


Perspectiva crítica

El papel de la IA en el combate a la infestación de muérdago en los bosques mexicanos: un llamado a la acción interdisciplinaria

Juan Carlos
Valdiviezo-Navarro 
CONAHCYT-CentroGeo,
Yucatán, Mexico

Mauricio G.
Orozco-del-Castillo 
Tecnológico Nacional de
México/IT de Mérida, Yucatán,
Mexico

This article has been published in both English and Spanish to ensure accessibility to a broader audience. The English version of this article can be accessed at the following DOI: <https://doi.org/10.5281/zenodo.14699764>.

Palabras clave: detección de muérdago, inteligencia artificial en conservación, herramientas de gestión ecológica

PERSPECTIVA

El muérdago es una planta hemiparásita que se adhiere a los árboles huéspedes, extrayendo agua y nutrientes, lo que debilita los árboles, reduce la biodiversidad y altera los servicios ecosistémicos críticos. Si bien a menudo se romantiza en contextos culturales, el muérdago plantea una grave amenaza ecológica, particularmente en los ecosistemas urbanos y boscosos donde las infestaciones pueden propagarse sin control. Este artículo examina el papel de la inteligencia artificial (IA) y la teledetección para abordar los desafíos de detección y gestión que plantea el muérdago. A través de una evaluación crítica de metodologías que van desde el aprendizaje automático basado en texturas hasta modelos avanzados de aprendizaje profundo como ResNet-34, este artículo reflexiona sobre los éxitos, las limitaciones y las implicaciones de estos enfoques. Nuestra investigación interdisciplinaria destaca el potencial transformador de combinar la IA con la experiencia ecológica para desarrollar herramientas escalables y eficientes para la conservación. Sin embargo, también identificamos desafíos clave, incluida la necesidad de acceso equitativo, consideraciones éticas y escalabilidad en diversos contextos ecológicos. Además, enfatizamos la importancia de involucrar a la comunidad en general, ya que los conceptos erróneos sobre el muérdago obstaculizan los esfuerzos de conservación. Al integrar la conciencia pública con los avances tecnológicos, abogamos por un enfoque equilibrado y sostenible para la gestión ecológica. Este documento tiene como objetivo provocar un diálogo crítico e inspirar estrategias viables para aprovechar la IA para abordar los desafíos de conservación global.

Introducción

Las infestaciones de muérdago representan un ejemplo localizado de un problema global más amplio: los desafíos ecológicos y socioeconómicos que plantean las especies de plantas invasoras. Estas especies, caracterizadas por su capacidad para establecerse y proliferar rápidamente en ecosistemas no nativos, tienen impactos significativos y de gran alcance. A nivel mundial, las plantas invasoras contribuyen a la pérdida de biodiversidad al superar a las especies nativas, alterar las redes alimentarias y alterar los servicios ecosistémicos [1, 2]. En este sentido, su

propagación puede comprometer el secuestro de carbono, la regulación de la temperatura y el mantenimiento del hábitat para la vida silvestre nativa, al tiempo que crea cargas socioeconómicas al afectar la agricultura, la silvicultura y la salud pública.

El muérdago es una planta hemiparásita que requiere un árbol huésped para extraer agua, minerales y otros nutrientes mediante la inserción de una raíz especializada llamada *haustoria*. Esta relación parasitaria debilita los árboles hospedantes con el tiempo, reduciendo su estabilidad estructural, disminuyendo la biodiversidad y amenazando servicios ecosistémicos críticos [3, 4].

En la Ciudad de México, tres especies de muérdago—*Cladocolea loniceroides*, *Phoradendron velutinum* y *Struthanthus interruptus*—han sido identificadas como contribuyentes importantes a la alteración ecológica y uno de los principales problemas de los espacios verdes urbanos [5].

La detección y el manejo de infestaciones de muérdago presentan desafíos importantes debido a la capacidad de la planta para mezclarse visualmente con la vegetación huésped, particularmente en sus primeras etapas [6]. Como se muestra en la Figura 1, los grupos de muérdago se parecen mucho al follaje sano de sus árboles hospedantes, lo que di-

ficulta la identificación manual, especialmente en vegetación densa. Este desafío se ve agravado aún más por la variabilidad ambiental, incluidos los cambios en la iluminación, los ángulos de visión y la densidad del follaje estacional, que reducen la confiabilidad de los métodos tradicionales [7]. Las encuestas manuales, realizadas por expertos capacitados, siguen siendo el enfoque principal para la detección del muérdago, pero requieren mucho desarrollo manual, tiempo y recursos, lo que las hace poco prácticas para una implementación a gran escala [6]. Además, la inaccesibilidad física de ciertas áreas boscosas exacerba estas ineficiencias, permitiendo que las infestaciones se propaguen sin ser detectadas. En conjunto, estas limitaciones destacan las importantes dificultades que enfrentamos en el manejo de las infestaciones de muérdago y resaltan la necesidad apremiante de mejores métodos para mejorar la eficiencia y escalabilidad de los esfuerzos de detección.

Entre estas especies, *S. interruptus* y *P. velutinum* se destacan por su amplio impacto en los ecosistemas urbanos y áreas boscosas. Por ejemplo *S. interruptus* prevalece en 9 de las 16 alcaldías de la Ciudad de México [5], mientras que *P. velutinum* se destaca particularmente por su capacidad de combinarse perfectamente con la vegetación huésped en los bosques de conservación [6]. Ambas especies forman grupos densos en etapas avanzadas de infestación, dominando las copas de los árboles y alterando las estructuras naturales de los árboles [7]. Estas infestaciones comprometen la salud de los bosques, reducen la biodiversidad y obstaculizan los servicios ecosistémicos esenciales, incluido el secuestro de carbono y el apoyo al hábitat de especies nativas [3, 4]. Los impactos ecológicos y económicos generalizados de estas especies de muérdago enfatizan la urgencia de desarrollar estrategias de detección y gestión eficaces y escalables.

La urgente necesidad de soluciones innovadoras y escalables para abordar el problema de la infestación de muérdago en México catalizó la formación de una iniciativa de investigación interdisci-

plinaria. Este esfuerzo colaborativo reunió a expertos del Centro de Investigación en Ciencias de Información Geoespacial, A.C. (CentroGeo), el Tecnológico Nacional de México/Instituto Tecnológico de Mérida (ITM), el Instituto Tecnológico de Pabellón de Arteaga (ITPA), e incluyó el apoyo de la Secretaría de Educación, Ciencia, Tecnología e Innovación de la Ciudad de México (SECTEI), Secretaría del Medio Ambiente de la Ciudad de México (SEDEMA) y el Espacio de Innovación UNAM-Huawei. Combinando experiencia en inteligencia artificial (IA), teledetección, gestión ecológica y operaciones de campo, el equipo busca abordar los desafíos multifacéticos que plantean las infestaciones de muérdago en ecosistemas tanto urbanos como boscosos.

Un elemento central de la estrategia del equipo es la integración de tecnologías avanzadas con conocimientos ecológicos. En particular, las tecnologías de detección remota, como las imágenes multiespectrales de alta resolución recopiladas mediante vehículos aéreos no tripulados (UAV, de *Unmanned Aerial Vehicles*), han brindado la capacidad de monitorear grandes áreas de manera eficiente y capturar información detallada relacionada con la salud de la vegetación y la fenología, entre otros. Estos datos, combinados con técnicas de IA de vanguardia, han permitido el desarrollo de herramientas de detección escalables. Por lo tanto, aprovechando los algoritmos de aprendizaje automático y los modelos de aprendizaje profundo, el equipo pretende crear metodologías capaces de distinguir los grupos de muérdago de la vegetación saludable circundante con alta precisión, incluso en condiciones ambientales desafiantes.

El objetivo general de la iniciativa es desarrollar metodologías innovadoras impulsadas por la tecnología para la detección y gestión automatizadas de las infestaciones de muérdago. Diseñadas para abordar las limitaciones de los enfoques tradicionales, estas metodologías priorizan la escalabilidad, la precisión y la eficiencia, al tiempo que garantizan interpretabilidad y conocimientos prácticos para los profesio-

nales de la ecología. Al centrarse en la escalabilidad, las herramientas apuntan a apoyar diversos contextos ecológicos, desde parques urbanos hasta áreas de conservación forestal, contribuyendo a la preservación de la biodiversidad y la salud de los ecosistemas.

Para abordar los desafíos de la detección del muérdago, se han recopilado conjuntos de datos completos de diversos sitios de estudio, incluido el área de conservación ecológica *San Bartolo Ameyalco*, el *Jardín Ramón López Velarde* y el muelle de Xochimilco, en la Ciudad de México. Estas ubicaciones fueron elegidas en conjunto con SEDEMA debido a su alta prevalencia de infestaciones de muérdago y sus diversas condiciones ambientales, que brindan una base sólida para desarrollar modelos de detección sólidos.

Los conjuntos de datos se construyeron utilizando un dron multiespectral P4, que proporciona información espacial y espectral detallada, fundamental para distinguir el muérdago de la vegetación huésped. Este dispositivo permitió capturar imágenes de alta resolución, preservando los detalles de grano fino de los racimos de muérdago, como sus hojas anchas y aterciopeladas y su coloración distintiva. Estas características son esenciales para una identificación precisa, particularmente en las primeras etapas de infestación, donde el muérdago se mezcla perfectamente con sus árboles huéspedes. La imagen aérea original a la izquierda de la Figura 2 resalta esta similitud visual, lo que demuestra el desafío de diferenciar el muérdago de la vegetación saludable. Para abordar esto, se aplicaron pasos de preprocesamiento, como el co-registro y la normalización de bandas multiespectrales, para garantizar la coherencia en todo el conjunto de datos.

La identificación y segmentación de los grupos de muérdago en cada conjunto de imágenes fue realizada manualmente por un especialista en ecología. Estos mapas etiquetados sirvieron como base para el aprendizaje supervisado, proporcionando datos precisos y reales para entrenar modelos de aprendizaje automático. La imagen izquierda de la Figura 2



Figura 1. Representación visual de grupos de muérdago (*S. interruptus*) resaltados en azul, capturados en el Jardín Ramón López Velarde, Ciudad de México, en noviembre de 2024. El muérdago hemiparásito se mezcla perfectamente con la vegetación huésped, lo que complica la detección manual y enfatiza la necesidad de métodos de identificación automatizados.

muestra un ejemplo de un mapa de segmentación (en rojo) superpuesto a la imagen original correspondiente. Esta combinación de imágenes de alta resolución y segmentación experta creó un conjunto de datos sólido para avanzar en las metodologías de detección automatizadas.

La integración de la IA y la teledetección es prometedora no sólo para abordar el desafío inmediato de las infestaciones de muérdago, sino también para aplicaciones ecológicas más amplias. Estas herramientas permiten a los conservacionistas monitorear la biodiversidad, evaluar la salud de los ecosistemas y desarrollar estrategias de manejo específicas para especies invasoras. Como se destaca en esta investigación, el uso de estas tecnologías requiere un enfoque multidisciplinario que combine expe-

riencia ecológica con avances computacionales, asegurando que las soluciones sean científicamente sólidas y prácticas.

Los objetivos de este trabajo son triples. Primero, reflexionar sobre los conocimientos adquiridos a partir de los esfuerzos de colaboración continuos de nuestro equipo de investigación interdisciplinario, enfatizando tanto los éxitos como los desafíos encontrados en la aplicación de la IA y la teledetección a la conservación ecológica. En segundo lugar, fomentar el diálogo dentro de las comunidades científica y conservacionista, fomentando la colaboración interdisciplinaria e inspirando la innovación. Finalmente, delinear posibles direcciones para investigaciones futuras, enfatizando la importancia del despliegue sostenible y equitativo de

tecnologías de IA para abordar los desafíos ambientales apremiantes.

Avances actuales

La fase inicial de nuestra investigación exploró el potencial de los enfoques de computación evolutiva, específicamente la Programación Genética (GP, de *Genetic Programming*), para abordar el desafío de la detección del muérdago. Se empleó GP para desarrollar un método de índice espectral capaz de distinguir infestaciones de muérdago en imágenes multispectrales adquiridas por UAV [6]. Al simular procesos evolutivos naturales, GP optimizó iterativamente combinaciones de bandas espectrales para crear un índice altamente efectivo para detectar especies de *Phoradendron Velutinum* durante




Figura 2. Visualización del procesamiento del modelo CNN ResNet-34 para la identificación de especies de muérdago conocidas como *P. Velutinum*. A la izquierda, la imagen RGB de alta resolución original con una máscara de segmentación binaria superpuesta (roja) que resalta las regiones de muérdago (etiquetadas por expertos) y a la derecha, el mapa de calor generado por CNN que enfatiza las áreas identificadas como muérdago.

su etapa de floración.

Esta metodología demostró una precisión notable, superior al 96% en condiciones controladas, y proporcionó una prueba de concepto fundamental para la detección automatizada. El enfoque en la etapa de floración de *P. velutinum* aprovechó las características espectrales únicas de la planta parásita, permitiendo una diferenciación precisa de los árboles huéspedes y la vegetación circundante. Este logro puso de manifiesto el potencial de los enfoques computacionales para complementar los métodos ecológicos tradicionales, particularmente al abordar tareas que requieren mucho desarrollo manual, como las inspecciones manuales de campo.

El éxito de GP no solo validó la viabilidad de utilizar análisis espectral automatizado para la detección de muérdago, sino que también destacó la complejidad de ampliar dichos métodos a contextos ecológicos más amplios y al seguimiento de diferentes especies de muérdago. Estos conocimientos sientan las bases para exploraciones posteriores hacia técnicas más adaptables capaces de manejar la variabilidad ambiental y abordar una gama más amplia de especies. Por lo tanto, nuestra investigación se amplió para explorar el uso de descriptores de textura y técnicas de aprendizaje automático para

la detección de muérdago.

Reconociendo la importancia de los patrones espaciales para diferenciar el muérdago de los árboles hospedantes, empleamos descriptores como matrices de coocurrencia de nivel de grises (GLCM) y filtros Gabor, junto con transformaciones de color e índices de vegetación, para capturar las características texturales y espectrales únicas de los grupos de muérdago [8]. Estas características fueron seleccionadas con el objetivo de mejorar el rendimiento de clasificación de *S. Interruptus* realizada mediante Máquinas de Vectores de Soporte (SVM, de *Support Vector Machines*), que alcanzó una precisión cercana al 60% en entornos controlados [8]. Estos resultados demostraron el potencial de combinar descriptores espectrales y de textura con modelos de aprendizaje automático para la aplicación actual. Sin embargo, el rendimiento de estos métodos se vio significativamente afectado por la gran similitud entre el follaje del muérdago y del árbol huésped. Además, la falta de otras características espectrales limitó la adaptabilidad de nuestro enfoque a entornos más complejos y heterogéneos, como grandes áreas boscosas con varias especies de muérdago.

Los resultados de SVM revelaron el potencial del uso de técni-

cas computacionales para clasificar las infestaciones de muérdago, pero también evidenciaron sus limitaciones para adaptarse a la variabilidad ambiental y capturar la complejidad de los patrones de textura. Estos desafíos resaltaron la necesidad de metodologías capaces de aprender características complejas directamente a partir de los datos, sin depender de descriptores artesanales predefinidos. Esta comprensión nos llevó a explorar un enfoque de aprendizaje profundo, que ofrecía un marco más dinámico y adaptable para manejar tareas ecológicas complejas.

Entre las técnicas de aprendizaje profundo, las redes neuronales convolucionales (CNN, de *Convolutional Neural Networks*) surgieron como una opción natural y muy adecuada. Las CNN están diseñadas específicamente para extraer jerarquías espaciales de características de imágenes, lo que las hace particularmente efectivas para tareas ricas en texturas, como la detección de muérdago. Al aprender patrones directamente de las imágenes adquiridas por los UAV, las CNN proporcionaron la flexibilidad necesaria para tener en cuenta la variabilidad de las condiciones ambientales, como los cambios en la iluminación, la densidad del follaje y la estructura de los árboles. Esta adaptabilidad convirtió a las CNN en un siguiente paso ideal

en nuestra investigación, cerrando la brecha entre los esfuerzos anteriores y la necesidad de soluciones sólidas y escalables.

Con el propósito de probar la viabilidad de técnicas avanzadas de clasificación basadas en imágenes, comenzamos por el desarrollo de una aplicación más sencilla orientada a la detección de árboles muertos en parques urbanos [9]. Esta tarea nos permitió centrarnos en características visuales bien definidas, como la ausencia de follaje o áreas verdes, mientras utilizamos datos adquiridos por UAV para establecer modelos de referencia. Para hacerlo, implementamos ResNet-34, una arquitectura de CNN conocida por su equilibrio entre eficiencia computacional y poder de representación [10, 11, 12]. ResNet-34 utiliza bloques residuales con conexiones de acceso directo, que mitigan el problema del desvanecimiento del gradiente y permiten un entrenamiento eficaz en redes profundas [13]. Esta arquitectura sobresale en la extracción de características de grano fino, lo que la hace particularmente adecuada para tareas de monitoreo ecológico donde las distinciones sutiles, como la identificación de especies invasoras o vegetación degradada, son críticas.

Esta fase de nuestra investigación no sólo confirmó el potencial de las CNN para el monitoreo ecológico y de la vegetación, sino que también sentó las bases para esfuerzos posteriores para capturar patrones de textura más sutiles asociados con las infestaciones de muérdago. Al aplicar con éxito las CNN a la detección de árboles muertos, pudimos perfeccionar nuestras metodologías y generar confianza en la escalabilidad y adaptabilidad de los modelos de aprendizaje profundo para desafíos ecológicos más amplios, como la clasificación de especies de muérdago.

Luego, nuestra investigación avanzó para implementar ResNet-34 para la tarea más compleja de clasificación del muérdago en espacios verdes urbanos. Para profundizar nuestra comprensión de los rasgos visuales y las características asociadas con dicha planta parásita, realizamos experimentos que perturbaron las imágenes de entrada

con cambios en el brillo, el ruido y la resolución. Estas perturbaciones fueron diseñadas para explorar cómo las variaciones en las condiciones ambientales afectaban la capacidad del modelo para identificar grupos de muérdago. Este enfoque proporcionó información valiosa sobre las características visuales específicas que ResNet-34 priorizó durante la clasificación, como el color, la textura y los patrones espaciales, mejorando nuestra comprensión ecológica del muérdago y sus distintas firmas visuales.

Además, integramos herramientas de explicabilidad, como mapas de activación de clases (también conocidos como mapas de calor), para validar aún más las predicciones del modelo. Estas visualizaciones resaltaron las regiones de las imágenes en las que se basó el modelo para sus clasificaciones, lo que nos permitió asegurar que sus decisiones se alinearan con las expectativas ecológicas. Esta combinación de análisis de perturbaciones y explicabilidad no solo fortalece la interpretabilidad del modelo, sino que también pretende proporcionar a los usuarios finales, como expertos forestales y profesionales de la conservación, conocimientos prácticos sobre las características visuales del muérdago, facilitando una gestión ecológica más informada.

La implementación de modelos de CNN mejoró significativamente nuestra capacidad para identificar grupos de muérdago; sin embargo, estos modelos también introdujeron demandas computacionales sustanciales. Entrenar e implementar modelos de CNN a escala requiere una potencia de procesamiento considerable, particularmente cuando se manejan imágenes de vehículos aéreos no tripulados de alta resolución. Este desafío se abordó a través de nuestra colaboración con el Espacio de Innovación UNAM-Huawei, que brindó acceso a infraestructura computacional de alto rendimiento, permitiendo la optimización y entrenamiento eficiente de nuestros modelos. Sin embargo, ciertos experimentos requirieron una evaluación de diversas configuraciones de hardware y entornos computacionales para evaluar el rendimiento y la adaptabi-

lidad en diferentes escenarios. Por ejemplo, la combinación óptima de configuraciones de hardware, estrategias de asignación de recursos y configuraciones de sistemas para minimizar los tiempos de entrenamiento aún no se comprende adecuadamente, lo que destaca la necesidad de explorar más a fondo las compensaciones entre hardware y rendimiento para aplicaciones ecológicas de aprendizaje profundo.

Para abordar la exploración anterior, realizamos un análisis comparativo de plataformas de hardware, evaluando configuraciones que van desde computadoras portátiles de consumo hasta servidores de alto rendimiento. El estudio reveló conocimientos críticos sobre las compensaciones entre eficiencia computacional, costo y rendimiento del modelo. Las estaciones de trabajo de alto rendimiento y el hardware especializado proporcionaron reducciones significativas en el tiempo de entrenamiento y mejoraron la escalabilidad de nuestros modelos. Al optimizar el rendimiento del hardware, no solo aumentamos la viabilidad de implementar modelos de aprendizaje profundo para la detección de muérdago, sino que también sentamos las bases para aplicaciones más amplias en la conservación ecológica. Esta fase de investigación reforzó la necesidad de colaboraciones interdisciplinarias e iniciativas de intercambio de recursos para superar las barreras computacionales, allanando el camino para soluciones más sólidas y escalables a desafíos ambientales complejos.

Un objetivo principal de nuestra investigación ha sido desarrollar herramientas prácticas y escalables para la conservación ecológica, pasando de metodologías experimentales a aplicaciones del mundo real. Nuestros sistemas de detección, que van desde mapas de infestación hasta modelos de clasificación automatizados, están diseñados teniendo en cuenta la usabilidad y abordando las necesidades del personal forestal, los administradores de parques urbanos y los formuladores de políticas. Estas herramientas tienen el potencial de automatizar tareas que requieren mucho desarrollo manual, proporcio-

nar información útil para la asignación de recursos y monitorear la efectividad de las estrategias de gestión. Además, las herramientas de explicabilidad, como los mapas de activación de clases, garantizan la interpretabilidad y la confianza en los resultados de los modelos, cerrando la brecha entre los métodos computacionales avanzados y los esfuerzos prácticos de conservación.

Discusión

Los avances logrados hasta ahora en esta iniciativa representan un progreso significativo para abordar los desafíos ecológicos que plantean las infestaciones de muérdago. Sin embargo, como ocurre con cualquier enfoque innovador, el viaje ha revelado no sólo éxitos sino también limitaciones que justifican una reflexión crítica. Más allá de los logros técnicos, este trabajo plantea preguntas más amplias sobre el papel de la IA en la conservación ecológica, las implicaciones éticas y prácticas del despliegue de tales tecnologías y los desafíos de garantizar la escalabilidad y la accesibilidad. Esta sección tiene como objetivo proporcionar un análisis de estos aspectos, explorando las lecciones aprendidas, los desafíos no resueltos y las oportunidades para la innovación futura. Al reflexionar sobre estas dimensiones, esperamos inspirar un diálogo continuo y una colaboración interdisciplinaria en la búsqueda de soluciones de conservación sostenibles e impactantes.

Las metodologías exploradas reflejan una respuesta en evolución a los complejos desafíos que plantean las infestaciones de muérdago. GP demostró un potencial significativo al automatizar el diseño de un índice espectral que logró una precisión general del 96,6 % en la detección de infestaciones de muérdago durante la etapa de floración de *P. velutinum*. Esta precisión se logró en condiciones controladas con imágenes multiespectrales de vehículos aéreos no tripulados, lo que destaca la capacidad de GP para derivar soluciones personalizadas para desafíos ecológicos específicos. Sin embargo, su dependencia de las características espectrales de la etapa de floración re-

salta las limitaciones a la hora de generalizar entre condiciones variables y etapas fenológicas.

Este éxito se yuxtapuso a desafíos en materia de escalabilidad y adaptabilidad. Si bien GP destacó en escenarios específicos, su dependencia de índices espectrales limitó su solidez en entornos heterogéneos. El análisis detallado de las soluciones GP reveló una fuerte dependencia de las bandas del espectro visible, particularmente los canales R y B, alineándose con la pigmentación característica del muérdago. Esta especificidad, si bien es eficaz en el área de estudio objetivo, plantea dudas sobre la adaptabilidad de los algoritmos basados en GP a otros entornos y especies de muérdago.

La exploración posterior de descriptores de textura y clasificadores de aprendizaje automático representó un paso importante para abordar la complejidad espacial de las infestaciones de muérdago. Se emplearon técnicas como matrices de coocurrencia de nivel de grises (GLCM, de *Gray Level Co-occurrence Matrix*), filtros de Gabor y patrones binarios locales (LBP, de *Local Binary Patterns*) para capturar las distintas características de textura de las regiones de muérdago, complementadas con índices de vegetación derivados de imágenes multiespectrales adquiridas por UAV. Estos enfoques mostraron el papel fundamental de la textura para diferenciar el muérdago de la vegetación sana, particularmente en escenarios controlados. Sin embargo, los experimentos de clasificación realizados con SVM revelaron desafíos notables. Estos incluían la sensibilidad a la variabilidad ambiental, como la iluminación y los cambios estacionales, así como las limitaciones inherentes de las características artesanales, que restringían la escalabilidad y la generalización a ecosistemas heterogéneos. Si bien la metodología ofreció información valiosa, los resultados resaltaron la necesidad de técnicas más adaptables capaces de aprender características directamente de los datos, sentando las bases para enfoques de aprendizaje profundo.

Las técnicas de aprendizaje profundo, si bien ofrecen una ma-

yor adaptabilidad, requieren grandes conjuntos de datos anotados para explotar plenamente su potencial. Sin embargo, nuestro conjunto de datos era de tamaño limitado, lo que planteaba limitaciones importantes para entrenar las CNN para realizar tareas como la segmentación semántica, que exigen anotaciones a nivel de píxel. Para abordar esta limitación, adoptamos un enfoque de clasificación de imágenes dividiendo imágenes aéreas más grandes en mosaicos más pequeños para su análisis. Este método maximizó la utilidad de los datos disponibles y aprovechó las sólidas capacidades de extracción de características de las arquitecturas CNN como ResNet-34. En lugar de abordar de inmediato la compleja tarea de distinguir el muérdago de la vegetación verde, optamos por un enfoque más gradual. Al centrarnos inicialmente en la clasificación de árboles muertos versus vegetación verde, refinamos nuestras metodologías, construimos una base sólida para el entrenamiento de modelos y validamos la viabilidad de nuestro enfoque. Esta progresión gradual equilibró los desafíos técnicos de la implementación del aprendizaje profundo con las limitaciones prácticas de la disponibilidad limitada de datos y la complejidad ecológica.

Nuestra investigación logró un hito importante con la clasificación de árboles muertos utilizando imágenes multiespectrales adquiridas por UAV. El estudio comparativo de ResNet-34 y DenseNet-121 proporcionó información sobre la aplicabilidad de estas arquitecturas para detectar anomalías de la vegetación indicativas de perturbaciones ecológicas. Ambos modelos demostraron un rendimiento sólido, con DenseNet-121 superando ligeramente a ResNet-34 en métricas como precisión y puntuación F1, alcanzando valores de aproximadamente el 97 % [9]. Este alto nivel de precisión se complementó con la integración de mapas de calor, que iluminaron las áreas dentro de las imágenes de entrada más relevantes para el proceso de clasificación. Estas herramientas visuales mejoraron la interpretabilidad de las decisiones de los modelos, cerrando la brecha en-

tre los resultados computacionales y los conocimientos ecológicos procesables. Si bien estos resultados validaron la viabilidad de utilizar CNN para monitorear la salud de los árboles, también sentaron un precedente para abordar tareas de clasificación más complejas, como distinguir las infestaciones de muérdago de la vegetación sana.

Aprovechando el éxito de la clasificación de los árboles muertos, pasamos a la tarea más compleja de identificar las infestaciones de muérdago. Confiados en nuestro enfoque, extrajimos los mosaicos de la misma manera que antes, esta vez centrándonos específicamente en el muérdago. Estos mosaicos, derivados de imágenes multispectrales adquiridas por vehículos aéreos no tripulados, formaron la base para entrenar el modelo para distinguir el muérdago (*S. interruptus*) de la vegetación circundante. La Figura 3 muestra mosaicos representativos de muérdago, capturando las distintas características visuales necesarias para la clasificación.

El modelo ResNet-34 logró una precisión notable, con métricas de rendimiento de referencia que superaron constantemente el 83% en las estrategias de validación de reserva y k-fold. Las visualizaciones de mapas de calor resaltaron de manera efectiva características biológicamente relevantes, alineándose con las regiones de muérdago anotadas y validando la relevancia ecológica de las clasificaciones del modelo.

Sin embargo, el estudio también destacó limitaciones específicas. El modelo mostró sensibilidad a las perturbaciones ambientales, como cambios en los canales de color y la introducción de ruido, particularmente ruido de sal y pimienta a intensidades más altas. Si bien esta sensibilidad destaca áreas que requieren un mayor refinamiento, como mejorar la robustez a través de metodologías de entrenamiento tolerantes al ruido o estrategias de preprocesamiento adaptativo, también ofrece una oportunidad única para comprender mejor las características visuales del muérdago. Al analizar las respuestas del modelo en diferentes condiciones, obtenemos conocimien-

tos más profundos sobre las características definitorias del muérdago, como su textura, color y patrones espaciales. Esta mejor comprensión puede contribuir tanto a la identificación manual por parte de los profesionales ecológicos como al desarrollo de métodos de detección automatizados más sofisticados. Además, la dependencia de la clasificación basada en mosaicos, si bien es práctica dada las limitaciones del conjunto de datos, presenta desafíos a la hora de capturar el contexto espacial más amplio necesario para el monitoreo ecológico a gran escala.

De cara al futuro, estos resultados resaltan el potencial de integrar técnicas de segmentación semántica para superar las limitaciones espaciales de la clasificación basada en mosaicos. Al mejorar la capacidad del modelo para identificar el muérdago a nivel de píxel, los esfuerzos futuros podrían mejorar significativamente la precisión y la escalabilidad de la detección. Sin embargo, las demandas computacionales de metodologías tan refinadas resaltan la importancia de soluciones de hardware eficientes. A medida que los modelos de aprendizaje profundo crecen en complejidad, abordar las compensaciones entre la eficiencia computacional y el rendimiento se vuelve esencial para garantizar su viabilidad para aplicaciones ecológicas a gran escala.

Nuestros resultados proporcionan información valiosa para optimizar las demandas computacionales de los modelos de aprendizaje profundo para la detección de muérdago. Se evaluaron múltiples configuraciones, incluidos procesadores Intel y AMD, GPU de consumo y estaciones de trabajo de alto rendimiento, para evaluar su idoneidad para el entrenamiento de ResNet-34. En particular, los procesadores AMD superaron consistentemente a sus homólogos Intel en eficiencia de entrenamiento, y las configuraciones AMD de rango medio lograron un equilibrio entre costo y rendimiento. Además, la desactivación del *hyperthreading* (HT) en las CPU aceleró los tiempos de entrenamiento en la mayoría de las plataformas, lo que resalta la importancia de ajustar

cuidadosamente la configuración del hardware para las tareas de aprendizaje profundo.

Las GPU de consumo demostraron eficacia para tareas de entrenamiento a corto plazo, brindando un rendimiento competitivo en relación con estaciones de trabajo de alto rendimiento en escenarios con demandas computacionales moderadas. Sin embargo, los servidores de alto rendimiento exhibieron una escalabilidad incomparable y tiempos de entrenamiento reducidos, lo que los hizo indispensables para conjuntos de datos extensos o cargas de trabajo a largo plazo. Estos hallazgos resaltan las compensaciones entre la eficiencia computacional y el costo, enfatizando la necesidad de seleccionar configuraciones de hardware que se alineen con la escala y el alcance de las aplicaciones ecológicas.

Estos resultados refuerzan la viabilidad de implementar modelos avanzados para el monitoreo ecológico, siempre que las opciones de hardware estén optimizadas para restricciones operativas específicas. Naturalmente, pasan a consideraciones más amplias de implementación, como abordar los desafíos de accesibilidad en regiones de escasos recursos y equilibrar el rendimiento computacional con la sostenibilidad ambiental.

Si bien nuestras metodologías han demostrado un potencial significativo, no están exentas de limitaciones, muchas de las cuales presentan desafíos críticos para una implementación y escalabilidad más amplias. Una limitación clave reside en la dependencia de imágenes de alta resolución adquiridas por vehículos aéreos no tripulados, que, si bien permiten una detección precisa, exigen recursos sustanciales para la recopilación y el procesamiento de datos. Esta dependencia plantea dudas sobre la viabilidad de implementar tales métodos en regiones con recursos limitados o en ecosistemas de gran escala donde la cobertura de los UAV y la capacidad computacional pueden estar restringidas.

Otra limitación es el desafío de generalizar nuestros modelos a diversos contextos ecológicos. La alta precisión lograda en entornos controla-




Figura 3. Mosaicos de muestra utilizados en el conjunto de datos de entrenamiento para muérdago (*S. interruptus*). Cada mosaico mide 32×32 píxeles y corresponde a un segmento extraído de las imágenes aéreas originales. Estos mosaicos se utilizaron para entrenar y validar el modelo ResNet-34.

dos o semicontrolados no garantiza un rendimiento equivalente en paisajes más complejos y heterogéneos. Las variaciones en los tipos de vegetación, las especies de muérdago y las condiciones ambientales, como la iluminación o los cambios estacionales, pueden afectar significativamente la solidez del modelo. Esto destaca la necesidad de una extensa validación de campo y el desarrollo de modelos capaces de adaptarse a la naturaleza dinámica de los sistemas ecológicos.

Ampliar estos enfoques a áreas más grandes también presenta desafíos no resueltos, incluidas las demandas computacionales del procesamiento de conjuntos de datos expansivos y la necesidad de automatización en la planificación de vuelos de UAV y la anotación de datos. Además, los sesgos en los datos de entrenamiento (derivados de una sobrerrepresentación de condiciones ecológicas o áreas geográficas específicas) pueden limitar inadvertidamente la aplicabilidad de los modelos. Abordar estos sesgos requerirá una cuidadosa conservación de los conjuntos de datos, centrándose en mejorar la representatividad y la diversidad de las muestras de entrenamiento.

Estas brechas invitan a una mayor exploración e innovación dentro de las comunidades científica y conservacionista. ¿Cómo podemos equi-

librar la necesidad de datos de alta resolución con el objetivo de crear soluciones escalables y accesibles? ¿Existen enfoques híbridos, como la integración de imágenes satelitales para una cobertura más amplia con datos de UAV para realizar ajustes, que puedan cerrar esta brecha? Además, las técnicas de aprendizaje adaptativo, en las que los modelos se actualizan continuamente con nuevos datos de diversos entornos, podrían ofrecer un camino hacia una mayor generalización y resiliencia.

Al reconocer estas limitaciones, pretendemos estimular el debate y la colaboración sobre cómo abordarlas. Si bien los desafíos son importantes, también presentan oportunidades para perfeccionar y ampliar la aplicabilidad de las herramientas de conservación impulsadas por la IA, allanando el camino para soluciones ecológicas más inclusivas e impacantes.

Las metodologías y los conocimientos desarrollados en esta investigación tienen un potencial significativo para hacer avanzar las aplicaciones de IA más allá de la detección de infestaciones de muérdago. La integración de imágenes adquiridas por UAV, aprendizaje automático y técnicas de aprendizaje profundo establece un marco escalable que puede adaptarse a una variedad de desafíos ecológicos. Por ejem-

plo, estos enfoques podrían utilizarse para monitorear la biodiversidad en hábitats amenazados, evaluar la propagación de otras especies invasoras o evaluar la salud de los bosques afectados por el cambio climático. La capacidad de los modelos de IA para procesar y analizar grandes volúmenes de imágenes de alta resolución los posiciona como herramientas transformadoras en la conservación ecológica.

Sin embargo, la aplicación más amplia de estas tecnologías plantea importantes cuestiones éticas y prácticas. Las preocupaciones sobre la propiedad de los datos y la privacidad son particularmente relevantes cuando los UAV se despliegan en áreas con actividad humana, capturando potencialmente información no deseada. Establecer protocolos claros para la gobernanza de datos y garantizar el cumplimiento de las normas de privacidad será esencial para mantener la confianza pública y la integridad ética. De manera similar, la accesibilidad a herramientas avanzadas de IA en áreas de escasos recursos sigue siendo un desafío apremiante. La informática de alto rendimiento y la infraestructura de UAV a menudo se limitan a instituciones bien financiadas, lo que genera disparidades en cuanto a quién puede beneficiarse de estas innovaciones. Abordar estas desigualdades requere-

rirá esfuerzos de colaboración para diseñar soluciones rentables y compartir recursos de manera más equitativa.

La sostenibilidad ambiental es otra consideración crítica. Los vuelos de UAV, en particular los que implican misiones múltiples, contribuyen a las emisiones de carbono, mientras que la naturaleza de uso intensivo de energía de la informática de alto rendimiento aumenta la huella ambiental de las aplicaciones de IA. Estos factores resaltan la importancia de optimizar el uso de recursos y explorar alternativas más ecológicas, como la informática de punta o hardware más eficiente desde el punto de vista energético, para alinear el progreso tecnológico con los principios de conservación.

De cara al futuro, esta investigación invita a una reflexión crítica sobre la sostenibilidad y la inclusión de la IA en aplicaciones ecológicas. ¿Cómo podemos garantizar que estas herramientas sean accesibles para las regiones de escasos recursos y adaptables a diversos contextos ecológicos? ¿Existen formas de integrar el conocimiento ecológico tradicional con los sistemas de IA para crear estrategias de conservación más holísticas e inclusivas? Además, ¿qué marcos se necesitan para minimizar el impacto ambiental del despliegue de estas tecnologías a escala?

Al plantear estas preguntas, pretendemos provocar un debate reflexivo dentro de las comunidades científica y conservacionista. Si bien la IA es inmensamente prometedora para abordar desafíos ecológicos complejos, su aplicación responsable requiere un equilibrio entre innovación y sostenibilidad. A través de la colaboración interdisciplinaria y la previsión ética, estas herramientas pueden evolucionar para volverse más inclusivas, equitativas y alineadas con los objetivos de conservación a largo plazo.

Los avances logrados en esta investigación sientan una base sólida para explorar nuevas vías en el monitoreo y la conservación ecológicos. Ampliar el alcance de las pruebas más allá de la detección de muérdago a otros desafíos ecológicos ofrece oportunidades prometedoras para

validar y perfeccionar aún más estas metodologías. Por ejemplo, las mismas imágenes adquiridas por UAV y los mismos marcos de aprendizaje automático podrían adaptarse para detectar otras especies invasoras, como los escarabajos de la corteza o las enredaderas parásitas, que amenazan de manera similar la salud de los bosques. Además, las técnicas de análisis espectral y de textura empleadas aquí podrían aplicarse para evaluar indicadores más amplios de salud forestal, como la identificación de signos tempranos de enfermedades o el seguimiento de la recuperación de la vegetación después de perturbaciones.

Las tecnologías emergentes presentan posibilidades interesantes para mejorar la escalabilidad y precisión de estos esfuerzos. *Vision Transformers* (VT), una arquitectura de última generación para el análisis de imágenes, podría emplearse para capturar relaciones espaciales complejas y mejorar la precisión de la detección en entornos altamente heterogéneos. Al aprovechar su capacidad para procesar el contexto global dentro de imágenes, VT puede proporcionar una comprensión más completa de los patrones ecológicos.

Un siguiente paso fundamental es la puesta a prueba de estas metodologías en implementaciones del mundo real. Las colaboraciones con profesionales de la conservación locales y agencias forestales serán esenciales para adaptar estas herramientas a las necesidades y limitaciones específicas de las aplicaciones de campo. Los programas piloto podrían servir como campo de pruebas para perfeccionar los flujos de trabajo, abordar los desafíos de usabilidad y generar confianza entre los usuarios finales. Además, las asociaciones con organizaciones comunitarias podrían facilitar la integración del conocimiento ecológico local, enriqueciendo los datos y aumentando la relevancia de los conocimientos impulsados por la IA.

La colaboración interdisciplinaria fue la piedra angular de este proyecto, impulsando tanto sus éxitos como su evolución para abordar el desafío ecológico de las infestaciones de muérdago. Al integrar la expe-

riencia de CentroGeo, ITM e ITPA, así como aprovechar las asociaciones con SECTEI, SEDEMA, CORENA y el Espacio de Innovación UNAM-Huawei, el equipo unió con éxito la innovación técnica con aplicaciones ecológicas. Este marco de colaboración facilitó el desarrollo de metodologías avanzadas, desde el diseño de índices espectrales hasta la implementación de modelos de aprendizaje profundo, asegurando que cada fase del proyecto estuviera informada por una amplia gama de perspectivas y habilidades. De manera similar, el acceso a recursos informáticos de alto rendimiento a través de asociaciones institucionales permitió al equipo superar importantes desafíos computacionales, acelerando el refinamiento de los modelos de aprendizaje profundo y permitiendo evaluaciones detalladas del desempeño.

Sin embargo, esta colaboración también reveló desafíos inherentes que destacan la complejidad de la investigación interdisciplinaria. Las diferencias en las prioridades y metodologías disciplinarias en ocasiones llevaron a desajustes en los objetivos y expectativas del proyecto. Por ejemplo, mientras los socios técnicos priorizaban la eficiencia y precisión computacional, los colaboradores ecológicos a menudo enfatizaban la interpretabilidad y aplicabilidad de campo de las herramientas que se estaban desarrollando. La comunicación efectiva y los ciclos de retroalimentación iterativos son esenciales para resolver estas tensiones, pero también resaltaron la necesidad de marcos más claros para alinear los objetivos multidisciplinarios desde el principio.

Al reflexionar sobre estas experiencias, surgen varias lecciones que podrían informar futuros proyectos interdisciplinarios. En primer lugar, establecer objetivos claros y compartidos al comienzo de un proyecto puede ayudar a alinear las prioridades y reducir la fricción entre disciplinas. En segundo lugar, la creación de canales de comunicación estructurados (como talleres periódicos o plataformas colaborativas) puede facilitar el diálogo continuo y garantizar que se escuchen todas las voces durante todo el proceso de investiga-

ción. Finalmente, fomentar una cultura de respeto mutuo y apertura a perspectivas diversas es fundamental para maximizar el potencial de los equipos interdisciplinarios.

Una prioridad clave para futuras investigaciones e implementación es fomentar un diálogo que no solo perfeccione las aplicaciones de IA para la detección de muérdago, sino que también genere conciencia sobre la amenaza ecológica que representa. Este diálogo debe extenderse más allá de los científicos y expertos técnicos para incluir a los formuladores de políticas, los profesionales de la conservación y el público en general. Si bien a menudo se romantiza el muérdago, es esencial comunicar su grave impacto en los bosques, donde las infestaciones no controladas debilitan los árboles, reducen la biodiversidad y alteran servicios ecosistémicos críticos. Involucrar a las comunidades en esta conversación puede ayudar a cambiar las percepciones y generar apoyo para las medidas de conservación necesarias.

Involucrar a las comunidades locales es particularmente importante, ya que sus conocimientos ecológicos tradicionales pueden mejorar los enfoques impulsados por la IA y fundamentarlos en realidades prácticas. Se necesitan marcos de colaboración para garantizar que las herramientas de detección y las estrategias de gestión sean accesibles y viables, especialmente en zonas de escasos recursos donde las infestaciones de muérdago podrían ser más graves. Además, las iniciativas de educación pública pueden ayudar a cerrar la brecha entre el simbolismo cultural del muérdago y la urgencia ecológica de su control, fomentando una comprensión compartida del problema y las soluciones requeridas.

A medida que avanzamos en estos esfuerzos, es crucial garantizar que las aplicaciones de IA sigan siendo equitativas, transparentes y alineadas con la gestión ecológica. El futuro del manejo del muérdago depende no sólo de la innovación tecnológica sino también de nuestra capacidad para involucrar y empoderar a todas las partes interesadas, desde los científicos conservacionistas hasta la comunidad en general. Al combi-

nar herramientas avanzadas con una conciencia generalizada y una acción colaborativa, podemos proteger los bosques del impacto devastador de las infestaciones de muérdago y al mismo tiempo fomentar prácticas de conservación sostenibles.

Conclusiones

Este trabajo examina críticamente el papel de la IA y la teledetección para abordar los desafíos ecológicos que plantean las infestaciones de muérdago, ofreciendo información sobre las metodologías y enfoques que han dado forma a este campo emergente. Al aprovechar GP, descriptores de textura y CNN, nuestra investigación destaca tanto el potencial como las limitaciones de estas tecnologías en la conservación ecológica. GP demostró su eficacia en el desarrollo de índices espectrales adaptados a desafíos ecológicos específicos, proporcionando un punto de partida para la automatización en la detección de muérdago. De manera similar, los métodos de aprendizaje automático basados en texturas, si bien son valiosos para capturar patrones espaciales, evidenciaron las limitaciones de las características hechas a mano en entornos complejos y heterogéneos.

El cambio hacia el aprendizaje profundo, particularmente a través de las CNN, refleja una evolución en la metodología que no solo abordó las limitaciones anteriores sino que también reveló la escalabilidad y adaptabilidad de las soluciones para la conservación impulsadas por la IA. Estos avances sirven como una reflexión crítica sobre la aplicación de tecnologías de vanguardia en el monitoreo ecológico, ilustrando cómo la IA puede transformar tareas que requieren mucho desarrollo manual en procesos escalables y eficientes. Sin embargo, también plantean preguntas importantes sobre la practicidad y accesibilidad de estos enfoques, particularmente en entornos con recursos limitados.

Si bien las metodologías y los conocimientos presentados en este trabajo demuestran un potencial significativo para abordar los desafíos ecológicos, van acompañados de li-

mitaciones críticas que justifican una mayor exploración. La variabilidad ambiental complica la generalización de estos modelos. El rendimiento de los enfoques de aprendizaje automático y aprendizaje profundo, optimizados para contextos ecológicos específicos, puede degradarse en entornos heterogéneos caracterizados por diversos tipos de vegetación, cambios estacionales o condiciones de luz fluctuantes. Abordar esta variabilidad requerirá metodologías adaptativas capaces de aprender de diversos conjuntos de datos, junto con una extensa validación de campo para garantizar la solidez en todos los entornos ecológicos.

Las demandas computacionales también presentan un desafío importante, particularmente para los modelos de aprendizaje profundo que requieren muchos recursos. El consumo de energía y la infraestructura necesaria para entrenar e implementar estos sistemas plantean cuestiones importantes sobre su sostenibilidad ambiental y práctica. Los esfuerzos de colaboración, como aprovechar la informática de punta para análisis en tiempo real u optimizar las configuraciones de hardware para lograr eficiencia, representan vías críticas para mitigar estas limitaciones.

La integración de la IA en la conservación ecológica exige una colaboración interdisciplinaria sostenida, basada tanto en la previsión ética como en estrategias de implementación prácticas. Las complejidades de la detección del muérdago y los desafíos ecológicos más amplios requieren experiencia de diversos campos, incluidas las ciencias computacionales, la ecología y las ciencias sociales, para garantizar que los avances tecnológicos sigan siendo contextualmente relevantes e inclusivos. Los esfuerzos futuros deben priorizar asociaciones que cierren la brecha entre la investigación de vanguardia y las prácticas de conservación viables, fomentando la colaboración entre investigadores, formuladores de políticas y comunidades locales.

El despliegue práctico de herramientas de IA también presenta oportunidades críticas para la innovación. La implementación en el

mundo real, respaldada por pruebas de campo y un diseño centrado en el usuario, será clave para perfeccionar estas tecnologías y garantizar su usabilidad por parte de partes interesadas no especializadas, como administradores de parques y trabajadores de conservación. La integración de tecnologías emergentes como VT y la informática de punta podría mejorar aún más la adaptabilidad y eficiencia de las soluciones impulsadas por la IA, haciéndolas más accesibles y sostenibles.

De cara al futuro, el papel de la IA en la conservación está a punto de expandirse mucho más allá de la detección del muérdago. Estas herramientas ofrecen un inmenso potencial para abordar diversos desafíos, desde monitorear la biodiversidad hasta mitigar los impactos del cambio climático. Sin embargo, su impacto dependerá en última instancia de nuestra capacidad para alinear el progreso tecnológico con los principios de sostenibilidad, equidad y transparencia.

Al fomentar el diálogo interdisciplinario y adoptar un enfoque con visión de futuro, la comunidad científica puede promover aplicaciones de IA que no solo aborden las amenazas ecológicas inmediatas sino que también contribuyan al objetivo más amplio del desarrollo sostenible. El camino que tenemos por delante es desafiante y está lleno de oportunida-

des, y requiere acción colectiva, reflexión ética y un compromiso de colaboración que trascienda las fronteras disciplinarias. A través de estos esfuerzos, la IA puede convertirse en una fuerza transformadora en la conservación, impulsando la innovación y al mismo tiempo salvaguardando el planeta para las generaciones futuras.

Declaración de contribución de autoría de CRediT

Juan Carlos Valdiviezo-Navarro: Conceptualización, Metodología, Análisis formal, Redacción – borrador original, Redacción – revisión y edición. **Mauricio G. Orozco-del-Castillo:** Conceptualización, Metodología, Análisis formal, Redacción – borrador original, Redacción – revisión y edición.

Declaración de IA Generativa y tecnologías asistidas por IA en el proceso de redacción

Durante la preparación de este trabajo, los autores utilizaron ChatGPT para mejorar la legibilidad. Después de utilizar esta herramienta, los autores revisaron y editaron el contenido según fuera necesario y asumieron total responsabilidad por el contenido de la pu-

blicación.

Declaración de interés en competencia

Los autores declaran que no tienen intereses financieros en competencia ni relaciones personales conocidas que pudieran haber influido en el trabajo presentado en este artículo.

Reconocimiento

Expresamos nuestro agradecimiento a la Secretaría del Medio Ambiente (SEDEMA) por el apoyo durante el trabajo de campo. También reconocemos el esfuerzo de nuestro equipo para desarrollar este proyecto: Paola Andrea Mejía Zuluaga, León Felipe Dozal García, Alejandra Aurelia López Caloca, Alejandro Téllez Quiñones, Adriana Lizette Luna Nieves, Amilcar Morales Gamas y Mario Ledesma Arriola (CentroGeo); Nivia Iracemi Escalante García, Eduardo Flores Gallegos y José Ernesto Olvera González (TecNM/ITPA); Nora L. Cuevas Cuevas, Carlos Bermejo-Sabbagh, William Orozco-González y Pedro A.G. Ortiz-Sánchez (TecNM/ITM). Parte de este trabajo ha sido financiado por la Secretaría de Educación, Ciencia, Tecnología e Innovación (SECTEI) de la Ciudad de México a través del Subsidio Número 3581c24.

Referencias

- [1] P. K. Rai and J. Singh, "Invasive alien plant species: Their impact on environment, ecosystem services and human health," *Ecological Indicators*, vol. 111, p. 106020, 2020.
- [2] B. Gallardo, M. Clavero, M. I. Sánchez, and M. Vilà, "Global ecological impacts of invasive species in aquatic ecosystems," *Global Change Biology*, vol. 22, 2016.
- [3] M. Pompa-García and J. A. Rodríguez, "Variation of carbon uptake from forest species in Mexico: a review," *Madera Y Bosques*, vol. 23, pp. 225–235, 2017.
- [4] N. Mesa-Sierra, M. de la Peña-Domene, J. Campo, and C. Giardina, "Restoring Mexican tropical dry forests: A national review," *Sustainability*, 2022.
- [5] D. Cibrián Tovar, "Diagnóstico fitosanitario de áreas verdes infestadas por muérdago en la Ciudad de México," 2016.
- [6] P. A. Mejía-Zuluaga, L. Dozal, and J. Valdiviezo-N., "Genetic programming approach for the detection of mistletoe based on UAV multispectral imagery in the conservation area of Mexico City," *Remote Sensing*, vol. 14, p. 801, 2022.
- [7] T. Paap, T. Burgess, and M. Wingfield, "Urban trees: bridge-heads for forest pest invasions and sentinels for early detection," *Biological Invasions*, vol. 19, pp. 3515–3526, 2017.
- [8] P. A. Mejía-Zuluaga, J. C. Valdiviezo-N., and L. Dozal, "Texture descriptors and machine learning algorithms for mistletoe detection in urban forests using multispectral imagery," in *Remote Sensing*, 2023. [Online]. Available: <https://api.semanticscholar.org/CorpusID:264299698>

- [9] W. Orozco-González, J. C. Valdiviezo-Navarro, M. G. O. del Castillo, P. A. Mejia-Zuluaga, and L. Dozal, “Classification of dead trees in urban parks using aerial imagery and convolutional neural networks,” in *ICCBR Workshops*, 2024. [Online]. Available: <https://api.semanticscholar.org/CorpusID:270701684>
- [10] A. Abrol, A. Sharma, K. Karnic, and R. Ranjan, “Human activity recognition using resnet-34 model,” *International Journal of Recent Technology and Engineering*, vol. 10, no. 5, pp. 224–228, 2021.
- [11] X. Li, X. Xu, X. He, X. Wei, and H. Yang, “Intelligent crack detection method based on gm-resnet,” *Sensors (Basel, Switzerland)*, vol. 23, 2023.
- [12] W. Liu, L. Jiangtao, G. Zhao, L. Sun, H. Wang, W. Li, and B. Sun, “Improvement of cifar-10 image classification based on modified resnet-34,” in *Advances in Natural Computation, Fuzzy Systems and Knowledge Discovery*, 2020.
- [13] S. Salman and X. Liu, “Sparsity as the implicit gating mechanism for residual blocks,” in *2019 International Joint Conference on Neural Networks (IJCNN)*. IEEE, 2019, pp. 1–6.