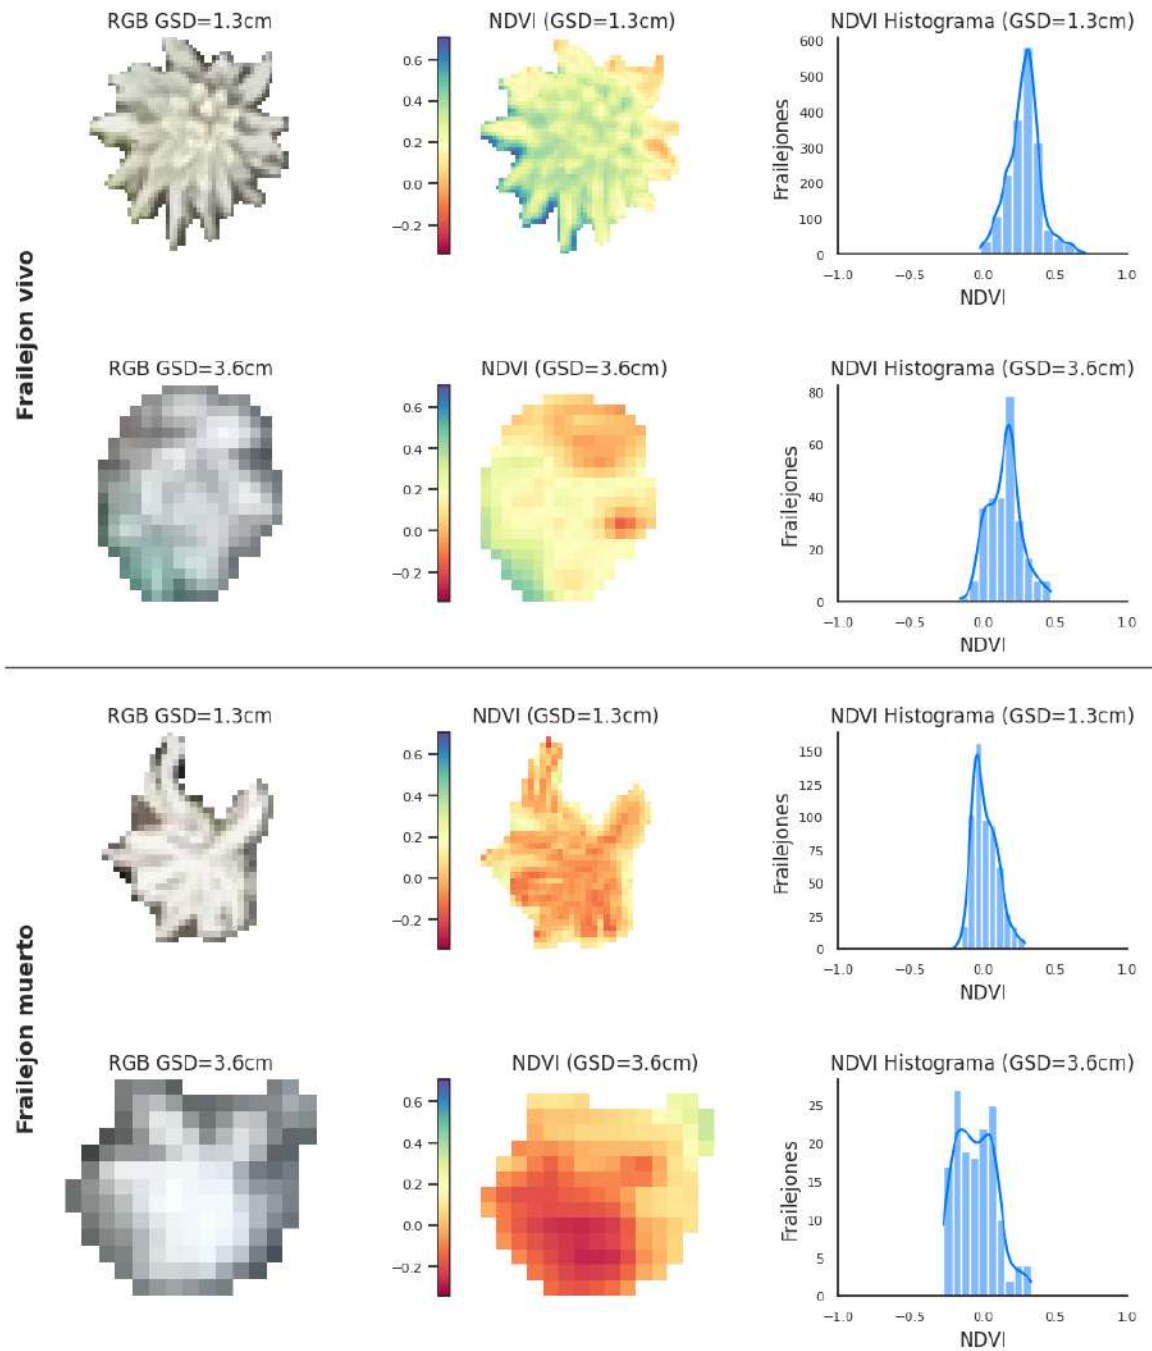


Figura 25. Mezcla espectral para frailejones vivos y muertos a diferente resolución. Se comparan los mismos dos frailejones: uno vivo, y otro muerto, a diferentes resoluciones en términos de GSD.

Aunque la segmentación en RGB parece correcta, los valores de NDVI muestran un “corrimiento” atribuible a la influencia de píxeles circundantes. Estas limitaciones, sumadas a las diferencias en detección discutidas en la sección anterior, reflejan las restricciones inherentes a la resolución espacial y subrayan la necesidad de futuros estudios orientados a desarrollar estrategias para mejorar tanto la clasificación como la detección en imágenes de baja resolución.




Figura 26. Errores de clasificación en imágenes de baja resolución debido a mezcla espectral de los píxeles de la roseta con vegetación circundante o suelo.

4.4. RESULTADOS DE MORTALIDAD

A continuación, se presentan los resultados de aplicar el flujo de procesamiento propuesto a distintos ortomosaicos, utilizando el modelo de detección con mejor desempeño en la validación y el umbral estadístico de NDVI para la clasificación. El Cuadro 5 resume el número total de frailejones detectados, los individuos muertos

Resolución	Ortomosaico	Área	Frailejones	Muertos	Mortalidad
Alta resolución	Agosto 2024 (GSD 1.5cm)	3.2 ha	6,013	≈2,194	35 - 37 %
	Diciembre 2024 (GSD 1.3cm)	3.8 ha	6,218	≈1,797	28 - 29 %
	Junio 2025 (GSD 1.1cm)	3.8 ha	5,804	≈1,342	23 %
Baja resolución	Diciembre 2024 (GSD 3.6cm)	83 ha	86,026	≈ 29,860	30 - 40 %

Cuadro 5. Resultados de mortalidad en los ortomosaicos seleccionados para la realización del proyecto. Se abarca una mayor área en baja resolución ya que el dron vuela a mayor altura.

y la mortalidad estimada en cada caso. Esta última se reporta como un rango, ya que pequeñas variaciones en el umbral modifican la asignación de individuos a las categorías de vivos o muertos. Con base en estos resultados, se desarrollan dos análisis: uno espacial, sobre la distribución de individuos en un área extensa del páramo, y otro temporal, comparando ortomosaicos captados en diferentes momentos.

4.4.1 Análisis espacial de la mortalidad

El ortomosaico con mayor cobertura de la zona afectada por el incendio corresponde a diciembre de 2024. Este abarca 83 hectáreas de páramo y fue capturado en baja resolución (GSD de 3.6 cm). En esta área se detectaron 86,026 individuos con diámetro de roseta superior a 20 cm. Utilizando los umbrales de clasificación mostrados en la Figura 27, la mortalidad estimada con el umbral calculado en alta resolución es del 30 %, mientras que con el umbral obtenido mediante el GMM alcanza el 40 %. En consecuencia, la mortalidad en esta zona se encuentra entre el 30 % y el 40 %, lo que equivale a entre 25,836 y 34,099 individuos muertos, pro-

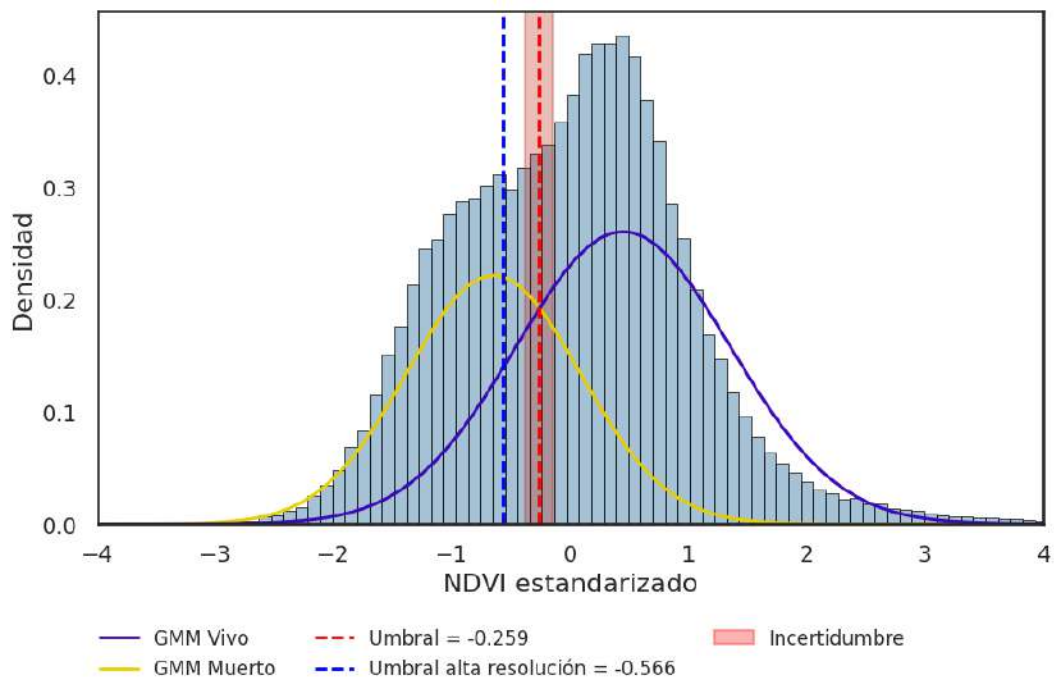


Figura 27. Distribución del NDVI estandarizado en el área afectada por el incendio. Se muestran las distribuciones Gaussianas utilizadas en la estimación del umbral para la resolución del ortomosaico analizado (línea discontinua roja) y el umbral derivado del mosaico de alta resolución utilizado como referencia para la clasificación (línea discontinua azul). La franja sombreada en rojo es la zona de incertidumbre.

bablemente como resultado del estrés post-incendio asociado al evento ocurrido a comienzos de ese año. En la Figura 28 se presenta la distribución del diámetro de las rosetas de los frailejones detectados. Se observa que los individuos clasificados como muertos tienden a presentar diámetros menores, lo cual puede asociarse a la pérdida de vigor en las hojas, que reduce el tamaño de la roseta.

En la Figura 29 se presenta la distribución de los individuos detectados, vivos y muertos mediante un mapa de densidad construido con hexágonos de 20 × 20 metros. Estos mapas sugieren la presencia de patrones espaciales marcados en la mortalidad y supervivencia de los individuos, así como zonas con mayor abundancia de frailejones. No obstante, se requieren estudios adicionales para comprender las causas de estas distribuciones, que podrían estar asociadas con variaciones

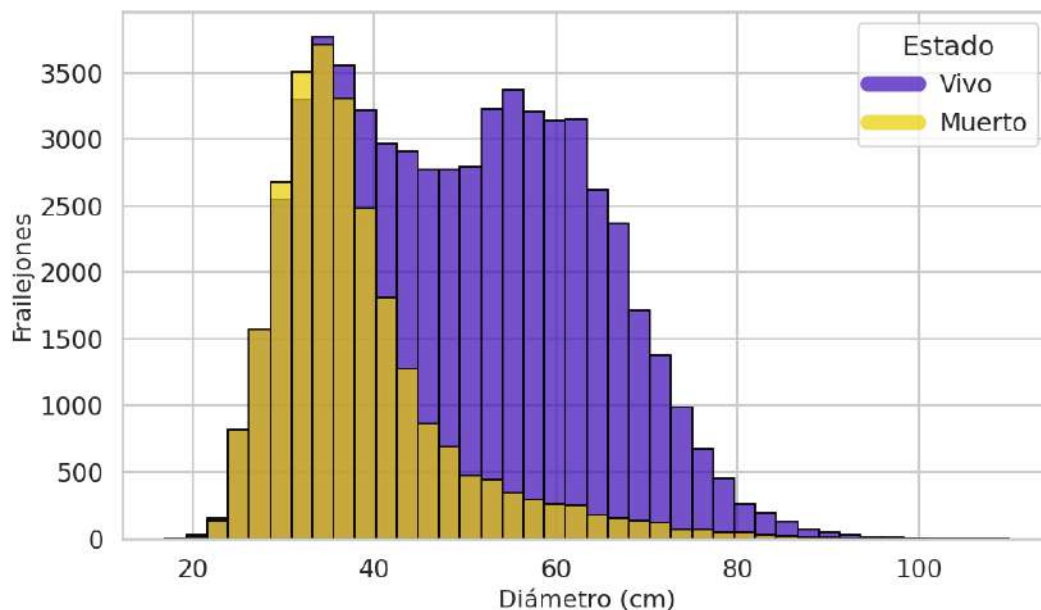


Figura 28. Distribución del diámetro de rosetas clasificadas como vivas o muertas, en unidades de centímetros, de más de 86,000 frailejones.

en la intensidad del fuego, la historia del uso del suelo, diferencias en la cobertura vegetal, la edad de los individuos, la topografía, el flujo del agua u otros factores ambientales.

4.4.2 Análisis temporal de la mortalidad

Aplicando el flujo de procesamiento a los tres ortomosaicos de alta resolución correspondientes a agosto y diciembre de 2024, y junio de 2025, se obtienen los resultados que se muestran en la Figura 30: los histogramas de NDVI dentro de las rosetas detectadas y la ubicación espacial de los frailejones.

Para el área del 30 de agosto de 2024, el histograma no presenta una separación clara entre individuos vivos y muertos, probablemente porque seis meses después del incendio el deterioro post-incendio aún no era evidente. En este caso, la clasificación directa en dos categorías puede resultar imprecisa y sería más adecuado

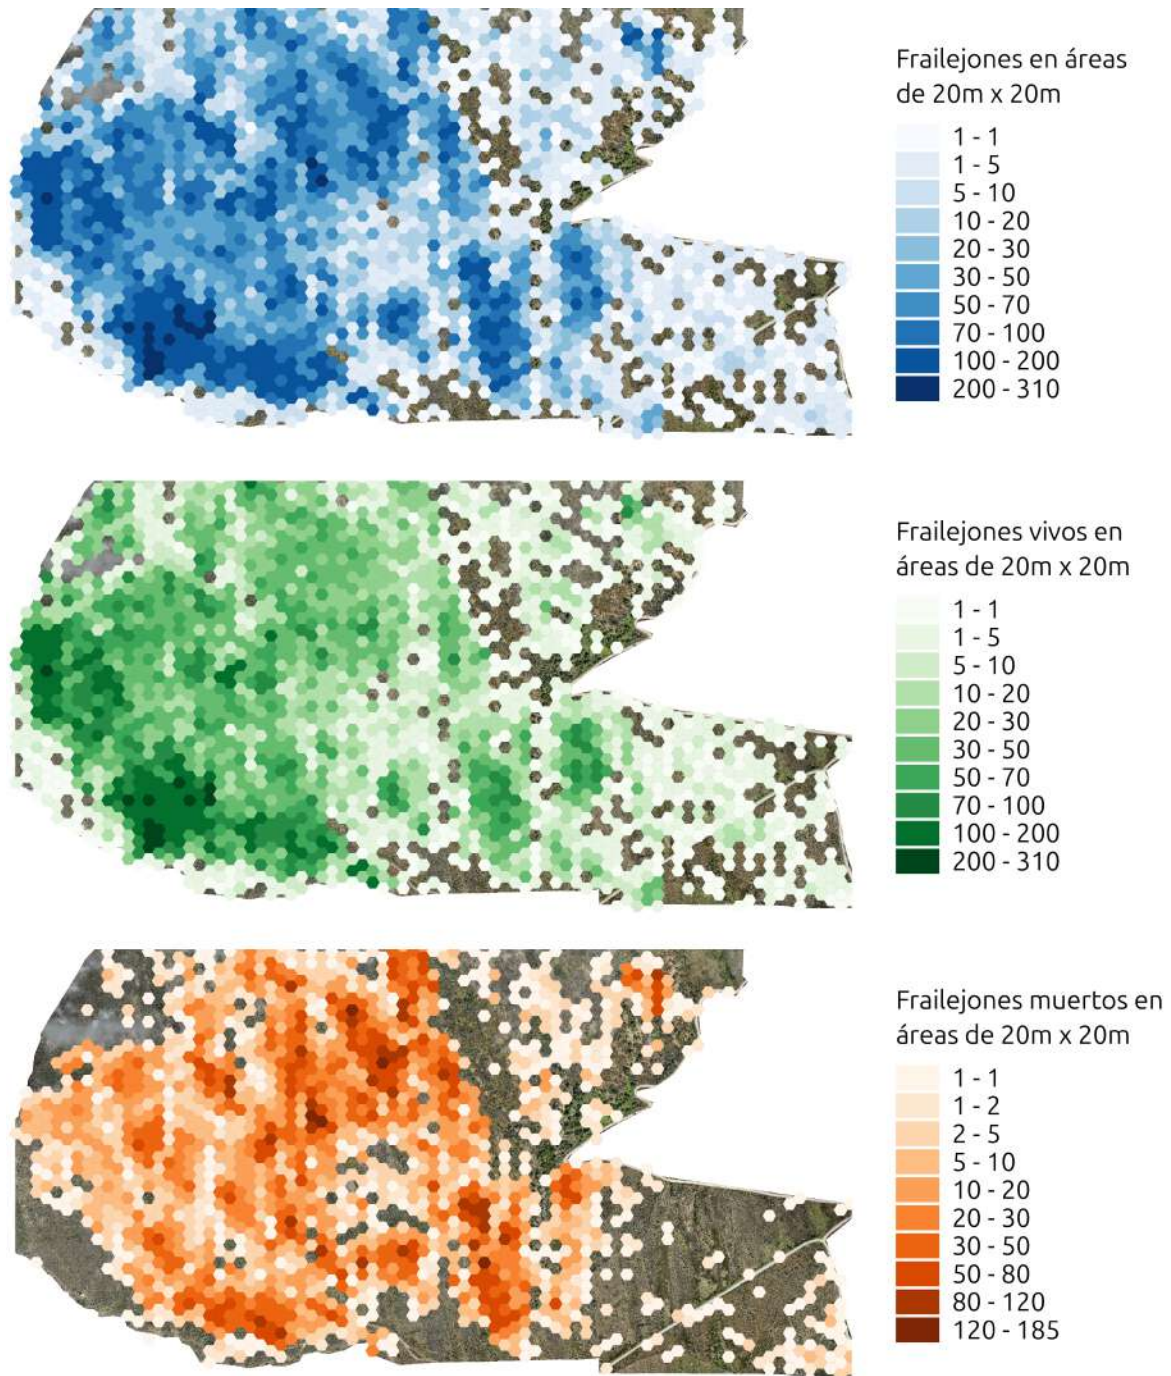


Figura 29. Mapas de un área de 83 hectáreas con presencia de frailejones, y distribución de frailejones vivos y muertos un año después del incendio.

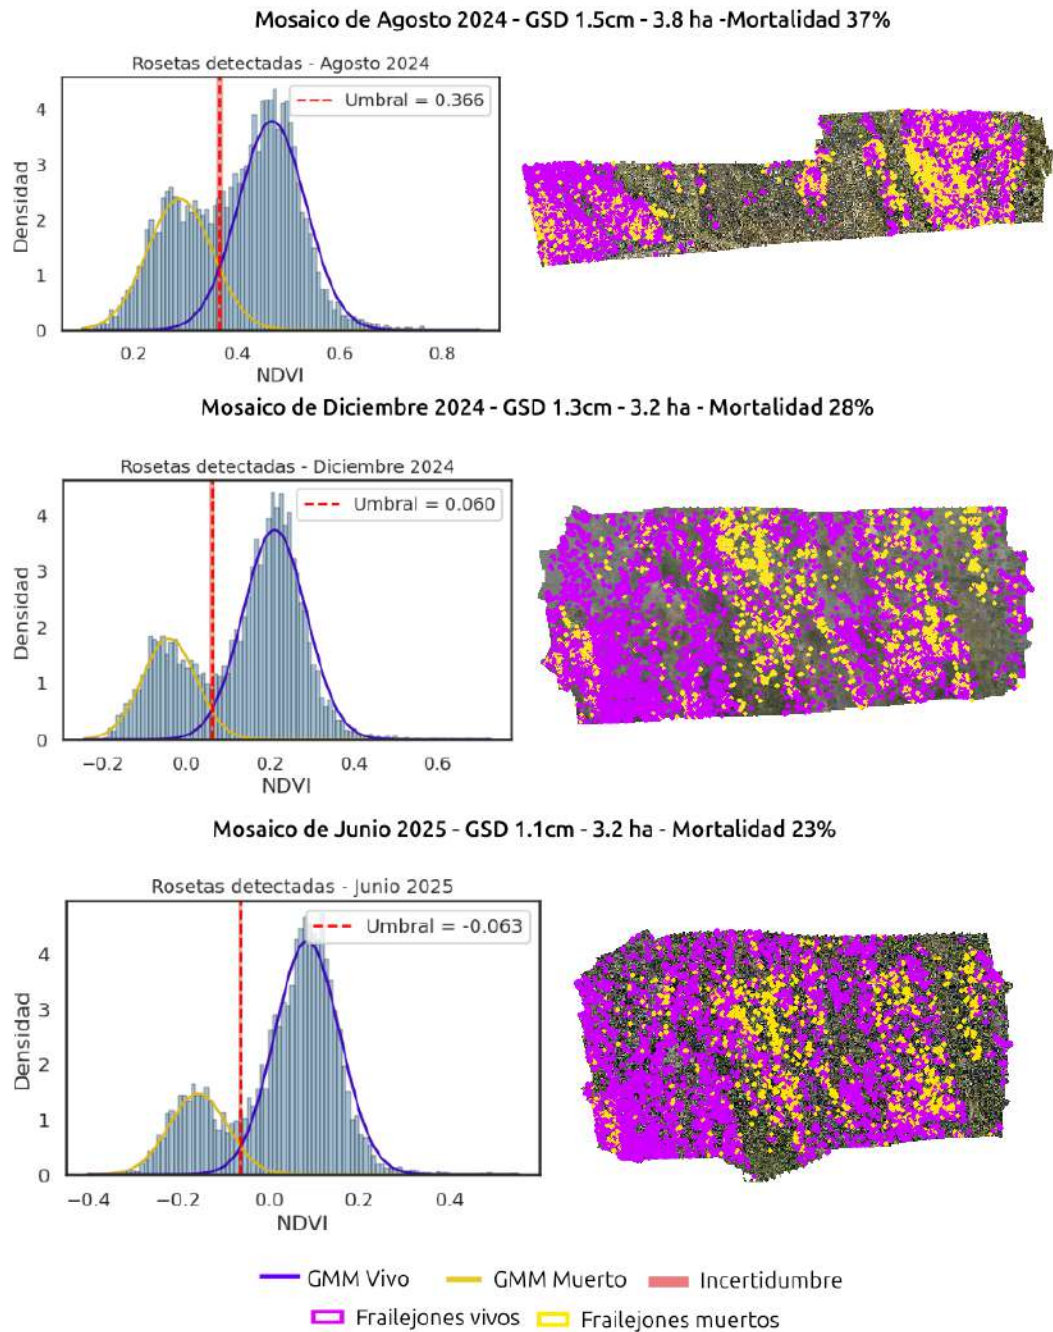


Figura 30. Histograma y mapas de mortalidad de los frailejones en las áreas registradas en alta resolución.

incluir estados intermedios como enfermos o en riesgo.

Por otro lado, los ortomosaicos de diciembre de 2024 y junio de 2025 muestran




Figura 31. Diferencia entre frailejones vivos con diámetro de roseta mayor a 15cm detectados entre diciembre de 2024 y junio de 2025 en áreas de 20m x 20m para una misma región. Valores más negativos (rojo) indican que se detectaron más frailejones vivos en diciembre de 2024, mientras que, valores más positivos (azul) indican una mayor cantidad de vivos en junio de 2025. Ejemplos de los cambios ocurridos en este lapso de seis meses se ilustran en: (A) Frailejones reportados como vivos, mueren. (B) Frailejones previamente clasificados como muertos dejan de ser detectados, ya que están demasiado deteriorados. (C) Frailejones vivos se vuelven visibles por cambios en la cobertura o condiciones de la imagen.

una distribución claramente bimodal en los valores de NDVI de las rosetas. Ya que ambos cubren un área en común de aproximadamente 3 hectáreas, en la Figura 31

Ortomosaico	Diciembre 2024	Junio 2025	Diferencia
Frailejones Vivos	3540	3800	+ 260
Frailejones Muertos	1535	1315	- 220
Total	5075	5115	+ 40

Cuadro 6. Frailejones detectados vivos y muertos en una misma área con una diferencia temporal de 6 meses, entre diciembre de 2024 y junio de 2025.

se presenta la variación en el número de frailejones vivos en esta área calculada por hexágonos de 20 × 20 metros y en el Cuadro 6 se presentan el número de individuos totales detectados, vivos y muertos en cada fecha.

Aunque en algunas celdas se observa una disminución en el número de individuos vivos, asociada a frailejones que murieron entre diciembre de 2024 y junio de 2025 (ejemplo en la Figura 31 A), el balance general muestra un aumento en los individuos vivos detectados. En junio se identificaron 260 frailejones vivos adicionales con diámetro >15 cm, lo que corresponde al 6.7 % de los individuos vivos registrados en esa fecha. Estos nuevos registros corresponden a rosetas que seis meses antes eran demasiado pequeñas o estaban parcialmente ocultas por las condiciones del paisaje (Figura 31 C).

En contraste, el balance de los individuos muertos fue negativo. Esto se debe a que algunos frailejones clasificados como muertos en diciembre de 2024 se degradaron hasta desaparecer y ya no fueron detectados en junio de 2025 (ejemplo en la Figura 31 B). Sin embargo, aún se requiere mayor investigación para precisar, entre los individuos identificados como muertos, qué proporción corresponde a nuevas muertes ocurridas en el periodo de seis meses y cuál a desapariciones producto de la degradación.

En conjunto, los resultados indican que la mortalidad no aumentó significativamente durante este periodo, mientras que la regeneración y el crecimiento superaron la pérdida de individuos. Cabe subrayar que la metodología utilizada únicamente

contabiliza frailejones con diámetro superior a 15 cm, por lo que las rosetas más pequeñas, que representan los primeros estadios de crecimiento, no pueden ser detectadas por el modelo. Por lo que se enfatiza la necesidad de estudios adicionales para monitorear la regeneración de frailejones en el páramo tras el incendio.

5. CONCLUSIONES

Este trabajo presenta un método basado en técnicas de inteligencia artificial para estimar la mortalidad de frailejones tras un incendio, utilizando imágenes multiespectrales captadas por dron. El flujo de procesamiento propuesto, basado en la detección, segmentación y clasificación del estado de las plantas mediante un umbral de NDVI, permite realizar análisis sobre grandes extensiones de páramo, monitoreando de forma individual miles de ejemplares y complementando eficientemente el trabajo de campo. El modelo de detección de objetos entrenado para identificar frailejones mostró un buen equilibrio entre precisión y sensibilidad, mientras que la segmentación *zero-shot* se evidenció como una etapa útil de preprocesamiento para mejorar la clasificación. A su vez, la clasificación basada en un umbral de NDVI se adoptó por ser el método más simple y fácil de interpretar a la vez que conseguía una buena exactitud. No obstante, se evidenció que la capacidad de detección y clasificación de los frailejones depende fuertemente de la resolución de las imágenes. El flujo de procesamiento propuesto permitió realizar un análisis temporal de la mortalidad en un lapso de seis meses, entre diciembre de 2024 y junio de 2025. Los resultados muestran que el crecimiento de los frailejones superó la mortalidad, con un 6.7% de nuevas rosetas vivas de más de 15 cm de diámetro registradas durante este intervalo. La metodología también hizo posible evaluar casi la totalidad del área afectada por el incendio un año después del evento: en 83 hectáreas de páramo se detectaron aproximadamente 86.000 frailejones con rosetas de más de 20 cm de diámetro, de los cuales entre un 30% y un 40% presentaron mortalidad posiblemente asociada al estrés provocado por el fuego. Este estudio evidencia el potencial del uso combinado de drones e inteligencia artificial para apoyar el análisis ecológico de disturbios como los incendios y subraya la proyección futura de este enfoque para el monitoreo continuo de los páramos y de especies clave como los frailejones.

6. TRABAJO FUTURO

A partir de los resultados obtenidos, surgen nuevas preguntas sobre la resiliencia de los frailejones y del ecosistema de páramo frente a perturbaciones como los incendios. Como líneas de trabajo futuro, se propone explorar la relación entre la mortalidad de los individuos y variables como su altura, ubicación espacial o características topográficas del terreno. Asimismo, un análisis temporal que integre condiciones atmosféricas podría aportar evidencia sobre los factores que influyen en la supervivencia de los frailejones tras eventos de perturbación. En cuanto a la regeneración de los frailejones, esta metodología permite cuantificar la mortalidad causada por el incendio y evaluar su variación en el tiempo. Sin embargo, no contempla las plantas más pequeñas en etapas tempranas de crecimiento, por lo que para estudiar los procesos de regeneración será necesario aplicar otros métodos. En cuanto a la metodología, existen varias oportunidades de mejora. El modelo de detección podría optimizarse para aumentar su capacidad de generalización en imágenes de menor resolución espacial. De igual forma, el método de clasificación puede refinarse para mejorar la exactitud en baja resolución e incluso aprovechar mejor la información de los píxeles segmentados de cada planta, con el fin de incorporar categorías adicionales como individuos enfermos o en riesgo. Otra dirección prometedora consiste en desarrollar un modelo integrado que combine detección y clasificación, utilizando directamente las bandas espectrales como entrada. Finalmente, extender el muestreo a otros páramos permitiría entrenar modelos más generalistas, aplicables a distintas especies de frailejones y condiciones ecológicas. Alternativamente, esta metodología podría adaptarse para estudiar otros grupos funcionales de plantas, ampliando su utilidad en contextos de monitoreo y conservación de ecosistemas de alta montaña.

BIBLIOGRAFÍA

Agisoft LLC. *Agisoft Metashape*. Version 1.6.5, available at: <https://www.agisoft.com/>. 2020 (vid. págs. 24, 32).

Baudchon, H. et al. *SelvaBox: A high-resolution dataset for tropical tree crown detection*. 2025. arXiv: 2507.00170 [cs.CV] (vid. págs. 25, 40).

Bradski, G. «The OpenCV Library». En: *Dr. Dobb's Journal of Software Tools* (2000) (vid. pág. 55).

Buytaert, W. et al. «Cambio climático: la nueva amenaza para los páramos». En: *Avances en investigación para la conservación de los páramos andinos. CONDESAN, Lima* (2014) (vid. pág. 21).

Cárdenas, M. et al. «Ecophysiology of frailejones (*Espeletia* spp.), and its contribution to the hydrological functioning of páramo ecosystems». En: *Plant Ecology* 219 (2018), págs. 185-198 (vid. págs. 15, 21).

Carion, N. et al. «End-to-end object detection with transformers». En: *European Conference on Computer Vision*. Springer. 2020, págs. 213-229 (vid. pág. 39).

Deliry, S. y U. Avdan. «Accuracy of unmanned aerial systems photogrammetry and structure from motion in surveying and mapping: a review». En: *Journal of the Indian Society of Remote Sensing* 49.8 (2021), págs. 1997-2017 (vid. pág. 24).

Dempster, A., N. Laird y D. Rubin. «Maximum Likelihood from Incomplete Data Via the EM Algorithm». en. En: *Journal of the Royal Statistical Society Series B: Statisti-*

cal Methodology 39.1 (sep. de 1977), págs. 1-22. DOI: 10.1111/j.2517-6161.1977.tb01600.x (vid. pág. 49).

DJI. *Mavic 3 Multispectral*. DJI Agriculture. Retrieved February 22, 2025 (vid. pág. 32).

Dosovitskiy, A. et al. «An image is worth 16x16 words: Transformers for image recognition at scale». En: *arXiv preprint arXiv:2010.11929* (2020) (vid. pág. 39).

(ESA), Agencia Espacial Europea. *Imagen de Sentinel-2 del Copernicus Data Hub*. Accedido: 2025-04-21. 2025.

Geng, T. et al. «Research on Segmentation Method of Maize Seedling Plant Instances Based on UAV Multispectral Remote Sensing Images». En: *Plants* 13.13 (2024). DOI: 10.3390/plants13131842 (vid. pág. 25).

Gitelson A. and Merzlyak, M. y O. Chivkunova. «Optical properties and nondestructive estimation of anthocyanin content in plant leaves». En: *Photochemistry and photobiology* 74.1 (2001), págs. 38-45 (vid. pág. 28).

Glenn, J., C. Ayush y Q. Jing. *Ultralytics YOLOv8*. Ver. 8.0.0. 2023 (vid. pág. 39).

Goldstein, G. y F. Meinzer. «Influence of insulating dead leaves and low temperatures on water balance in an Andean giant rosette plant». En: *Plant, Cell & Environment* 6.8 (1983), págs. 649-656 (vid. pág. 22).

He, K. et al. «Mask R-CNN». En: *Proceedings of the IEEE International Conference on Computer Vision (ICCV)*. 2017 (vid. pág. 39).

Huang, S. et al. «A commentary review on the use of normalized difference vegetation index (NDVI) in the era of popular remote sensing». En: *Journal of forestry research* 32.1 (2021), págs. 1-6 (vid. pág. 27).

Joher, G. y J. Qiu. *Ultralytics YOLO11*. Ver. 11.0.0. 2024 (vid. págs. 17, 38).

Khanam, R. y M. Hussain. «Yolov11: An overview of the key architectural enhancements». En: *arXiv preprint arXiv:2410.17725* (2024) (vid. pág. 39).

Kriegler, F. «Preprocessing transformations and their effects on multispectral recognition». En: *Proceedings of the sixth international symposium on remote sensing of environment*. 1969, págs. 97-131 (vid. pág. 26).

Liang, C. et al. «Enhanced visual detection of litchi fruit in complex natural environments based on unmanned aerial vehicle (UAV) remote sensing». En: *Precision Agriculture* 26.1 (2025), pág. 23 (vid. pág. 25).

Lloyd, S. «Least squares quantization in PCM». En: *IEEE Transactions on Information Theory* 28.2 (1982), págs. 129-137. DOI: 10.1109/TIT.1982.1056489 (vid. pág. 47).

Murad, C., J. Pearse y C. Huguet. «Multitemporal monitoring of paramos as critical water sources in Central Colombia». En: *Scientific Reports* 14.1 (2024), pág. 16706 (vid. pág. 21).

Pearson, K. «Contributions to the Mathematical Theory of Evolution». En: *Philosophical Transactions of the Royal Society of London. A* 185 (1894), págs. 71-110 (vid. pág. 48).

Pearson, K. «On lines and planes of closest fit to systems of points in space». En: *The London, Edinburgh, and Dublin Philosophical Magazine and Journal of Science* 2.11 (1901), págs. 559-572. DOI: 10.1080/14786440109462720 (vid. pág. 47).

Pedregosa, F. et al. «Scikit-learn: Machine Learning in Python». En: *Journal of Machine Learning Research* 12 (2011), págs. 2825-2830 (vid. págs. 47, 49).

Penuelas, J., F. Baret, I. Filella et al. «Semi-empirical indices to assess carotenoids/chlorophyll a ratio from leaf spectral reflectance». En: *Photosynthetica* 31.2 (1995), págs. 221-230 (vid. pág. 28).

Rada, F et al. «Supercooling along an Altitudinal Gradient in *Espeletia schultzei*, a Caulescent Giant Rosette Species». En: *Journal of Experimental Botany* 38.3 (mar. de 1987), págs. 491-497. DOI: 10.1093/jxb/38.3.491. eprint: <https://academic.oup.com/jxb/article-pdf/38/3/491/1193668/38-3-491.pdf> (vid. pág. 21).

Ramsay, P. «Giant rosette plant morphology as an indicator of recent fire history in Andean páramo grasslands». En: *Ecological Indicators* 45 (2014), págs. 37-44 (vid. págs. 15, 23).

Ramsay, P. «Páramo vegetation recovery in the first two years after a fire on Volcán Chiles, Ecuador». En: *The Ecology of Volcán Chiles: high-altitude ecosystems on the Ecuador-Colombia border* (2001), págs. 65-73 (vid. pág. 23).

Raniga, D. et al. «Monitoring of Antarctica's fragile vegetation using drone-based remote sensing, multispectral imagery and AI». En: *Sensors* 24.4 (2024), pág. 1063 (vid. pág. 27).

Ravi, N. et al. *SAM 2: Segment Anything in Images and Videos*. 2024. arXiv: 2408.00714 [cs.CV] (vid. págs. 17, 25).

Redmon, J. et al. «You only look once: Unified, real-time object detection». En: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. 2016, págs. 779-788 (vid. pág. 39).

Selvaraj, M. et al. «Detection of banana plants and their major diseases through aerial images and machine learning methods: A case study in DR Congo and Republic of Benin». En: *ISPRS Journal of Photogrammetry and Remote Sensing* 169 (2020), págs. 110-124 (vid. pág. 27).

Septer, Q. *Unprecedented Fire Season Has Raged Through One of Earth's Biodiversity Hotspots*. <https://www.scientificamerican.com/article/unprecedented-fire-season-has-raged-through-one-of-earths-biodiversity-hotspots/>. Accessed: 2025-08-22. Feb. de 2024 (vid. pág. 15).

Shen, Y. et al. «Fast and accurate multi-class geospatial object detection with large-size remote sensing imagery using CNN and Truncated NMS». En: *ISPRS Journal of Photogrammetry and Remote Sensing* 191 (2022), págs. 235-249 (vid. pág. 37).

Smith, A. «Function of dead leaves in *Espeletia schultzei* (Compositae), and Andean caulescent rosette species». En: *Biotropica* (1979), págs. 43-47 (vid. pág. 22).

Softwel/Aviyaan Tech. *SW Maps - GIS Data Collector*. https://play.google.com/store/apps/details?id=np.com.softwel.swmaps&hl=es_CO. Available at: https://play.google.com/store/apps/details?id=np.com.softwel.swmaps&hl=es_CO. 2025 (vid. pág. 35).

Sun, Z. et al. «UAVs as remote sensing platforms in plant ecology: review of applications and challenges». En: *Journal of Plant Ecology* 14.6 (2021), págs. 1003-1023 (vid. págs. 17, 25).

Team, QGIS Development. *QGIS: Sistema de Información Geográfica*. Accedido: 2025-04-21. 2025 (vid. pág. 32).

Ullman, S. «The interpretation of structure from motion». En: *Proceedings of the Royal Society of London. Series B. Biological Sciences* 203.1153 (1979), págs. 405-426 (vid. pág. 24).

Verweij, P. y K. Kok. «Effects of fire and grazing on *Espeletia hartwegiana* populations». En: *Páramo. An Andean ecosystem under human influence. Academic, London, England* (1992), págs. 215-229 (vid. pág. 23).

Xue, J. y B. Su. «Significant remote sensing vegetation indices: A review of developments and applications». En: *Journal of sensors* 2017.1 (2017), pág. 1353691 (vid. pág. 27).

Yao, H., R. Qin y X. Chen. «Unmanned Aerial Vehicle for Remote Sensing Applications—A Review». En: *Remote Sensing* 11.12 (2019). DOI: 10.3390/rs11121443 (vid. págs. 15, 24, 25).

Yao, S. et al. «Individual Tree Crown Detection and Classification of Live and Dead Trees Using a Mask Region-Based Convolutional Neural Network (Mask R-CNN)». En: *Forests* 15.11 (2024), pág. 1900 (vid. pág. 27).

Zhang, C. et al. «Identifying and mapping individual plants in a highly diverse high-elevation ecosystem using UAV imagery and deep learning». En: *ISPRS Journal of Photogrammetry and Remote Sensing* 169 (2020), págs. 280-291 (vid. pág. 26).

Zhang, S. et al. «Banana Fusarium Wilt Disease Detection by Supervised and Un-supervised Methods from UAV-Based Multispectral Imagery». En: *Remote Sensing* 14.5 (2022). DOI: 10.3390/rs14051231 (vid. pág. 27).

Zhao, F. et al. «Smart UAV-assisted rose growth monitoring with improved YOLOv10 and Mamba restoration techniques». En: *Smart Agricultural Technology* 10 (2025), pág. 100730 (vid. pág. 25).

Zhao, Y. et al. «DETRs Beat YOLOs on Real-time Object Detection». En: *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. 2024, págs. 16965-16974 (vid. págs. 17, 39).

Zomer, M. y P. Ramsay. «Post-fire changes in plant growth form composition and diversity in Andean páramo grassland». En: *Applied Vegetation Science* 24.1 (2021), e12554 (vid. pág. 23).