

IA y Big Data para la biología de invasiones: descubrir, modelar y predecir las dinámicas poblacionales de las especies invasoras

Erola Fenollosa^{1,*} , Roberto Salguero-Gómez¹ 

(1) Department of Biology, University of Oxford, Oxford, United Kingdom.

* Autora para correspondencia / Corresponding author: E. Fenollosa [erola.fenollosaromani@biology.ox.ac.uk, erola.fenollosa@gmail.com]

> Recibido / Received: 03/12/2024 – Aceptado / Accepted: 10/04/2025

Cómo citar / How to cite: Fenollosa, E., Salguero-Gómez, R. 2025. IA y Big Data para la biología de invasiones: descubrir, modelar y predecir las dinámicas poblacionales de las especies invasoras. *Ecosistemas* 34(3): 2933. <https://doi.org/10.7818/ECOS.2933>

IA y Big Data para la biología de invasiones: descubrir, modelar y predecir las dinámicas poblacionales de las especies invasoras

Resumen: La inteligencia artificial (IA) está transformando rápidamente el estudio y la gestión de especies invasoras mediante herramientas analíticas y predictivas que optimizan la detección, el monitoreo y la erradicación. En este trabajo, revisamos los principios fundamentales del aprendizaje automático y profundo, ilustrados con casos de estudio recientes sobre especies invasoras. Presentamos, además, la primera revisión sistemática del uso de la IA en el campo de las invasiones biológicas, con 278 artículos publicados desde 1999, un 50 % de ellos en los últimos cinco años, lo que subraya el rápido avance de este campo y sus aplicaciones. Observamos que la mayoría de los estudios se centran en plantas y tareas de detección, empleando imágenes de satélites, drones y cámaras digitales como principales fuentes de datos, lo cual permite monitorear especies invasoras con una precisión y eficiencia sin precedentes. Los algoritmos de aprendizaje profundo destacan por su capacidad para procesar datos visuales complejos, mientras que los enfoques de ensamblaje de modelos generan predicciones más robustas. La creciente disponibilidad de bases de datos globales, imágenes y plataformas colaborativas ha reducido los costos asociados al trabajo de campo, facilitando el acceso a áreas remotas y de mayor extensión, y permitiendo el uso de algoritmos sin necesidad de experiencia avanzada en programación. Este trabajo constituye una guía práctica y accesible para investigadores que se inician en el uso de la IA, destacando los avances más recientes y su potencial transformador para abordar los desafíos de las invasiones biológicas.

Palabras clave: aprendizaje automático; demografía; Especies exóticas; inteligencia artificial (IA); modelos de distribución de especies; teledetección

AI and Big Data for invasion biology: finding, modelling and forecasting the population dynamics of invaders

Abstract: Artificial intelligence (AI) is rapidly transforming the study and management of invasive species through analytical and predictive tools that optimize detection, monitoring, and eradication. In this work, we review the fundamental principles of machine learning and deep learning, illustrated with recent case studies on invasive species. We also present the first systematic review of AI applications in the field of biological invasions, encompassing 278 articles published since 1999, with 50% of them appearing in the last five years, highlighting the rapid progress in this area and its applications. We observe that most studies focused on plants and detection tasks, utilizing satellite images, drones, and digital cameras as primary data sources, enabling unprecedented precision and efficiency in monitoring invasive species. Deep learning algorithms stand out for their ability to process complex visual data, while ensemble modelling approaches produce more robust predictions. The growing availability of global databases, images, and collaborative platforms has significantly reduced fieldwork costs, improved access to larger and remote areas, and enabled the use of algorithms without requiring advanced programming expertise. This work serves as a practical and accessible guide for researchers new to AI, highlighting the most recent advances and its transformative potential to address the challenges of biological invasions.

Keywords: artificial intelligence (AI), demography, exotic species, machine learning, remote sensing, species distribution models

Inteligencia artificial en ecología, una pequeña introducción para principiantes

La inteligencia artificial (IA) está transformando rápidamente muchas áreas del conocimiento, y la ecología no es una excepción (p. ej., [Borowiec et al. 2022](#); [Pichler y Hartig 2023](#); [Wilson 2024](#)). Con el aumento de datos ambientales y la necesidad de análisis complejos, la IA ha emergido como una herramienta de gran potencial para abordar preguntas ecológicas a gran escala y alta resolución ([Galaz García et al. 2023](#); [Veiga Branco et al. 2023](#)). La IA permite procesar grandes volúmenes de información (el “*Big Data*”), lo que resulta especialmente útil en el contexto de la ecología, donde cada vez es más común integrar múltiples fuentes como imágenes satelitales, sensores remotos, o datos procedentes de estudios de campo ([Buchelt et al. 2024](#)).

Pese al extenso uso de la palabra “inteligencia artificial”, actualmente su definición sigue siendo algo difusa. El concepto “IA” incluye todo sistema computacional construido para realizar alguna tarea típicamente humana. Estas tareas pueden ser el reconocimiento de objetos, toma de decisiones o el aprendizaje. Debido que la mayoría de las aplicaciones implican procesos de aprendizaje, habitualmente se usa el término aprendizaje automático (“*machine learning*”) como sinónimo a la IA (Fig. 1). Sin embargo, técnicamente, el aprendizaje automático únicamente engloba aquellos algoritmos de IA en los que su rendimiento aumenta con la exposición a los datos. Dentro de la categoría de aprendizaje automático existen diferentes grupos de algoritmos como el aprendizaje profundo (“*deep learning*”), que a su vez incluiría la subcategoría de la inteligencia artificial generativa que tanta popularidad ha ganado en el último año (p. ej., Agathokleous et al. 2023; Biswas 2023; Rodas-Trejo y Ocampo-González 2024).




Figura 1. Inteligencia artificial (IA) para principiantes. Diagrama de Venn mostrando las relaciones entre los términos: Inteligencia artificial, aprendizaje automático, profundo y por refuerzo, así como las tareas de aprendizaje supervisado para tareas de clasificación y regresión (con datos etiquetados), y no supervisado (datos no etiquetados) para tareas de agrupación. En los tres gráficos, los puntos blancos simbolizan los datos de prueba, que el modelo (en línea discontinua) no ve durante el entrenamiento del modelo y sirven para comprobar si el modelo está o no sobre ajustado a nuestros datos o si es generalizable. Debajo de cada gráfico se presenta un ejemplo de aplicación en invasiones biológicas.

Figure 1. Artificial intelligence (AI) for Beginners. Venn diagram illustrating the hierarchy of the presented terms: Artificial Intelligence, Machine Learning, Deep Learning, and Reinforcement Learning, as well as supervised learning tasks for classification and regression (using labelled data) and unsupervised learning (using unlabelled data) for clustering tasks. In all three graphs, white dots represent test data. Dashed lines represent the model. Below each plot, we provide an example of application in biological invasions.

El funcionamiento de los algoritmos de aprendizaje automático se basa en la exposición ordenada a los datos, de forma similar al aprendizaje humano. Los datos se dividen generalmente en conjuntos de entrenamiento, validación y prueba, para asegurar que el modelo aprendido por la computadora generalice bien a nuevos datos (Greener et al. 2022). Este proceso se conoce en la disciplina de aprendizaje automático como adaptación de dominios (“*domain adaptation*”; Orouji et al. 2024). El conjunto de entrenamiento es el grupo de datos con el que el modelo “aprende”, ajustando sus parámetros para minimizar el error en las predicciones. Una vez que el modelo ha sido entrenado, habitualmente se evalúa su rendimiento en el conjunto de validación, un subconjunto de datos que permite ajustar y optimizar parámetros del modelo (Hastie et al. 2009). Finalmente, el conjunto de prueba es un grupo de datos completamente nuevo para el modelo, utilizado solo al final para medir su capacidad de generalización y obtener una evaluación precisa de su rendimiento en datos no vistos. Hablamos de sobreajuste (“*overfitting*”) cuando el rendimiento del modelo empeora al evaluarse con los datos de prueba (Greener et al. 2022).

La forma en que dividimos los datos en los diferentes conjuntos balancea el rendimiento del modelo y su capacidad de generalización y predicción (Walsh et al. 2021). Una proporción habitual para dividir los datos es el “90-10” (Bzdok et al. 2018), donde el 90 % de los datos se destina al entrenamiento del algoritmo de IA y el 10 % a su prueba de rendimiento/predicción. Estas proporciones pueden ajustarse según el tamaño del conjunto de datos y debe considerar todo el rango de los datos. Con conjuntos de datos pequeños, se recomienda utilizar técnicas como la validación cruzada (Hastie et al. 2009) para maximizar el uso de los datos disponibles y obtener una evaluación más precisa. Otro método de validación común es la validación con *bootstrapping* (Tsamardinos et al. 2018), que selecciona múltiples subconjuntos de datos de manera aleatoria y con reemplazo, evaluando el modelo en cada subconjunto y promediando los resultados.

Para determinar si en una fotografía aparece una especie invasora en particular, es necesario contar con muchas imágenes etiquetadas que indiquen si la especie está presente o no. Publicaciones recientes utilizando estas técnicas incorporan desde 300 (Mqingwana et al. 2024), 4200 (Matsuhashi et al. 2024) o hasta 309 373 fotografías (Chaity y van Aardt 2024). Una vez que hemos examinado parte de esas fotografías (conjunto de entrenamiento) y sus atributos relevantes (como la forma y disposición de las hojas, el tamaño, el color de la flor, etc.), seremos capaces de identificar si en una nueva foto (conjunto de prueba) esa especie está o no presente. Cuando esta tarea la realiza un sistema computacional, hablamos de aprendizaje supervisado, ya que sabiendo la categoría de cada imagen (presencia o no de la especie), supervisamos cómo realiza la clasificación el sistema de IA. En cambio, si no tenemos información sobre qué especies aparecen en cada fotografía (datos no etiquetados), el modelo no podrá aprender a identificar la presencia de una especie específica, pero sí podrá agrupar las imágenes en función de similitudes, como el tipo de planta (herbácea, arbusto, árbol) o el color de las flores. Este tipo de aproximación es un caso de aprendizaje no supervisado, ya que el algoritmo detecta patrones de agrupación basándose únicamente en datos no etiquetados.

Dentro del aprendizaje automático, hay diversas tareas que permiten analizar y extraer patrones de los datos según los objetivos del estudio. Para modelos de aprendizaje supervisado, una de las más comunes es la clasificación (Greener et al. 2022; Walsh et al. 2021), donde el modelo aprende a asignar categorías o etiquetas a nuevos datos. Por ejemplo, categorizar la especie de ave en función de su canto (Knight et al. 2017) o detectar la presencia de carrizo invasor (*Phragmites australis*; Xiong et al. 2024). Otra tarea es la regresión (Greener et al. 2022), utilizada para predecir valores continuos, como la probabilidad de invasión en función de variables ambientales (Pasha y Reddy 2024), o la cantidad de especies exóticas en un ecosistema (Toussaint et al. 2014). Los algoritmos más utilizados para estas tareas son la regresión logística o lineal, máquinas de soporte vectorial (“*support vector machines*” [SVM]; Ben-Hur et al. 2008), árboles de decisión (incluyendo el más famoso: *Random forest*; Simon et al. 2023) y K-vecinos más cercanos (“*K-Nearest Neighbors*” [KNN]; Bzdok et al. 2018).

Para modelos de aprendizaje no supervisado, las tareas más comunes son la agrupación y la asociación. La agrupación (“*clustering*”; Jain et al. 2010) es una técnica que permite agrupar datos en función de su similitud sin necesidad de etiquetas previas. La tarea de asociación o afinidad busca descubrir relaciones entre variables o características dentro de un conjunto de datos (Anandhavalli et al. 2010). Tanto algoritmos de agrupación como afinidad han sido utilizados para identificar asociaciones de fitoplancton, definiendo grupos funcionales (Zhu et al. 2022), para identificar condiciones aceptables en el contexto de la restauración ecológica (Hamilton y Murphy 2020) o para delimitar especies a nivel taxonómico (Pyrón 2023). Los algoritmos utilizados para estas tareas se dividen en métodos de aglomeración jerárquica y métodos que requieren la definición del número de grupos, como *k-means* (Greener et al. 2022).

Además de estos dos tipos de aprendizaje (supervisado y no supervisado), existen opciones mixtas, como el aprendizaje semi-supervisado y el aprendizaje por refuerzo. En el aprendizaje semi-supervisado (Hastie et al. 2009) se emplea una combinación de datos etiquetados y no etiquetados, como por ejemplo para reconocer biodiversidad acuática con pocos registros etiquetados (Ma et al. 2024). En cambio, el aprendizaje por refuerzo (“*reinforcement learning*”; Lapeyrolerie et al. 2022) introduce un elemento adicional: la recompensa. En este tipo de aprendizaje, el modelo toma acciones, recibe información del entorno resultante y una evaluación de sus decisiones. Ha sido especialmente de interés para la toma de decisiones de conservación (Lapeyrolerie et al. 2022), como la optimización de recursos en gestión de fauna (Fonnesbeck 2008) o balancear costes y beneficios de la protección de la biodiversidad en diferentes áreas (Silvestro et al. 2022).

Existen diferentes aproximaciones para el aprendizaje en función del nivel de transparencia del modelo. Las tareas de regresión, clasificación, agrupación y asociación se pueden resolver con diferentes aproximaciones en función de si especificamos las variables a partir de las que queremos que el modelo aprenda (aprendizaje automático), o si dejamos que el modelo identifique las variables más relevantes (aprendizaje profundo). En el aprendizaje profundo (“*deep learning*”; Christin et al. 2019; Borowiec et al. 2022), el algoritmo detecta y extrae los atributos más relevantes de nuestros datos gracias a la descomposición de estos en múltiples capas y nodos que se relacionan de una forma similar a una red neuronal (Olden et al. 2008). Las redes neuronales convolucionales (“*convolutional neural network*” [CNN]) y las redes neuronales recurrentes (“*recurrent neural networks*” [RNN]) son las arquitecturas de redes neuronales más usadas en ecología (Christin et al. 2019) y pueden ser adaptadas tanto a tareas de regresión como clasificación. Algunos ejemplos en ecología incluyen la cuantificación del daño foliar (Loyani 2024) o la detección de peces a partir de videos submarinos (Fleure et al. 2024). Especialmente, en aprendizaje profundo, se ha popularizado el uso de aprendizaje por transferencia (“*transfer learning*”; Pan y Yang 2010), en el que se reutiliza o adapta unos datos nuevos a un modelo previamente entrenado con otros datos. Por ejemplo, bases de datos de imágenes públicas como las disponibles en ImageNet (Deng et al. 2009) pueden ser utilizadas para pre-entrenar un modelo descargable en línea que después se puede utilizar para identificación de tipos de plancton a través del paquete de R *EcoTransLearn* (Wacquet y Lefebvre 2022).

Existen diferentes opciones para elegir el mejor algoritmo una vez identificada la tarea a realizar. Una de las aproximaciones más utilizadas es comparar baterías de algoritmos, seleccionando el que resulta en mayor precisión (Cao et al. 2020). Otra aproximación es el ensamblaje de múltiples algoritmos para un resultado más robusto, combinando las ventajas de cada modelo

individual. Los métodos de ensamblaje más comunes son el *bagging* (promedio de múltiples modelos entrenados en subconjuntos de los datos) y el *boosting* (entrenamiento secuencial de modelos) (Dietterich 2000).

Los algoritmos de aprendizaje automático pueden tomar una gran variedad de tipos de datos. Por lo general, al disponer de variables específicas para el entrenamiento (en contraposición a archivos complejos como imágenes, videos o audios) el modelo resulta más interpretable, permitiendo examinar los atributos que son más relevantes para la predicción. Sin embargo, esto requiere un alto conocimiento del problema y un gran procesamiento de datos. Por ejemplo, para detectar diferentes clases de plancton a partir de imágenes, Orenstein et al. (2022) obtuvieron el tamaño, la forma y arquitectura, la presencia de extensiones (espinas u otras estructuras defensoras), transparencia, color o presencia de reservas lipídicas, a partir del examen individual de cada fotografía, y sugirieron el uso de aprendizaje profundo para reducir el tiempo de procesamiento manteniendo la precisión del modelo. La realidad detrás del uso de aprendizaje automático es que la gran mayoría del tiempo se invierte en el procesamiento de los datos ("*data wrangling*") y no en la propia programación del modelo. Por ese motivo es especialmente importante entender bien nuestros datos, plantear el objetivo de nuestro modelo y escoger en consecuencia el modelo a utilizar.

Estado del arte del uso de la IA en el estudio de invasiones biológicas

El uso de la IA en el estudio de invasiones biológicas avanza lentamente en comparación con su aplicación en otras áreas de la ecología. Para comprender las tendencias en este campo, realizamos una revisión sistemática de artículos publicados en revistas incluidas en la base de datos *Science Citation Index* (SCI) que utilizan IA en el estudio de especies invasoras. Empleamos los criterios de búsqueda de Han et al. (2023) que tenía por objetivo capturar los artículos en ecología que incluían el uso de la IA a través de la búsqueda de las palabras clave "*artificial intelligence*" o "*machine learning*" y en las áreas de "*ecology*" o "*environmental sciences*". No obstante, ampliamos los términos para incluir una mayor diversidad de algoritmos y palabras clave relacionadas con especies invasoras. La búsqueda realizada en *Web of Science* (WoS) fue: "TS = ((*"invasive species"* OR *invader** OR *"alien species"* OR *"non-native"* OR *neophyte** OR *neobiota** OR *"invasive alien species"* OR *exotic** OR *invasion* OR *"biological invasion"* OR *"invasive organisms"*) AND (*"machine learning"* OR *"artificial intelligence"* OR *"deep learning"* OR *"neural network"* OR *"support vector machine"* OR *"random forest"* OR *"reinforcement learning"* OR *"genetic algorithm"* OR *"supervised learning"* OR *"unsupervised learning"*)) AND PY = (1997-2024) AND DT = (Article) AND SU = (Agriculture OR Environmental Sciences OR Multidisciplinary Sciences OR Biochemistry Molecular Biology OR Geosciences Multidisciplinary) NOT TS = (cancer OR human OR medic* OR optical OR photon OR metasurface OR protein*)". La búsqueda, realizada el 30 de octubre de 2024 a través de *Web of Science* (WoS), identificó 415 artículos, que fueron posteriormente filtrados para excluir duplicados y estudios fuera del área de interés de este manuscrito. Algunos estudios fuera del área de interés fueron publicaciones relacionadas con procesos de invasión celular o el desarrollo de nuevas metodologías no invasivas. Tras esta criba, retuvimos 278 artículos. Para identificar el crecimiento del uso de la IA en las invasiones biológicas, detectar patrones en los modelos, tareas o grupos taxonómicos en los que se ha utilizado, de estos 278 artículos seleccionados, extrajimos información sobre especies estudiadas, algoritmos aplicados y objetivos del uso de la IA. Entre las diferentes aplicaciones de IA agrupamos los artículos en: detección, modelaje de la invasión (determinantes de la presencia de la especie, identificación de rasgos relacionados con la capacidad invasora, cuantificación de impactos), predicción de hábitat, y otras aplicaciones (generar datos de prueba, desarrollo de aplicaciones comerciales, análisis de literatura y simulaciones de gestión) (Fig. 2).

La producción de artículos sobre IA e invasiones ha crecido significativamente en los últimos años. Aunque el uso de la IA en este campo data de 1999, casi la mitad de los artículos (48.16 %) se han publicado entre 2022 y 2024 (Fig. 2A). Dichos estudios se han centrado principalmente en tres grupos taxonómicos: plantas (45.3 %), artrópodos (20.9 %) y peces (10.8 %) (Fig. 2B). Este sesgo taxonómico coincide con las tendencias globales de especies invasoras, donde las plantas son el grupo más numeroso, seguidas por insectos y otros taxones, como crustáceos y moluscos (Roy et al. 2024).

En la última década, la detección de especies invasoras ha sido la aplicación más destacada de la IA. Este crecimiento se refleja en el aumento exponencial de publicaciones, con un máximo de 45 artículos en 2024, a pesar de ser un año aún incompleto al momento de la revisión (30 de octubre; Fig. 2A). Las primeras aplicaciones de IA en invasiones biológicas se centraron en el modelado y la predicción. Por ejemplo, en 1999, Aussem y Hill utilizaron redes neuronales para simular la expansión y biomasa del alga invasora comúnmente llamada alga asesina (*Caulerpa taxifolia*) en el Mediterráneo. También en esos años, Iguchi et al. (2004) construyeron modelos de distribución para determinar el potencial invasor de diferentes especies de perca utilizando un algoritmo genético entrenado con los datos climáticos de las zonas que actualmente ocupan esas especies. Considerando todo el periodo, 1999-2024, las aplicaciones de la IA en invasiones biológicas han variado según el taxón, con predominancia por la detección en plantas (p. ej., Marziales et al. 2021), modelado en peces (p. ej., Epstein et al. 2018) y predicción en artrópodos (p. ej., Gil-Tapetado et al. 2024) (Fig. 2C).

Los algoritmos más utilizados en los estudios revisados incluyen modelos de regresión y clasificación. Los modelos de regresión han sido aplicados para predecir la presencia de especies en función de variables climáticas (p. ej., Yang et al. 2024 o Urza et al. 2024), mientras que los modelos de clasificación han sido utilizados, por ejemplo, para identificar huevos de peces invasores a partir de datos morfológicos (Camacho et al. 2019). En cambio, los modelos de agregación y el aprendizaje por refuerzo han sido menos comunes. Entre los modelos de agregación se encuentran aplicaciones como agrupar los patrones de comportamiento de un caracol invasor en función de la temperatura (Bae et al. 2021). Solo cuatro estudios aplicaron aprendizaje por refuerzo en nuestra búsqueda, principalmente en simulaciones complejas, como interacciones entre especies (Prober et al. 2012; Blonder et al. 2024) o modelos de gestión óptima en ecosistemas acuáticos (Potapov 2009).




Figura 2. Resumen gráfico de la revisión sistemática del uso de inteligencia artificial (IA) para el estudio de especies invasoras en la literatura científica. **A)** Cronograma de los artículos encontrados (1999–2024, búsqueda el 30 de octubre de 2024) y la clasificación de la aplicación por la cual se utiliza la IA. **B)** Mapa de árbol representando el número de estudios en diferentes grupos taxonómicos, destacando los que agruparon mayor número de artículos: plantas, artrópodos y peces. **C)** Mapa de puntos relacionando las diferentes tareas de la IA con los taxones para los que se encontraron más de cinco artículos. Mientras que el tamaño del punto representa el número relativo de artículos totales, la intensidad de color representa la tarea mayoritaria en cada grupo taxonómico (que coincide con el tamaño de punto más grande para cada taxón).

Figure 2. Graphical summary of the systematic review of the use of artificial intelligence (AI) for studying invasive species in scientific literature. **A)** Published articles timeline (1999–2024, search conducted on October 30th, 2024) and the classification of applications for which AI was used. **B)** Tree map illustrating the number of studies across different taxonomic groups, highlighting those with the highest number of articles: plants, arthropods, and fishes. **C)** Scatterplot linking different AI tasks to the taxonomic groups with more than five articles. The size of the points represents the relative number of total articles, while colour intensity indicates the predominant task for each taxonomic group (matching the largest point size for each taxon).

Descubrir: Métodos de detección de especies invasoras con IA

La detección de especies invasoras es una de las aplicaciones más importantes de la IA en la disciplina de las invasiones biológicas, especialmente en los últimos años (Fig. 2). La detección, y especialmente la detección temprana, es crucial en la gestión de especies invasoras para reducir sus impactos a largo plazo (Latombe et al. 2017). Las mejoras en la captura (Nazir y Kaleem 2021) y procesamiento de imágenes (Wang et al. 2010; Krizhevsky et al. 2017), así como la disponibilidad de imágenes digitales (Depauw et al. 2022) y satelitales (Cavender-Bares et al. 2022), han facilitado mucho el desarrollo de múltiples herramientas para la identificación automática de especies invasoras (Martinez et al. 2020).

La mayoría de los estudios de detección que resultaron de la revisión sistemática realizada, se basaron en imágenes como fuente principal de datos. Más del 90 % de los artículos revisados (correspondiente a 102 artículos) utilizaron imágenes obtenidas de satélites (32.4 %), cámaras digitales (29.4 %), drones o vehículos controlados remotamente (27.5 %) y tipos de cámaras o sensores especializados (10.8 %; imágenes termales, cámaras hiperspectrales, LiDAR, etc.). En el 9 % de artículos restantes se han empleado datos alternativos como grabaciones de audio (Gugele et al. 2021; Wood et al. 2024), trayectorias de movimiento (Wiegler et al. 2022) o características morfológicas (Camacho et al. 2019).

Los algoritmos de aprendizaje profundo, especialmente las CNN, son predominantes en la detección de especies invasoras. Estos algoritmos destacan por su capacidad para procesar datos visuales sin necesidad de variables predefinidas (García-Navarrete et al. 2024). Las CNN, diseñadas específicamente para analizar imágenes, han sido utilizadas en numerosos estudios para identificar plantas, insectos y animales invasores (p. ej., Kulkarni y Minin 2023; Cardoso et al. 2024; Keerthinathan et al. 2024). Es de especial interés el que las CNN se pueden construir con diferentes arquitecturas (diferente número y estructura de capas y neuronas) y existen algunas arquitecturas predefinidas de interés, como AlexNet (Zhuang et al. 2023), ResNet (Bao et al. 2024), EfficientNet (Devi et al. 2023), o YOLO (p. ej., Matsushashi et al. 2024; Salcedo et al. 2024), las cuales son discutidas en más extensión a continuación.

Las imágenes satelitales ofrecen una herramienta poderosa para la detección de plantas invasoras. Estudios como el de [Castillo et al. \(2008\)](#) marcaron el inicio de esta línea de investigación, utilizando imágenes de MODIS 250 m RGB para detectar la planta acuática *Lemna obscura*. Hasta el momento, únicamente encontramos el uso de imágenes de satélite para la detección de plantas invasoras, probablemente por la naturaleza sésil de estas, que permite en principio obtener ocurrencias completas en ciertas áreas a partir de imágenes de satélite multispectrales ([Wang et al. 2013](#); [Meerdink et al. 2024](#)). La ventaja del uso de imágenes de satélite respecto a métodos más tradicionales como censos poblacionales de campo ([Salguero-Gómez y Gamelon 2021](#)) o estudios fenológicos mediante observación directa ([Fenner 1998](#)), radica en la cobertura espacial y temporal, que permite monitorear grandes áreas y realizar análisis estacionales ([Cavender-Bares et al. 2022](#); [Katal et al. 2022](#)). No obstante, una desventaja de las imágenes de satélite multispectrales es su actual resolución. Actualmente, la máxima resolución se encuentra entre 0.3 y 0.5 m (EOSDA LandViewer), pero la eficiencia de la detección de especies dependerá, no solo del tamaño de estas sino también del contraste en los hábitats que ocupa. Por ejemplo, se ha demostrado que puede ser útil para la detección de ballenas o elefantes en entornos homogéneos, pero no para ñus en biomas complejos ([Hollings et al. 2018](#)). En algunas especies, el uso de imágenes en diferentes momentos permitió una detección más precisa, como al principio de la temporada de crecimiento y durante el proceso de senescencia en praderas ([Raab et al. 2018](#)), o antes y durante la floración de la acacia azul (*Acacia saligna*; [Marzalletti et al. 2021](#)).

El uso de cámaras digitales (incluyendo cámaras montadas en vehículos remotos) agrupa la mayor cantidad de artículos que usan IA para la detección de especies invasoras (29.4 % cámaras digitales, 27.5 % vehículos remotos). Por ejemplo, [Yang et al. \(2022\)](#) construyó una base de datos con 3000 imágenes de semillas de 12 especies invasoras para entrenar una CNN para detectarlas en el tránsito global. En este trabajo, los autores utilizaron una de las arquitecturas de CNN comentada anteriormente y que ha ganado más fama últimamente, el modelo YOLO ("You Only Look Once", traducido como: solo miras una vez) que también se ha utilizado para detectar la avispa asiática (*Vespa velutina*; [O'Shea-Wheller et al. 2024](#)), la chinche hedionda (*Halyomorpha halys*; [Palazzetti et al. 2024](#)), o ciervo de Timor (*Rusa timorensis*; [Sudholz et al. 2022](#)). Algunos de los modelos comentados en el anterior párrafo utilizan no solo una arquitectura de red neuronal predefinida, sino también una red pre-entrenada (aprendizaje por transferencia), reduciendo así la demanda de datos. Este es el caso de [Gupta et al. \(2020\)](#) para la detección de plántulas no deseadas en base a fotografías de RGB, o [Ulhaq et al. \(2021\)](#) para detectar cerdos, conejos y canguros en base a imágenes térmicas.

La disponibilidad de imágenes digitales en línea ha permitido aplicaciones de detección de especies invasoras sin recogida de datos en campo. Por ejemplo, las imágenes de *Google Street View* permiten detectar especies invasoras a lo largo de carreteras ([Kotowska et al. 2021](#)). También imágenes en redes sociales (Flickr, Twitter, Instagram, y Facebook) han permitido la detección temprana de la hierba de la pampa (*Cortaderia selloana*; [Cardoso et al. 2024](#)) y datos de redes sociales en general también son especialmente útiles para entender la dimensión social de las especies invasoras ([Novoa et al. 2025](#)).

El uso de drones para el monitoreo de especies invasoras ha incrementado rápidamente en la última década ([Dash et al. 2019](#); [Singh et al. 2024](#)). En su revisión, Singh et al. destacaron que la mayoría de los estudios hasta la fecha se centran en probar diferentes algoritmos de aprendizaje automático y profundo para clasificar especies invasoras, y menos estudios que presentan monitoreo de estas. En este contexto, las imágenes de dron resultan especialmente útiles para cubrir grandes extensiones en áreas remotas o poco accesibles ([Fig. 3](#)), obteniendo así de forma precisa la cobertura vegetal ([Kattenborn et al. 2020](#); [Bravo-Díaz et al. 2024](#)). El estudio de [James y Bradshaw \(2020\)](#) presenta una metodología para la detección de plantas con drones durante el vuelo, donde en base a redes neuronales y el desarrollo en la aplicación DJI SDK UXSDKDEMO (<https://github.com/DJI-Mobile-SDK-Tutorials/Android-UXSDKDemo>) se muestra en pantalla y en vivo las áreas donde se encuentra la especie objetivo, de alto interés para especies invasoras. No solo para detectar la presencia de individuos sino también para su conteo, el uso de imágenes de dron ha demostrado ser más eficiente que el conteo humano ([Hodgson et al. 2018](#)).

Las imágenes térmicas o el uso de videos pueden proporcionar más precisión que las imágenes digitales para detectar algunas especies invasoras en particular. La detección de mamíferos u otros endotermos ([Stone y Davis 2024](#)) es especialmente eficiente a través de imágenes térmicas ([Ulhaq et al. 2021](#); [Gonzalez et al. 2016](#)). El uso de videos para la detección de especies invasoras proporciona mucha resolución temporal, así como un mayor número de imágenes totales ([Gonzalez et al. 2016](#); [Ulhaq et al. 2021](#); [Sudholz et al. 2022](#); [Dyrmann et al. 2024](#)). Los videos resultan especialmente útiles para el monitoreo de organismos móviles, incluyendo animales marinos ([Fleure et al. 2024](#)) o mamíferos terrestres ([Ulhaq et al. 2021](#)) y también la detección en movimiento, como la detección de plantas invasoras en carreteras a partir de videos de un coche con alta velocidad ([Dyrmann et al. 2024](#)).

La detección de especies invasoras es una de las aplicaciones más avanzadas de la IA en invasiones biológicas, especialmente mediante el uso de imágenes. Satélites, drones y cámaras digitales destacan como las principales fuentes de datos, mientras que algoritmos de aprendizaje profundo, como redes neuronales pre-entrenadas, lideran las metodologías. Las tecnologías emergentes, como imágenes térmicas, videos y datos de redes sociales, han ampliado las capacidades de detección, permitiendo identificar especies en territorios amplios, áreas remotas y entornos dinámicos. Estos avances consolidan la IA como una herramienta esencial para la gestión y el monitoreo de especies invasoras.



Figura 3. Detección, modelaje y predicción de plantas invasoras a partir de imágenes de dron e inteligencia artificial (IA). La captura de datos demográficos a partir de aplicar la IA en imágenes de dron permite capturar el tamaño de la población manteniendo las distancias con especies invasoras dañinas como la chumbera (**A**), acceder a terrenos difíciles (**B**) y cubrir grandes extensiones (**C**). Gracias al entrenamiento de modelos de aprendizaje automático podemos detectar nuevos individuos, cuantificar tasas vitales (supervivencia, crecimiento y reproducción), evaluar el éxito de programas de erradicación, identificar patrones de distribución espacial o proyectar la dinámica poblacional en el tiempo.

Figure 3. Detection, modelling, and prediction of invasive plants using drone images and artificial intelligence (AI). The use of AI on drone imagery enables the capture of demographic data, allowing the estimation of population size while maintaining safe distances from harmful invasive species such as prickly pear cactus (**A**), accessing difficult terrains (**B**), and covering large areas (**C**). Through machine learning, it is possible to detect new individuals, quantify vital rates (survival, growth, and reproduction), assess the success of eradication programs, identify spatial distribution patterns, or project population dynamics over time.

Modelar: importancia de variables y adquisición de datos

Prácticamente un 30 % de los artículos (de un total de 278) que utilizan IA en nuestra revisión de la literatura lo hicieron para modelar algún aspecto del proceso de invasión, sin incluir la proyección de su distribución. Estas investigaciones abordan principalmente dos áreas: la contribución de conjuntos de predictores para variables de interés y la mejora en la adquisición de datos. Este enfoque incluye estudios que exploran atributos invasores, demografía a partir de imágenes y análisis de impactos.

La IA permite identificar la importancia relativa de predictores sobre variables de interés de manera eficiente. Los algoritmos de aprendizaje automatizado facilitan el manejo de relaciones no lineales y la identificación de factores clave en procesos biológicos. Entre las aplicaciones destacadas en invasiones biológicas se encuentran la explicación de la presencia o abundancia de especies (Sampaio Franco et al. 2021; White et al. 2022), la riqueza de especies invasoras (Toussaint et al. 2014; Santoianni et al. 2024), la dispersión de especies (Pontin et al. 2011) y el éxito de programas de erradicación (Xiao et al. 2018). También destacamos la existencia de múltiples trabajos que se enfocan en identificar características que determinan el comportamiento invasor mediante bases de datos de atributos (Kolar 2004; Keller et al. 2011; Philibert et al. 2011).

Aparte de determinar la importancia de factores, otra aplicación de la IA para modelar las invasiones biológicas es ampliar o acelerar la captura de datos. El aprendizaje automático y profundo se han utilizado para entrenar modelos que permiten una adquisición de datos más rápida y menos costosa con una alta precisión (Fig. 3). El desarrollo de cámaras y lentes ha permitido plantear la sustitución de las largas visitas al campo por el vuelo de drones o los costosos análisis al laboratorio por fotografías hiperespectrales. Por ejemplo, gracias al desarrollo de métodos de reconstrucción 3D es posible estimar el volumen corporal de animales de forma remota a través del vuelo de un dron (Los et al. 2023; Stone y Davis 2024). En invasiones biológicas se han empleado imágenes para caracterizar el crecimiento y estructura poblacional (Benzer y Benzer 2020; Bednarsek et al. 2022), componentes esenciales para cuantificar las dinámicas de invasión. Otra fuente de datos que la IA nos permite explotar mejor es la literatura publicada. Por ejemplo, para entender las aproximaciones en la restauración forestal, Nunez-Mir et al. (2015) hacen una revisión sistemática con análisis de contenido automático, lo que denominamos “big literature” (Bolaños et al. 2024).

La IA se ha utilizado no solo para entender los determinantes de la invasión, o cuantificar su demografía, sino también para evaluar sus impactos. Por ejemplo, para cuantificar los impactos específicos sobre otra especie, como cuantificar el nivel de daño foliar sobre hojas de tomate por parte de la polilla del tomate (*Tuta absoluta*; Loyani 2024). De forma similar, el uso de la IA también resulta útil para reducir datos multidimensionales, como la composición del microbioma del suelo (Li et al. 2022) o propiedades fisicoquímicas (Zhang et al. 2023) y encontrar marcadores de interés que nos ayuden a detectar los impactos de la invasión.

La IA se utiliza en el modelado de procesos de invasión, destacando su capacidad para identificar factores clave, acelerar la adquisición de datos y evaluar impactos. Herramientas como drones, análisis hiperspectrales y algoritmos avanzados han optimizado el estudio de atributos invasores, demografía y evaluación de daños específicos. Además, la aplicación de IA a grandes bases de datos, como literatura científica, amplía su potencial para abordar las complejidades de las invasiones biológicas.

Predecir: Modelos de distribución de especies invasoras

Los modelos de distribución de especies ("*species distribution models*" [SDMs]; Pearson 2003) son herramientas fundamentales para predecir la idoneidad ambiental de las especies (Guisan et al. 2017). Por esta razón, han sido ampliamente empleados para predecir la distribución potencial de las especies invasoras (Guisan et al. 2014). Los SDMs capturan la relación entre los registros de presencia de especies y diferentes predictores (p. ej., temperatura, precipitación o tipo de suelo), utilizando estas relaciones para mapear la probabilidad de presencia de una especie invasora (Davis et al. 2024).

La mayoría de los estudios aquí revisados emplearon IA para construir SDMs, aunque existen otras aplicaciones predictivas. De los 91 artículos sobre predicción, el 93 % utilizaron IA para SDMs, mientras que el resto construyó predicciones basadas en cambios de uso del suelo (Martínez-Vega et al. 2017) o crecimiento bajo diferentes condiciones ambientales (Javed et al. 2022). El interés de los SDMs reside en el gran potencial que tienen incluso cuando disponemos de pocos datos, permitiendo construir el nicho ecológico de especies invasoras y cuantificar cambios en este, o el potencial invasor en nuevas áreas (Jeschke y Strayer et al. 2008; Barbosa et al. 2012).

El uso de algoritmos para SDMs ha evolucionado, reflejando cambios en las tecnologías disponibles, desde los algoritmos genéticos al uso de baterías de algoritmos y su ensamblaje. En 2008, Jeschke y Strayer revisaron los métodos estadísticos más utilizados para SDMs, destacando, entre otros, la regresión logística, los modelos lineales generalizados (Lehman et al. 2002), los modelos aditivos generalizados (Leathwick et al. 2006), los árboles de regresión y clasificación (Elith et al. 2006), las redes neuronales (Pearson et al. 2002) y los algoritmos genéticos (Stockwell y Peters 1999). Sin embargo, en 2012, Barbosa et al. destacaban que el algoritmo genético GARP ("*Genetic Algorithm for Rule-set Production*"; Stockwell y Peters 1999) fue el más usado para el mismo propósito. Este algoritmo se basa en los principios de la selección natural para determinar un conjunto de atributos que mejor optimizan la variable a predecir, incluyendo procesos de cruce de atributos y mutación (Stockwell y Peters 1999). Debido a su uso extendido, existe un paquete de R específico (GARPTools) para la construcción y evaluación de SDMs con GARP (Haase et al. 2021).

En nuestra revisión sistemática encontramos la predominancia del uso de un solo algoritmo de aprendizaje automático, especialmente GARP y también Maxent ("*Maximum Entropy Modelling*"; Phillips et al. 2006). Maxent es un método de modelado estadístico que busca la distribución más uniforme (máxima entropía) que se ajuste a los datos de ocurrencia y a las restricciones ambientales disponibles. Maxent es popular en la comunidad ecológica por su capacidad para trabajar con datos de presencia únicamente y por generar modelos robustos incluso con conjuntos de datos incompletos o limitados (Jiang et al. 2018; Adepoju et al. 2020; Morey y Venette 2020). A partir de aproximadamente 2016 ya no hay artículos usando GARP, mientras que algoritmos basados en árboles de decisiones como los *random forest* y redes neuronales ganan terreno, así como el uso de baterías de algoritmos en vez de uno de solo. Por ejemplo, Pasha y Reddy (2024) ajustaron múltiples modelos incluyendo Maxent, modelos lineales generalizados, modelos aditivos generalizados, redes neuronales, modelo potenciado generalizado y *random forest*, seleccionando el que presenta mejor ajuste para predecir la distribución del arbusto mezquite (*Prosopis juliflora*) a distintos escenarios de cambio climático. Otros estudios no solo compararon todos estos modelos, sino también ensamblan sus resultados para producir una distribución final. Tal es el caso de Mathur y Mathur (2024), que utilizaron ensamblaje de modelos para predecir la distribución de la chumbera (*Opuntia ficus-indica*) bajo múltiples escenarios de cambio climático. Los autores incluyeron modelos lineales generalizados, modelos aditivos generalizados, *support vector machine*, árboles de decisión, *random forest*, Maxent, MARS ("*multivariate adaptive regression splines*") y redes neuronales, combinando las proyecciones resultantes de cada modelo en una sola capa promedio. Es también el caso de Nisin et al. (2023) que proyectó la distribución del pez piracú (*Arapaima gigas*) a través de promediar las probabilidades de presencia de la especie de una selección de los mejores modelos entre 10 algoritmos.

Aunque útiles, los SDMs presentan limitaciones importantes que deben considerarse (Elith et al. 2011). Existen múltiples artículos revisando cómo construir SDMs de forma apropiada (p. ej., Araújo et al. 2019; Zurell et al. 2020; Sillero et al. 2021; Hui 2023; Soley-Guardia et al. 2024; Davis et al. 2024). Sin embargo, estos modelos se basan en correlaciones, no en causalidad, y son sensibles a los datos de ocurrencias, que suelen ser imperfectos (Chen et al. 2013). Por ello, los SDMs mecanicistas, que incorporan procesos ecológicos explícitos, son una alternativa prometedora, especialmente para especies invasoras (Fenollosa et al. 2025), aunque requieren una alta disponibilidad de datos (Briscoe et al. 2019).

Gestión automatizada de especies invasoras con IA

La inteligencia artificial proporciona herramientas clave para la gestión de especies invasoras, abordando desafíos complejos con mayor eficacia y precisión. Las capacidades analíticas y predictivas previamente discutidas encuentran aplicaciones prácticas en la detección temprana, la delimitación de áreas afectadas, y el diseño de estrategias de control y erradicación. Estas herramientas están transformando la gestión de invasiones biológicas al optimizar la priorización de acciones y reducir costos operativos. A continuación, examinamos cómo estas tecnologías están revolucionando las prácticas de manejo y control de especies invasoras.

La detección temprana es una de las aplicaciones más efectivas de la IA en la gestión de especies invasoras. Herramientas como el monitoreo acústico en tiempo real se han implementado para rastrear la expansión del búho barrado (*Strix varia*) en América del Norte (Wood et al. 2024). Además, los modelos de distribución han ayudado a identificar áreas de riesgo, como espacios protegidos (Dar et al. 2023) o regiones afectadas bajo escenarios de cambio climático (Zhao et al. 2023a), priorizando así los esfuerzos de gestión.

El procesamiento avanzado de imágenes ha permitido el desarrollo de herramientas autónomas para la identificación y control de plantas invasoras. En el ámbito agrícola, productos comerciales emplean imágenes de alta resolución (AutoWeed, <https://autoweed.com.au/>), hiperspectrales (Ladybird, Universidad de Sidney, <https://robohub.org/robots-ladybird/>) o termales (Weedseeker 2, Trimble Agriculture, <https://ptxtrimble.com/es>) para la detección y eliminación precisa de hierbas no deseadas (Roberts y Florentine 2024). En ecosistemas acuáticos, un pequeño barco no tripulado utiliza aprendizaje profundo basado en YOLO para detectar y recolectar automáticamente algas o plantas acuáticas invasoras, como *Lemna minor*, a través de videos capturados en tiempo real (Salcedo et al. 2024). De forma similar, Patel et al. (2019) usan redes neuronales para detectar múltiples plantas acuáticas invasoras a partir de señales hidroacústicas tomadas bajo el agua, y lo acoplan a pequeños barcos autónomos que liberan pequeñas dosis de herbicida al encontrar las plantas objetivo.

La IA también se emplea en soluciones interactivas y específicas para gestionar fauna invasora. Un ejemplo es el uso de sistemas de captura con cebo automatizado, como el desarrollado por Charlton et al. (2024), que utiliza algoritmos para clasificar especies invasoras y dispensar cebos personalizados para fauna invasora. Asimismo, tecnologías basadas en aprendizaje profundo permiten ahuyentar aves invasoras mediante la detección de su canto y la reproducción de sonidos específicos para proteger cultivos (Chen et al. 2024). El uso de robots basados en animales permite la interacción directa y promete ser clave para la conservación de la biodiversidad (Schmickl y Romano 2024). Por ejemplo, se han utilizado robots mimetizando predadores para proteger renacuajos nativos de peces invasores como la gambusia (*Gambusia affinis*) (Polverino et al. 2022).

Las tecnologías basadas en IA facilitan la detección de introducciones o reintroducciones a través de aplicaciones innovadoras. Por ejemplo, Yang et al. (2022) entrenó un modelo para identificar semillas invasoras mediante imágenes captadas en controles fronterizos, mientras que Kulkarni y Di Minin (2023) han utilizado IA para rastrear el comercio ilegal de fauna a partir de fotografías en plataformas digitales.

La IA transforma la gestión de especies invasoras mediante herramientas que permiten la detección temprana, la interacción en tiempo real y la automatización de acciones específicas. Tal y como hemos presentado en esta sección, robots y sistemas autónomos con IA facilitan la gestión a tiempo real, mientras que el uso de aprendizaje profundo y análisis de datos mejora la vigilancia continua y la evaluación de los esfuerzos de erradicación. Estas innovaciones no solo aumentan la eficiencia de las intervenciones, sino que también reducen significativamente los costos operativos, posicionando a la IA como un componente esencial en la lucha contra las invasiones biológicas.

Paso a paso usando IA en tu proyecto con especies invasoras y practicas éticas

El ciclo de vida de los proyectos de datos proporciona un marco estructurado para implementar la IA (Fig. 4). Este proceso circular, regresivo en ocasiones, comienza con la delimitación del problema y finaliza con la comunicación de resultados. En este apartado, se examinan los componentes clave de este ciclo, destacando consideraciones específicas como fuentes de datos y aspectos éticos relevantes para las invasiones biológicas.

La delimitación del problema es el primer paso y determina el enfoque de todo el proyecto de IA. Es crucial definir la tarea a resolver (clasificación, regresión o agregación), el tipo de datos necesarios y los algoritmos a utilizar. Es importante describir qué categorías vamos a querer clasificar si nuestra tarea es de clasificación y el rango de la variable de interés si nuestra tarea es de regresión, en relación con nuestros datos. Por ejemplo, clasificar colores de flores de una especie invasora requeriría categorías específicas de los colores posibles y dependiendo del tipo de datos utilizados, una categoría adicional de "sin flor", o hasta podríamos usar el ángulo de color o matiz (en inglés: Hue) como definición numérica del color y explorar qué factores contribuyen a la escala de color a través de la regresión. Los análisis exploratorios pueden llevar a ajustes en el modelo, subrayando la importancia de mantener flexibilidad en el diseño experimental.

Una vez planteado el problema y el diseño experimental procederemos a la colección de datos. Como hemos visto en la revisión sistemática, muchos estudios hacen uso de bases de datos o imágenes de acceso libre, permitiendo extender las dimensiones temporales y espaciales de los proyectos (Coughlan et al. 2020; Heger et al. 2021) (Tabla 1). Estas bases de datos proporcionan datos de la ecología, estadio invasor, fechas de introducción, atributos o impactos descritos de especies invasoras, que podemos utilizar para análisis comparativos (Tabla 1). Otras fuentes de datos que son de interés para el monitoreo de especies invasoras son las imágenes satelitales e imágenes de redes sociales. En España destacamos el centro nacional de información geográfica (www.centrodedescargas.cnig.es) que centraliza bases de datos de imágenes satelitales. Adicionalmente, hace poco se desarrolló una base de datos de imágenes de dron, GeoNadir (<https://geonadir.com/>) que podrían proporcionar mayor resolución en sitios específicos, especialmente para el entrenamiento de detección vegetal. Debido a la importancia de la especie humana en las invasiones biológicas, datos de redes sociales, tendencias en Google o comercio electrónico pueden ser especialmente útiles para el monitoreo de procesos de invasión (Novoa et al. 2025). Para la captura de datos en portales web recomendamos las técnicas de raspado web (*Web scrapping*) que permite la extracción de contenido HTML de múltiples páginas de forma automática como a partir de anuncios de venta de plantas para detectar tráfico ilegal (Maher et al. 2023).




Figura 4. Elementos clave en el ciclo de vida en los proyectos de datos para el estudio de especies invasoras, desde la identificación del problema y la aplicación de la inteligencia artificial (IA) (detectar, modelar, predecir), hasta la comunicación de resultados, que puede llevar a la identificación de nuevas preguntas. El diagrama muestra los elementos más importantes para la integración de la IA en nuestra investigación. Para generalidades sobre un diseño experimental adecuado en ecología recomendamos Marshall (2024).

Figure 4. Key elements in data science lifecycle for the study of invasive species. The lifecycle spans from problem identification and artificial intelligence (AI) application (detection, modelling, prediction) to the communication of results, which may lead to the formulation of new questions. The diagram shows the most important elements for the integration of AI in our experiment. For generalities on appropriate experimental design in ecology we recommend Marshall (2024).

La elección del enfoque de aprendizaje condiciona los resultados y la metodología del proyecto. Mientras el aprendizaje profundo es ideal para datos complejos como imágenes, requiere grandes volúmenes de datos. En cambio, el aprendizaje automatizado es más transparente y adecuado para entender condicionantes, pero podría necesitar un procesamiento previo de las variables de interés. Para el análisis de imágenes existen algunos complementos para automatizar esta extracción de atributos para entrenar modelos de aprendizaje automático como el CIMMYT MaizeScanner en ImageJ (<https://github.com/sckefauver/CIMMYT>) o los paquetes *patternizes* (Van Belleghem et al. 2018), *pliman* (Olivoto 2022) o *recolorize* (Weller et al. 2024) en R. En problemas más simples, o con pocos datos, los métodos estadísticos tradicionales pueden ser más eficaces (Ley et al. 2022).

Diferentes lenguajes de programación destacan en su potencial para ajustar modelos de IA. Programas como R, Python o MATLAB son los más utilizados debido a la gran comunidad de usuarios y al desarrollo de paquetes o librerías específicos para la implementación de algoritmos de aprendizaje automático y profundo. Entre los programas de acceso libre, R solía recoger la mayor parte de la comunidad de ecólogos por lo que encontraremos mucho material de guía especializado, pero Python dispone de librerías mucho más adecuadas para el entrenamiento de modelos con imágenes. Para ambos programas hay una gran cantidad de ejemplos de aplicaciones de IA sobre diferentes tipos de datos en el portal de competiciones de Kaggle, incluyendo ejemplos con especies invasoras (<https://www.kaggle.com/competitions/invasive-species-monitoring/>). Si no disponemos de un ordenador capaz de procesar cierta cantidad de datos, recomendamos el uso del portal de Google Colab, que nos permite codificar en diferentes lenguajes de programación y procesar los datos en línea, sin limitación por la GPU de nuestro ordenador.

Las aplicaciones sin programación amplían el acceso a la IA, haciendo más inclusivo su uso en invasiones biológicas. En caso de que no tengamos experiencia en programación existen múltiples aplicaciones específicas con interfaz gráfica que nos permiten el uso de aprendizaje automático y profundo sin necesidad de programar. Empezando por las aplicaciones más específicas, encontramos que algunos artículos de la revisión sistemática realizada incluyeron una aplicación web que permite el uso directo del modelo ya entrenado, como *WhoseEgg* que permite subir datos de morfología de diferentes huevos y en base a un modelo ya entrenado clasifica la especie y si es invasora o no (Goode et al. 2023). De forma similar, Palazzetti et al. (2024) presenta una aplicación para Android que permite la detección a tiempo real de la chinche hedionda (*H. halys*) a partir de imágenes usando un modelo entrenado con redes neuronales. De forma más general, no específico para plantas invasoras, destacamos que existen complementos que podemos añadir a herramientas de análisis espacial para segmentar individuos invasores a partir de imágenes, como por ejemplo el complemento de acceso abierto para QGIS GeoSAM basado en el famoso

modelo “*segment anything*” (Zhao et al. 2023b; Prado Osco et al. 2023). Un último ejemplo del potencial de aplicaciones concretas para acortar distancias con la IA son portales como *liner.ai* o *Roboflow*. Estos portales con modelo *freemium* (parte de los servicios son gratuitos) permiten de forma muy simple entrenar diferentes algoritmos en base a imágenes, con una interfaz muy amigable y permitiendo el etiquetado colaborativo de imágenes.

Tabla 1. Selección de bases de datos de interés para proyectos de inteligencia artificial (IA) con especies invasoras, incluyendo bases de datos específicamente para especies exóticas e invasoras (en rojo), pero también bases de datos globales que incluyen especies invasoras (turquesa). Abr.: abreviación.

Table 1. Selection of databases of interest to develop artificial intelligence (AI) projects with invasive species, including databases that target exotic and invasive species specifically (red) but also global databases that include invasive species (turquoise). Abr: abbreviation.

Base de datos	Abr.	Especies objetivo	Región	Tipo de datos	Referencia
Invasive Species Compendium of the Centre for Agriculture and Bioscience International	CABI	Invasoras	Global	Identificación, impactos, mecanismos de control y literatura de referencia	www.cabidigitallibrary.org/journal/cabicompendium
European Alien Invasive Species Information Network	EASIN	Invasoras	Europa		www.easin.jrc.ec.europa.eu/easin
Global Invasive Species Database	GISD	Invasoras	Global		www.iucngisd.org/gisd/
European Network on Invasive Alien Species	NOBANIS	Exóticas e invasoras	Europa		www.nobanis.org/
Global Naturalized Alien Flora database	GLONAF	Plantas exóticas e invasoras	Global		Van Kleunen et al. 2019
Global Register of Introduced and Invasive Species	GRIIS	Exóticas e invasoras	Global	Registros temporales e información biológica	Pagad et al. 2018
Spatio-temporal dataset of global invasive and alien species and their traits	GIATAR	Exóticas e invasoras	Global		Saffer et al. 2024
Global Alien Species First Record Database	First record Database	Invasoras	Global		www.dataportal.senckenberg.de/dataset/global-alien-species-first-record-database
Economic costs of biological invasions worldwide	InvaCost	Invasoras	Global		Diagne et al. 2020
Global Impacts Dataset of Invasive Alien Species	GIDIAS	Invasoras	Global		Bacher et al. 2025
Botanical Information and Ecology Network	BIEN	Plantas	Global	Ocurrencias, rasgos y filogenia	Maitner et al. 2018
TRY	TRY	Plantas	Global	Rasgos funcionales	Kattge et al. 2020
COMPADRE Plant Matrix Database	COMPADRE	Plantas	Global	Datos demográficos	Salguero-Gómez et al. 2015
COMADRE Animal Matrix Database	COMADRE	Animales	Global	Datos demográficos	Salguero-Gómez et al. 2016
PADRINO IPM Database	PADRINO	General	Global	Datos demográficos	Levin et al. 2022
Global biodiversity information facility	GBIF	General	Global	Occurencias	www.gbif.org
iNaturalist	iNaturalist	General	Global	Occurencias e imagenes geolocalizadas	www.inaturalist.org

El uso de la IA es cada vez una tarea más sencilla, pero no está exenta de responsabilidad. Los patrones que observamos gracias a los modelos de IA dependen (y se limitan) a las variables y datos que hemos considerado y por ende están sujetos a sesgos. Este agosto de 2024 entró en vigor el primer marco jurídico sobre IA en Europa (Ley de AI de la UE, Reglamento 2024/1689) que ahora se está implementando en los estados miembros. En este marco se ha redactado el Código de buenas prácticas de IA de propósito general (GPAI) que se publicará durante la primavera de 2025. Sin embargo, queremos destacar algunos aspectos esenciales, específicamente sobre el uso de algoritmos de aprendizaje automático y considerando los tipos de datos mayoritariamente usados en el campo de las invasiones biológicas.

Entre buenas prácticas podemos encontrar aspectos técnicos de la construcción de los modelos, aspectos de representatividad de los datos, aspectos de calidad e interpretación del modelo, consideraciones éticas y de privacidad y principios FAIR (Fáciles de encontrar, accesibles, interoperables y reutilizables) (Heil et al. 2021).

En cuanto a los aspectos técnicos, algunos aspectos imprescindibles es asegurar que guardemos una parte de los datos representativa para la comprobación a través de técnicas de muestreo estructurado y probando diferentes particiones de datos. Otro aspecto técnico es la inclusión de muchas variables colineales en algunos modelos de aprendizaje automático. Recomendamos revisar las demandas de cada algoritmo específicamente, así como revisar los parámetros del modelo analizando su impacto de forma estructurada (Fourcade 2021). Además, de forma general se recomienda preparar el modelo de forma escalable, empezando con las partes más críticas y añadiendo complejidad de forma progresiva.

Respecto la representatividad de los datos, es común que estos no sean totalmente representativos de la realidad, sino que estén sesgados por múltiples ejes. Por ejemplo, la huella colonialista sigue presente en la actualidad, y es reconocible en los patrones de especies invasoras (Lenzner et al. 2022), impactando en la cantidad de estudios y datos ecológicos disponibles y, por tanto, en la representatividad de áreas con menos privilegios y realidades minoritarias (Trisos et al. 2021). Recomendamos incluir análisis de representatividad para datos sensibles (Clemmensen y Kjærsgaard 2022) que delimitaran la posibilidad de generalización.

La interpretación del modelo es requisito indispensable en proyectos con IA. Recomendamos contrastar las predicciones obtenidas con un modelo nulo o previo y la revisión biológica de los resultados. Por ejemplo, el uso SDM para la modelización de la presencia de especies de cuevas sin tener en cuenta la disponibilidad de hábitat nos retornará predicciones especialmente disparatadas (Mammola y Leroy 2018). Durante la evaluación del modelo deberemos incluir diferentes métricas en función del tipo de tarea realizada e informar no solo de la precisión con los datos de prueba sino también en los datos de entrenamiento (Rainio et al. 2024).

La exposición de la herramienta de IA utilizada debe hacerse de forma correcta, completa y clara, idealmente siguiendo los principios FAIR, revisando políticas de privacidad y reconociendo el crédito de los datos usados si no son de propia colección. Por ejemplo, es importante detallar la responsabilidad del error de los modelos, por ejemplo, de manejo automatizado (Dara et al. 2022) y evaluar si nuestros datos incluyen datos sensibles como imágenes de personas no informadas, por lo que su publicación requerirá el uso de protocolos de encriptación (Jia et al. 2023).

Conclusiones y visión de futuro

La inteligencia artificial ha revolucionado el estudio de especies invasoras, integrando innovación tecnológica con prácticas ecológicas. Nuestra revisión sistemática muestra que la mayoría de los estudios enfocados en IA y especies invasoras han priorizado tareas de detección, particularmente en plantas. Esto se ha facilitado por la creciente disponibilidad de datos abiertos, incluyendo imágenes satelitales, registros de redes sociales y datos de drones, que permiten extender las dimensiones temporales y espaciales de los proyectos. Desde la implementación de herramientas de detección temprana hasta el uso de robots autónomos para el control de especies, la IA ha reducido significativamente los costos y promete mejorar la eficiencia de los esfuerzos de erradicación.

La disponibilidad y calidad de los datos son factores clave que condicionan el éxito de los proyectos de IA en invasiones biológicas. Las herramientas de aprendizaje profundo, como las CNN, destacan en su capacidad para manejar datos visuales complejos, mientras que los modelos de ensamblaje han mejorado la robustez de las predicciones al combinar múltiples algoritmos. Sin embargo, persisten desafíos relacionados con la representatividad de los datos, los sesgos inherentes y la opacidad de algunos algoritmos. Es crucial priorizar el análisis crítico de los datos utilizados y fomentar el acceso a bases de datos diversas y completas.

Las perspectivas futuras en el uso de la IA para especies invasoras incluyen el desarrollo de modelos más integrados y adaptativos. La combinación de enfoques mecanicistas y de aprendizaje profundo utilizando aprendizaje por transferencia puede mejorar nuestra comprensión de los procesos ecológicos subyacentes en base a conjuntos de datos más limitados y permitir predicciones más precisas. Además, la democratización de las herramientas de IA mediante plataformas accesibles y aplicaciones específicas fomentará la colaboración interdisciplinaria y la integración de múltiples fuentes de datos. Es esencial promover buenas prácticas, incluyendo la adherencia a principios FAIR, evaluación de sesgos, la transparencia en los métodos y la evaluación crítica de las herramientas utilizadas.

Contribución de los autores

EF: Conceptualización, curación de datos, análisis formal, investigación, metodología, redacción – borrador original. RS-G: Supervisión, Redacción – revisión y edición.

Disponibilidad de datos

La lista de artículos producto de la revisión sistemática y el código para generar las figuras se encuentra disponible públicamente en el GitHub de los autores: https://github.com/erolafr/AIForInvasionBiology_Ecosistemas/, así como material complementario y traducciones al inglés.

Financiación, permisos requeridos, potenciales conflictos de interés y agradecimientos

Los autores/as declaran no tener ningún conflicto de intereses.

E.F. agradece la financiación por parte de UKRI Marie Skłodowska-Curie Actions Fellowship (EP/Y02873/1) bajo la supervisión de R.S.G. R.S.G. agradece la financiación de NERC Pushing the Frontiers grant (NE/X013766/1). No hay conflictos de interés.

Referencias

- Agathokleous, E., Saitanis, C. J., Fang, C., Yu, Z. 2023. Use of ChatGPT: What does it mean for biology and environmental science? *Science of the Total Environment* 888: 164154. <https://doi.org/10.1016/j.scitotenv.2023.164154>
- Adepoju, K., Adelabu, S. Mokubung, C. 2020. Mapping *Seriphium plumosum* encroachment and investigating its drivers using Sentinel-2 and environmental data. *Environmental Monitoring and Assessment* 192: 328. <https://doi.org/10.1007/s10661-020-08253-x>
- Anandhavalli, M., Ghose, MK., Gauthaman, K. 2010. Association rule mining in genomics. *International Journal of Computer Theory and Engineering* 2(2): 269-273. <https://doi.org/10.7763/IJCTE.2010.V2.151>
- Araújo, M.B., Anderson, R.P., Barbosa, A.M., Beale, C.M., Dormann, C.F., Early, R., Garcia, R.A., et al. 2019. Standards for distribution models in biodiversity assessments. *Science Advances* 5: eaat4858. <https://doi.org/10.1126/sciadv.aat4858>
- Aussem, A., Hill, D. 1999. Wedding connectionist and algorithmic modelling: applications to ecological systems. *Ecological Modelling* 120(2-3): 225-236. [https://doi.org/10.1016/S0304-3800\(99\)00104-0](https://doi.org/10.1016/S0304-3800(99)00104-0)
- Bacher, S., Ryan-Colton, E., Coiro, M., Cassey, P., Galil, B.S., Nuñez, M.A., Ansong, M., et al. 2025. Global Impacts Dataset of Invasive Alien Species (GIDIAS). *Scientific Data* 12, 832. <https://doi.org/10.1038/s41597-025-05184-5>
- Bao, G., Weng, B., Xv, H. 2024. Application of deep neural network identification models based on garden environment perception in plant protection. *Crop Protection* 184: 106833. <https://doi.org/10.1016/j.cropro.2024.106833>
- Barbosa, F.G., Schneck, F., Melo, A.S. 2012. Use of ecological niche models to predict the distribution of invasive species: a scientometric analysis. *Brazilian Journal of Biology* 72(4): 821-829. <https://doi.org/10.1590/S1519-69842012000500007>
- Bednarsek, N., Beck, M.W., Pelletier, G., Applebaum, S.L., Feely, R.A., Butler, R., Byrne, M., et al. 2022. Natural analogues in pH variability and predictability across the coastal pacific estuaries: extrapolation of the increased oyster dissolution under increased pH amplitude and low predictability related to ocean acidification. *Environmental Science and Technology* 56(12): 9015-9028. <https://doi.org/10.1021/acs.est.2c00010>
- Bae, M.-J., Kim, E.-J., Park, Y.-S. 2021. Comparison of invasive apple snail (*Pomacea canaliculata*) behaviors in different water temperature gradients. *Water* 13(9): 1149. <https://doi.org/10.3390/w13091149>
- Ben-Hur, A., Ong, C.S., Sonnenburg, S., Schölkopf, B., Rätsch, G. 2008. Support vector machines and kernels for computational biology. *PLoS Computational Biology* 4: e1000173. <https://doi.org/10.1371/journal.pcbi.1000173>
- Benzer, S., Benzer, R. 2020. Growth and length-weight relationships of *Pseudorasbora parva* (Temminck & Schlegel, 1846) in Hirfanli Dam Lake: Comparison with traditional and artificial neural networks approaches. *Iranian Journal of Fisheries Sciences* 19(3): 1098-1110.
- Biswas, S.S. 2023. Potential use of chatGPT in global warming. *Annals of Biomedical Engineering* 51: 1126-1127. <https://doi.org/10.1007/s10439-023-03171-8>
- Blonder, B.W., Lim, M.H., Godoy, O. 2024. Predicting and prioritising community assembly: learning outcomes via experiments. *Ecology Letters* 27(10): e14535. <https://doi.org/10.1111/ele.14535>
- Bolaños, F., Salatino, A., Osborne, F., Motta, E. 2024. Artificial intelligence for literature reviews: opportunities and challenges. *Artificial Intelligence Review* 57: 259. <https://doi.org/10.1007/s10462-024-10902-3>
- Borowiec, M.L., Dikow, R.B., Frandsen, P.B., McKeeken, A., Valentini, G., White, A.E. 2022. Deep learning as a tool for ecology and evolution. *Methods in Ecology and Evolution* 13: 1640-1660. <https://doi.org/10.1111/2041-210X.13901>
- Bravo-Díaz, A., Moreno, S., Lopatin, J. 2024. Evaluating the ability of convolutional neural networks for transfer learning in *Pinus radiata* cover predictions. *Ecological Informatics* 82: 102684. <https://doi.org/10.1016/j.ecoinf.2024.102684>
- Briscoe, N.J., Elith, J., Salguero-Gómez, R., Lahoz-Monfort, J.J., Camac, J.S., Giljohann, K.M., Holden, M.H., et al. 2019. Forecasting species range dynamics with process-explicit models: matching methods to applications. *Ecology Letters* 22: 1940-1956. <https://doi.org/10.1111/ele.13348>
- Buchelt, A., Adrowitzer, A., Kieseberg, P., Gollob, C., Nothdurft, A., Eresheim, S., Tschatschek, S., et al. 2024. Exploring artificial intelligence for applications of drones in forest ecology and management. *Forest Ecology and Management* 551: 121530. <https://doi.org/10.1016/j.foreco.2023.121530>
- Bzdok, D., Krzywinski, M., Altman, N. 2018. Machine learning: supervised methods. *Nature Methods* 15: 5-6. <https://doi.org/10.1038/nmeth.4551>
- Camacho, C.A., Sullivan, C.J., Weber, M.J., Pierce, C.L. 2019. Morphological identification of bighead carp, silver carp, and grass carp eggs using random forests machine learning classification. *North American Journal of Fisheries Management* 39: 1373-1384. <https://doi.org/10.1002/nafm.10380>
- Cao, Y., Geddes, T.A., Yang, J.Y.H., Yang P. 2020. Ensemble deep learning in bioinformatics. *Nature Machine Intelligence* 2: 500-508. <https://doi.org/10.1038/s42256-020-0217-y>
- Cardoso, A.S., Malta-Pinto, E., Tabik, S. 2024. Can citizen science and social media images support biodiversity monitoring? *Ecological Informatics* 81: 102602. <https://doi.org/10.1016/j.ecoinf.2024.102602>
- Castillo, C., Chollett, I., Klein, E. 2008. Enhanced duckweed detection using bootstrapped SVM classification on medium resolution RGB MODIS imagery. *International Journal of Remote Sensing* 29(19): 5595-5604. <https://doi.org/10.1080/01431160801961375>

- Cavender-Bares, J., Schneider, F.D., Santos, M.J., Armstrong, A., Carnaval, A., Dahlin, K.M., Fatoyinbo, L., et al. 2022. Integrating remote sensing with ecology and evolution to advance biodiversity conservation. *Nature Ecology and Evolution* 6, 506–519. <https://doi.org/10.1038/s41559-022-01702-5>
- Chaity, M.D., van Aardt, J. 2024. Exploring the limits of species identification via a convolutional neural network in a complex forest scene through simulated imaging spectroscopy. *Remote Sensing* 16(3): 498. <https://doi.org/10.3390/rs16030498>
- Charlton, G., Falzon, G., Shepley, A., Fleming, P.J.S., Ballard, G., Meek, P.D. 2024. The Sentinel Bait Station: an automated, intelligent design pest animal baiting system. *Wildlife Research* 51(1). <https://doi.org/10.1071/WR22183>
- Chen, G., Kéry, M., Plattner, M., Ma, K., Gardner, B. 2013. Imperfect detection is the rule rather than the exception in plant distribution studies. *Journal of Ecology* 101: 183–191. <https://doi.org/10.1111/1365-2745.12021>
- Chen, Q., Xie, J., Yu, Q., Liu, C., Ding, W., Li, X., Zhou, H. 2024. An experimental study of acoustic bird repellents for reducing bird encroachment in pear orchards. *Frontiers in Plant Science* 15: 1365275. <https://doi.org/10.3389/fpls.2024.1365275>
- Christin, S., Hervet, É., Lecomte, N. 2019. Applications for deep learning in ecology. *Methods in Ecology and Evolution* 10: 1632–1644. <https://doi.org/10.1111/2041-210X.13256>
- Clemmensen, L., Kjærsgaard, R. 2022. Data representativity for machine learning and AI systems. *arXiv*: 2203.04706v1.
- Coughlan, N.E., Lyne, L., Cuthbert, R.N., Cunningham, E.M., Lucy, F., Davis, E., Caffrey, J.M., Dick, J.T. 2020. In the black: Information harmonisation and educational potential amongst international databases for invasive alien species designated as of Union Concern. *Global Ecology and Conservation* 241. e01332. <https://doi.org/10.1016/j.gecco.2020.e01332>
- Dar, S.A., Sharief, A., Kumar, V., Singh, H., Joshi, B.D., Bhattacharjee, S., Dutta, R., et al. 2023. Free-ranging dogs are seriously threatening Himalayan environment: delineating the high-risk areas for curbing free-ranging dog infestation in the Trans-Himalayan region. *Environmental Monitoring and Assessment* 195: 1386. <https://doi.org/10.1007/s10661-023-11972-6>
- Dara, R., Hazrati Fard, S.M., Kaur, J. 2022. Recommendations for ethical and responsible use of artificial intelligence in digital agriculture. *Frontiers in Artificial Intelligence* 5: 884192. <https://doi.org/10.3389/frai.2022.884192>
- Dash, J.P., Watt, M.S., Paul, T.S.H., Morgenroth, J., Hartley, R. 2019. Taking a closer look at invasive alien plant research: A review of the current state, opportunities, and future directions for UAVs. *Methods in Ecology and Evolution* 10: 2020–2033. <https://doi.org/10.1111/2041-210X.13296>
- Davis, A.J.S., Groom, Q., Adriaens, T., Vanderhoeven, S., De Troch, R., Oldoni, D., Desmet, P., et al. 2024. Reproducible WiSDM: a workflow for reproducible invasive alien species risk maps under climate change scenarios using standardized open data. *Frontiers in Ecology and Evolution* 12: 1148895. <https://doi.org/10.3389/fevo.2024.1148895>
- Deng, J., Dong, W., Socher, R., Li, L. -J., Li, K., Fei-Fei, L. 2009. *ImageNet: A large-scale hierarchical image database*. IEEE Conference on Computer Vision and Pattern Recognition, Miami, FL, USA, 248–255. <https://doi.org/10.1109/CVPR.2009.5206848>
- Depauw, L., Blondeel, H., De Lombaerde, E., De Pauw, K., Landuyt, D., Lorer, E., Vangansbeke, P., et al. 2022. The use of photos to investigate ecological change. *Journal of Ecology* 110: 1220–1236. <https://doi.org/10.1111/1365-2745.13876>
- Devi, N., Sarma, K.K., Laskar, S. 2023. Design of an intelligent bean cultivation approach using computer vision, IoT and spatio-temporal deep learning structures. *Ecological Informatics* 75: 102044. <https://doi.org/10.1016/j.ecoinf.2023.102044>
- Diagne, C., Leroy, B., Gozlan Vaissière, A.-C., Assailly, C., Nuninger, L., Roiz, D., et al. 2020. InvaCost, a public database of the economic costs of biological invasions worldwide. *Scientific data* 7: 277. <https://doi.org/10.1038/s41597-020-00586-z>
- Dietterich, T.G. 2000. Ensemble methods in machine learning. In: *Multiple classifier systems. MCS 2000*. Lecture notes in computer science, vol 1857. Springer, Berlin, Heidelberg. https://doi.org/10.1007/3-540-45014-9_1
- Dyrmann, M., Skovsen, S.K., Christiansen, P.H., Kragh, M.F., Mortensen, A.K. 2024. High-speed camera system for efficient monitoring of invasive plant species along roadways. *F1000Research* 13: 360. <https://doi.org/10.12688/f1000research.141992.2>
- Elith, J., Graham, C., NCEAS species distribution modeling group. 2006. Novel methods improve prediction of species' distributions from occurrence data. *Ecography* 29: 129–151. <https://doi.org/10.1111/j.2006.0906-7590.04596.x>
- Elith, J., Kearney, M., Phillips, S. 2011. The art of modelling range-shifting species. *Methods in Ecology and Evolution* 1(4), 330–342. <https://doi.org/10.1111/j.2041-210X.2010.00036.x>
- Epstein, J.M., Pine, W.E. III., Romagosa, C.M., Scott, M.C., Phillips, C.T., Marion, C.A. Baiser, B. 2018. State- and regional-scale patterns and drivers of freshwater fish functional diversity in the southeastern USA. *Transactions of the American Fisheries Society* 147(6): 1179–1198. <https://doi.org/10.1002/tafs.10110>
- Fenner, M. 1998. The phenology of growth and reproduction in plants. *Perspectives in Plant Ecology, Evolution and Systematics* 1(1): 78–91. <https://doi.org/10.1078/1433-8319-00053>
- Fenollosa, E., Pang, S., Briscoe, N., Guisan, A., Salguero-Gómez, R. 2025. Powerful yet challenging: Mechanistic Niche Models for predicting invasive species potential distribution under climate change. *Ecography*. <https://doi.org/10.1002/ecog.07775>
- Fleure, V., Magneville, C., Mouillot, D., Villegier, S. 2024. Automated identification of invasive rabbitfishes in underwater images from the Mediterranean Sea. *Aquatic Conservation: Marine and Freshwater Ecosystems* 34(1). <https://doi.org/10.1002/aqc.4073>
- Fonnesbeck, C.J. 2008. Solving dynamic wildlife resource optimization problems using reinforcement learning. *Natural Resource Modeling* 18(1): 1–40. <https://doi.org/10.1111/j.1939-7445.2005.tb00147.x>
- Fourcade, Y. 2021. Fine-tuning niche models matters in invasion ecology: A lesson from the land planarian *Obama nungara*. *Ecological Modelling* 457: 109686. <https://doi.org/10.1016/j.ecolmodel.2021.109686>
- Galaz García, C., Bagstad, K.J., Brun, J., Chaplin-Kramer, R., Dhu, T., Murray, N.J., Nolan, C.J., et al. 2023. The future of ecosystem assessments is automation, collaboration, and artificial intelligence. *Environmental Research Letters* 18(1): 011003. <https://doi.org/10.1088/1748-9326/acab19>
- García-Navarrete, O.L., Correa-Guimaraes, A., Navas-Gracia, L.M. 2024. Application of convolutional neural networks in weed detection and identification: A systematic review. *Agriculture* 14: 568. <https://doi.org/10.3390/agriculture14040568>
- Gil-Tapetado, D., Koken, M., De Cock, R., Gomez, J.F., Cabrero-Sanudo, F.J., Polidori, C. 2024. Across the firefly-verse: comparison of niche suitability of an exotic firefly in its native and colonized range. *Journal of Insect Conservation* 28(1): 43–56. <https://doi.org/10.1007/s10841-023-00522-7>
- Gonzalez, L.F., Montes, G.A., Puig, E., Johnson, S., Mengersen, K., Gaston, K.J. 2016. Unmanned aerial vehicles (UAVs) and artificial intelligence revolutionizing wildlife monitoring and conservation. *Sensors* 16(1): 97. <https://doi.org/10.3390/s16010097>
- Goode, K., Weber, M.J., Dixon, P.M. 2023. WhoseEgg: classification software for invasive carp eggs. *PeerJ* 11: e14787. <https://doi.org/10.7717/peerj.14787>

- Greener, J.G., Kandathil, S.M., Moffat, L., Jonas, D.T. 2022. A guide to machine learning for biologists. *Nature Reviews Molecular Cell Biology* 23: 40-55. <https://doi.org/10.1038/s41580-021-00407-0>
- Gugele, S.M., Widmer, M., Baer, J., DeWeber, J.T., Balk, H., Brinker, A. 2021. Differentiation of two swim bladdered fish species using next generation wideband hydroacoustics. *Scientific Reports* 11(1): 10520. <https://doi.org/10.1038/s41598-021-89941-7>
- Guisan, A., Petitpierre, B., Broennimann, O., Daehler, C., Kueffer, C. 2014. Unifying niche shift studies: insights from biological invasions. *Trends in Ecology and Evolution* 29: 260-269. <https://doi.org/10.1016/j.tree.2014.02.009>
- Guisan, A., Thuiller, W., Zimmermann, N.E. 2017. *Habitat suitability and distribution models: with applications in R*. Cambridge University Press. <https://doi.org/10.1017/9781139028271>
- Gupta, K., Rani, R., Bahia, N. 2020. Plant-seedling classification using transfer learning. *International Journal of Agricultural and Environmental Information Systems* 11(4): 25-40. <https://doi.org/10.4018/IJAEIS.2020100102>
- Haase, C.G., Yang, A., McNyset, K.M., Blackburn, J.K. 2021. GARPTools: R software for data preparation and model evaluation of GARP models. *Ecography* 44: 1790-1796. <https://doi.org/10.1111/ecog.05642>
- Hamilton, S.A., Murphy, D.D. 2020. Use of affinity analysis to guide habitat restoration and enhancement for the imperiled delta smelt. *Endangered Species Research* 43:103-120. <https://doi.org/10.3354/esr01057>
- Han, B.A., Varshney, K. R., LaDeau, S., Subramaniam, A., Weathers, K.C., Zwart, J. 2023. A synergistic future for AI and ecology. *Proceedings of the National Academy of Sciences of the United States of America* 120(38): e2220283120. <https://doi.org/10.1073/pnas.2220283120>
- Hastie, T., Tibshirani, R., Friedman, J. 2009. *The elements of statistical learning: data mining, inference, and prediction*. 2^a ed. Springer Science and Business Media.
- Heger, T., Jeschke, J.M. Kollmann, J. 2021. Some reflections on current invasion science and perspectives for an exciting future. *NeoBiota* 68: 79-100. <https://doi.org/10.3897/neobiota.68.68997>
- Heil, B.J., Hoffman, M.M., Markowitz, F., Lee, S.-I., Greene, C.S., Hicks, S.C. 2021. Reproducibility standards for machine learning in the life sciences. *Nature Methods* 18: 1132-1135. <https://doi.org/10.1038/s41592-021-01256-7>
- Hodgson, J.C., Mott, R., Baylis, S.M., Pham, T.T., Wotherspoon, S., Kilpatrick, A.D., Segaran, R.R., et al. 2018. Drones count wildlife more accurately and precisely than humans. *Methods in Ecology and Evolution* 9: 1160-1167. <https://doi.org/10.1111/2041-210X.12974>
- Hollings, T., Burgman, M., van Andel, M., Gilbert, M., Robinson, T., Robinson, A. 2018. How do you find the green sheep? A critical review of the use of remotely sensed imagery to detect and count animals. *Methods in Ecology and Evolution* 9: 881-892. <https://doi.org/10.1111/2041-210X.12973>
- Hui, C. 2023. The dos and don'ts for predicting invasion dynamics with species distribution models. *Biological Invasions* 25: 947-953. <https://doi.org/10.1007/s10530-022-02976-3>
- Iguchi, K., Matsura, K., McNyset, K.M., Peterson, A.T., Scachetti-Pereira, R., Powers, K.A., Vieglais, D.A., et al. 2004. Predicting invasions of North American basses in Japan using native range data and a genetic algorithm. *Transactions of the American Fisheries Society* 133(4): 845-854. <https://doi.org/10.1577/T03-172.1>
- Jain, A.K. 2010. Data clustering: 50 years beyond K-means. *Pattern Recognition Letters* 31: 651-666. <https://doi.org/10.1016/j.patrec.2009.09.011>
- James, K., Bradshaw, K. 2020. Detecting plant species in the field with deep learning and drone technology. *Methods in Ecology and Evolution* 11(11): 1509-1519. <https://doi.org/10.1111/2041-210X.13473>
- Javed, Q., Azeem, A., Sun, J., Ullah, I., Du, D., Imran, M.A., Nawaz, M.I., Chattha, H.T. 2022. Growth prediction of *Alternanthera philoxeroides* under salt stress by application of artificial neural networking. *Plant Biosystems* 156(1): 61-67. <https://doi.org/10.1080/11263504.2020.1832603>
- Jeschke, J.M., Strayer, D.L. 2008. Usefulness of bioclimatic models for studying climate change and invasive species. En: Ostfeld, R.S., Schlesinger, W.H. (eds.). Year in Ecology and Conservation Biology 2008. *Annals of the New York Academy of Sciences* 1134: 1-24. <https://doi.org/10.1196/annals.1439.002>
- Jia, H., Cai, D., Yang, J., Qian, W., Wang, C. 2023. Efficient and privacy-preserving image classification using homomorphic encryption and chunk-based convolutional neural network. *Journal of Cloud Computing* 12: 175. <https://doi.org/10.1186/s13677-023-00537-0>
- Jiang, D., Chen, S., Hao, M., Fu, J., Ding, F. 2018. Mapping the potential global codling moth (*Cydia pomonella* L.) distribution based on a machine learning method. *Scientific Reports* 8: 13093. <https://doi.org/10.1038/s41598-018-31478-3>
- Katal, N., Rzanny, M., Mäder, P., Wäldchen, J. 2022. Deep learning in plant phenological research: A systematic literature review. *Frontiers in Plant Science* 13: 805738. <https://doi.org/10.3389/fpls.2022.805738>
- Kattenborn, T., Eichel, J., Wiser, S., Burrows, L., Fassnacht, F.E., Schmidlein, S. 2020. Convolutional neural networks accurately predict cover fractions of plant species and communities in unmanned aerial vehicle imagery. *Remote Sensing in Ecology and Conservation* 6(4): 472-486. <https://doi.org/10.1002/rse2.146>
- Kattge, J., Bönisch, G., Díaz, S., Lavorel, S., Colin Prentice, I., Leadley, P., Tautenhahn, S., et al. 2020. TRY plant trait database – enhanced coverage and open access. *Global Change Biology* 26: 119-188. <https://doi.org/10.5194/egusphere-egu2020-20191>
- Keerthinathan, P., Amarasingam, N., Desilva, A. 2024. African lovegrass segmentation with artificial intelligence. *Remote Sensing* 16(13): 2363. <https://doi.org/10.3390/rs16132363>
- Keller, R.P., Kocev, D., Dzeroski, S. 2011. Trait-based risk assessment for invasive species: high performance across diverse taxonomic groups, geographic ranges and machine learning/statistical tools. *Diversity and Distributions* 17(3): 451-461. <https://doi.org/10.1111/j.1472-4642.2011.00748.x>
- Knight, E., Hannah, K., Foley, G., Scott, C., Brigham, R., Bayne, E. 2017. Recommendations for acoustic recognizer performance assessment with application to five common automated signal recognition programs. *Avian Conservation and Ecology* 12(2). <https://doi.org/10.5751/ACE-01114-120214>
- Kolar, C. 2004. Risk assessment and screening for potentially invasive fishes. *New Zealand Journal of Marine and Freshwater Research* 38(3): 391-397. <https://doi.org/10.1080/00288330.2004.9517247>
- Kotowska, D., Pärt, T., Żmihorski, M. 2021. Evaluating Google Street View for tracking invasive alien plants along roads. *Ecological Indicators* 121: 107020. <https://doi.org/10.1016/j.ecolind.2020.107020>
- Krizhevsky, A., Sutskever, I., Hinton, G. 2017. ImageNet classification with deep convolutional neural networks. *Communications of the ACM* 60(6): 84-90. <https://doi.org/10.1145/3065386>
- Kulkarni, R., Di Minin, E. 2023. Towards automatic detection of wildlife trade using machine vision models. *Biological Conservation* 279: 109924. <https://doi.org/10.1016/j.biocon.2023.109924>

- Lapeyrolerie, M., Chapman, M.S., Norman, K.E.A., Boettiger, C. 2022. Deep reinforcement learning for conservation decisions. *Methods in Ecology and Evolution* 13: 2649–2662. <https://doi.org/10.1111/2041-210X.13954>
- Latombe, G., Pyšek, P., Jeschke, J.M., Blackburn, T.M., Bacher, S., Capinha, C., Costello, M.J., et al. 2017. A vision for global monitoring of biological invasions. *Biological Conservation* 213(B): 295–308. <https://doi.org/10.1016/j.biocon.2016.06.013>
- Leathwick, J.R., Elith, J., Hastie, T. 2006. Comparative performance of generalized additive models and multivariate adaptive regression splines for statistical modelling of species distributions. *Ecological Modelling* 199: 188–196. <https://doi.org/10.1016/j.ecolmodel.2006.05.022>
- Lehman, A., Overton, J.M., Leathwick, J.R. 2002. GRASP: generalized regression analysis and spatial prediction. *Ecological Modelling* 157: 189–207. [https://doi.org/10.1016/S0304-3800\(02\)00195-3](https://doi.org/10.1016/S0304-3800(02)00195-3)
- Lenzner, B., Latombe, G., Schertler, A., Seebens, H., Yang, Q., Winter, M., Weigelt, P., et al. 2022. Naturalized alien floras still carry the legacy of European colonialism. *Nature Ecology and Evolution* 6(11), 1723–1732. <https://doi.org/10.1038/s41559-022-01865-1>
- Levin, S.C., Evers, S., Potter, T., Guerrero, M. P., Childs, D.Z., Compagnoni, A., Knight, T.M., Salguero-Gómez, R. 2022. Rpadrino: An R package to access and use PADRINO, an open access database of Integral Projection Models. *Methods in Ecology and Evolution* 13: 1923–1929. <https://doi.org/10.1111/2041-210X.13910>
- Ley, C., Martin, R.K., Pareek, A., et al. 2022. Machine learning and conventional statistics: making sense of the differences. *Knee Surgery, Sports Traumatology, Arthroscopy* 30: 753–757. <https://doi.org/10.1007/s00167-022-06896-6>
- Li, C., Bo, H., Song, B., Chen, X., Cao, Q., Yang, R., Ji, S., et al. 2022. Reshaping of the soil microbiome by the expansion of invasive plants: shifts in structure, diversity, co-occurrence, niche breadth, and assembly processes. *Plant and Soil* 477: 629–646. <https://doi.org/10.1007/s11104-022-05445-x>
- Los, S., Múcher, C.A., Kramer, H., Franke, G.J., Kamphuis, C. 2023. Estimating body dimensions and weight of cattle on pasture with 3D models from UAV imagery. *Smart Agricultural Technology* 4: 100167. <https://doi.org/10.1016/j.atech.2022.100167>
- Loyani, L. 2024. Segmentation-based quantification of *Tuta absoluta*'s damage on tomato plants. *Smart Agricultural Technology* 7: 100415. <https://doi.org/10.1016/j.atech.2024.100415>
- Ma, D., Wei, J., Zhu, L., Zhao, F., Wu, H., Chen, X., Li, Y., et al. 2024. Semi-supervised learning advances species recognition for aquatic biodiversity monitoring. *Frontiers in Marine Science* 11: 1373755. <https://doi.org/10.3389/fmars.2024.1373755>
- Maher, J., Stringham, O.C., Moncayo, S., Wood, L., Lassaline, C.R., Virtue, J., Cassey, P. 2023. Weed wide web: characterising illegal online trade of invasive plants in Australia. *NeoBiota* 87: 45–72. <https://doi.org/10.3897/neobiota.87.104472>
- Maitner, B.S., Boyle, B., Casler, N., Condit, R., Donoghue II, J., Durán, S.M., Guaderrama, D., et al. 2018. The *bien* r package: A tool to access the Botanical Information and Ecology Network (BIEN) Database. *Methods in Ecology and Evolution* 9: 373–379. <https://doi.org/10.1111/2041-210X.12861>
- Mammola, S., Leroy, B. 2018. Applying species distribution models to caves and other subterranean habitats. *Ecography* 41: 1194–1208. <https://doi.org/10.1111/ecog.03464>
- Marshall, D.J. 2024. Principles of experimental design for ecology and evolution. *Ecology Letters* 27: e14400. <https://doi.org/10.1111/ele.14400>
- Martinez, B., Reaser, J.K., Dehgan, A., Zamft, B., Baisch, D., McCormick, C., Giordano, A.J., et al. 2020. Technology innovation: advancing capacities for the early detection of and rapid response to invasive species. *Biological Invasions* 22: 75–100. <https://doi.org/10.1007/s10530-019-02146-y>
- Martínez-Vega, J., Díaz, A., Miguel Nava, J., Gallardo, M., Echavarría, P. 2017. Assessing land use-cover changes and modelling change scenarios in two mountain Spanish national parks. *Environments* 4(4): 79. <https://doi.org/10.3390/environments4040079>
- Marzialelli, F., Frate, L., De Simone, W., Frattaroli, A.R., Acosta, A.T.R., Carranza, M.L. 2021. Unmanned aerial vehicle (UAV)-based mapping of *Acacia saligna* invasion in the mediterranean coast. *Remote Sensing* 13(17): 3361. <https://doi.org/10.3390/rs13173361>
- Mathur, M., Mathur, P. 2024. Habitat suitability of *Opuntia ficus-indica* (L.) Mill. (Cactaceae): a comparative temporal evaluation using diverse bioclimatic earth system models and ensemble machine learning approach. *Environmental Monitoring and Assessment* 196(3): 232. <https://doi.org/10.1007/s10661-024-12406-7>
- Matsushashi, S., Oishi, Y., Koarai, A., Sugiura, R. 2024. Enhancing image recognition robustness in early weed detection through optimal training data curation. *Weed Science* 72(5):546–552. <https://doi.org/10.1017/wsc.2024.63>
- Meerdink, S., Hiatt, D., Flory, S.L., Zare, A. 2024. Dealing with imperfect data for invasive species detection using multispectral imagery. *Ecological Informatics* 79: 102432. <https://doi.org/10.1016/j.ecoinf.2023.102432>
- Morey, A.C., Venette, R.C. 2020. Minimizing risk and maximizing spatial transferability: challenges in constructing a useful model of potential suitability for an invasive insect. *Annals of the Entomological Society of America* 113(2): 100–113. <https://doi.org/10.1093/aesa/saz049>
- Mqingwana, P., Shoko, C., Gxokwe, S., Dube, T. 2024. Monitoring and assessing the effectiveness of the biological control implemented to address the invasion of water hyacinth (*Eichhornia crassipes*) in Hartbeespoort Dam, South Africa. *Remote Sensing Applications: Society and Environment* 36: 101295. <https://doi.org/10.1016/j.rsase.2024.101295>
- Nazir, S., Kaleem, M. 2021. Advances in image acquisition and processing technologies transforming animal ecological studies. *Ecological Informatics* 61, 101212. <https://doi.org/10.1016/j.ecoinf.2021.101212>
- Nisin, M.K.M.N., Ramanathan, S.K.K., Sreeram, M.P., Sudheesan, D. 2023. Ensemble modelling of Pirarucu (*Arapaima gigas*) distribution in biodiversity hotspot to understand its invasion risk. *Ecology of Freshwater Fish* 32(3): 528–537. <https://doi.org/10.1111/eff.12704>
- Novoa, A., Jarić, I., Pipek, P., Pyšek, P. 2025. Culturomics and iEcology provide novel opportunities to study human and social dimensions of alien species introductions. *Trends in Ecology and Evolution* 40 (1), 18–26. <https://doi.org/10.1016/j.tree.2024.08.012>
- Nunez-Mir, G.C., Iannone, B.V. III., Curtis, K., Fei, S. 2015. Evaluating the evolution of forest restoration research in a changing world: a big literature review. *New Forests* 46(5–6): 669–682. <https://doi.org/10.1007/s11056-015-9503-7>
- Olden, J.D., Lawler, J.J., Poff, N.L. 2008. Machine learning methods without tears: A primer for ecologists. *The Quarterly Review of Biology* 83(2): 171–193. <https://doi.org/10.1086/587826>
- Olivoto, T. 2022. Lights, camera, pliman! An R package for plant image analysis. *Methods in Ecology and Evolution* 13: 789–798. <https://doi.org/10.1111/2041-210X.13803>
- Orenstein, E.C., Ayata, S.-D., Maps, F., Becker, É.C., Benedetti, F., Biard, T., de Garidel-Thoron, T., et al. 2022. Machine learning techniques to characterize functional traits of plankton from image data. *Limnology and Oceanography* 67: 1647–1669. <https://doi.org/10.1002/lno.12101>
- Orouji, S., Liu, M.C., Korem, T., Peters, M.A.K. 2024. Domain adaptation in small-scale and heterogeneous biological datasets. *Science Advances* 10(51). <https://doi.org/10.1126/sciadv.adp6040>
- O'Shea-Wheller, T.A., Corbett, A., Osborne, J.L., Recker, M., Kennedy, P.J. 2024. VespAI: a deep learning-based system for the detection of invasive hornets. *Communications Biology* 7(1). <https://doi.org/10.1038/s42003-024-05979-z>

- Pagad, S., Genovesi, P., Carnevali, L., Schigel, D., McGeoch, M.A. 2018. Introducing the Global Register of Introduced and Invasive Species. *Scientific data* 5: 170202. <https://doi.org/10.1038/sdata.2017.202>
- Palazzetti, L., Rangarajan, A.K., Dinca, A., Boom, B., Popescu, D., Offermans, P., Pinotti, C.M. 2024. The hawk eye scan: *Halyomorpha halys* detection relying on aerial tele photos and neural networks. *Computers and Electronics in Agriculture* 226: 109365. <https://doi.org/10.1016/j.compag.2024.109365>
- Pan, S.J., Yang, Q. 2010. A survey on transfer learning. *IEEE Transactions on Knowledge and Data Engineering* 22: 1345-1359. <https://doi.org/10.1109/TKDE.2009.191>
- Pasha, S.V., Reddy, C.S. 2024. Global spatial distribution of *Prosopis juliflora* - one of the world's worst 100 invasive alien species under changing climate using multiple machine learning models. *Environmental Monitoring and Assessment* 196(2): 196. <https://doi.org/10.1007/s10661-024-12347-1>
- Patel, M., Jernigan, S., Richardson, R., Ferguson, S., Buckner, G. 2019. Autonomous robotics for identification and management of invasive aquatic plant species. *Applied Sciences* 9(12):2410. <https://doi.org/10.3390/app9122410>
- Pearson, R.G. 2003. *Species' distribution modeling for conservation educators and practitioners*. Lessons in conservation 3., 54-89: Network of conservation educators and practitioners, Center for Biodiversity and Conservation, American Museum of Natural History. <https://doi.org/10.5531/cbc.linc.3.1.3>
- Pearson, R.G., Dawson, T.P., Berry, P.M., Harrison, P.A. 2002. Species: A spatial evaluation of climate impact on the envelope of species. *Ecological Modelling* 154: 289-300. [https://doi.org/10.1016/S0304-3800\(02\)00056-X](https://doi.org/10.1016/S0304-3800(02)00056-X)
- Philibert, A., Desprez-Loustau, M.L., Fabre, B., Frey, P., Halkett, F., Husson, C., Lung-Escarmant, B., et al. 2011. Predicting invasion success of forest pathogenic fungi from species traits. *Journal of Applied Ecology* 48(6): 1381-1390. <https://doi.org/10.1111/j.1365-2664.2011.02039.x>
- Phillips, S.J., Anderson, R.P., Schapire, R.E. 2006. Maximum entropy modeling of species geographic distributions. *Ecological Modelling* 190: 231-259. <https://doi.org/10.1016/j.ecolmodel.2005.03.026>
- Pichler, M., Hartig, F. 2023. Machine learning and deep learning—a review for ecologists. *Methods in Ecology and Evolution* 14(4): 994-1016. <https://doi.org/10.1111/2041-210X.14061>
- Polverino, G., Soman, V.R., Karakaya, M., Gasparini, C., Evans, J.P., Porfiri, M. 2022. Ecology of fear in highly invasive fish revealed by robots. *iScience* 25: 103529. <https://doi.org/10.1016/j.isci.2021.103529>
- Pontin, D.R., Schliebs, S., Worner, S.P., Watts, M.J. 2011. Determining factors that influence the dispersal of a pelagic species: A comparison between artificial neural networks and evolutionary algorithms. *Ecological Modelling* 222(10): 1657-1665. <https://doi.org/10.1016/j.ecolmodel.2011.03.002>
- Potapov, A. 2009. Stochastic model of lake system invasion and its optimal control: neurodynamic programming as a solution method. *Natural Resource Modeling* 22(2): 257-288. <https://doi.org/10.1111/j.1939-7445.2008.00036.x>
- Prado Osco, L., Wu, Q., Lopes de Lemos, E., Nunes Gonçalves, W., Marques Ramos, A.P., Li, J., Marcato Junior, J. 2023. The Segment Anything Model (SAM) for remote sensing applications: From zero to one shot. *International Journal of Applied Earth Observation and Geoinformation* 124: 103540. <https://doi.org/10.1016/j.jag.2023.103540>
- Prober, S.M., Hilbert, D.W., Ferrier, S., Dunlop, M., Gobbett, D. 2012. Combining community-level spatial modelling and expert knowledge to inform climate adaptation in temperate grassy eucalypt woodlands and related grasslands. *Biodiversity and Conservation* 21(7): 1627-1650. <https://doi.org/10.1007/s10531-012-0268-4>
- Pyron, R.A. 2023. Unsupervised machine learning for species delimitation, integrative taxonomy, and biodiversity conservation. *Molecular Phylogenetics and Evolution* 189: 107939. <https://doi.org/10.1016/j.ympev.2023.107939>
- Raab, C., Stroh, H.G., Tonn, B., Meissner, M., Rohwer, N., Balkenhol, N., e Isselstein, J. 2018. Mapping semi-natural grassland communities using multi-temporal RapidEye remote sensing data. *International Journal of Remote Sensing* 39(17): 5638-5659. <https://doi.org/10.1080/01431161.2018.1504344>
- Rainio, O., Teuho, J., Klén, R. 2024. Evaluation metrics and statistical tests for machine learning. *Scientific Reports* 14: 6086. <https://doi.org/10.1038/s41598-024-56706-x>
- Rodas-Trejo, J., Ocampo-González, P. 2024. Assessment of ChatGPT's potential as an innovative tool in searching for information on wild mammals. *Ecological Informatics* 102810. <https://doi.org/10.1016/j.ecoinf.2024.102810>
- Roberts, J., Florentine, S. 2024. Advancements and developments in the detection and control of invasive weeds: A global review of the current challenges and future opportunities. *Weed Science* 72(3): 205-215. <https://doi.org/10.1017/wsc.2024.13>
- Roy, H.E., Pauchard, A., Stoett, P.J., Renard Truong, T., Meyerson, L.A., Bacher, S., Galil, B.S., et al. 2024. Curbing the major and growing threats from invasive alien species is urgent and achievable. *Nature Ecology and Evolution* 8: 1216-1223.
- Saffer, A., Worm, T., Takeuchi, Y., Meentemeyer, R. 2024. GIATAR: a spatio-temporal dataset of global invasive and alien species and their traits. *Scientific Data* 11: 991. <https://doi.org/10.1038/s41597-024-03824-w>
- Salcedo, E., Uchani, Y., Mamani, M., Fernandez, M. 2024. Towards continuous floating invasive plant removal using unmanned surface vehicles and computer vision. *IEEE Access* 12: 6649-6662. <https://doi.org/10.1109/ACCESS.2024.3351764>
- Salguero-Gómez, R., Gamelon, M. (eds). 2021. *Demographic methods across the tree of life*. Oxford University Press. Oxford. UK. <https://doi.org/10.1093/oso/9780198838609.001.0001>
- Salguero-Gómez, R., Jones, O.R., Archer, C.R., Buckley, Y.M., Che-Castaldo, J., Caswell, H., Hodgson, D., et al. 2015. The compadre Plant Matrix Database: an open online repository for plant demography. *Journal of Ecology* 103: 202-218.
- Salguero-Gómez, R., Jones, O.R., Archer, C.R., Bein, C., de Buhr, H., Farack, C., Gottschalk, F., et al. 2016. COMADRE: a global data base of animal demography. *Journal of Animal Ecology* 85: 371-384. <https://doi.org/10.1111/1365-2656.12482>
- Sampaio Franco, A.C., Garcia-Berthou, E., Neves dos Santos, L. 2021. Ecological impacts of an invasive top predator fish across South America. *Science of the Total Environment* 761: 143296. <https://doi.org/10.1016/j.scitotenv.2020.143296>
- Santoian, L.A., Innangi, M., Varricchio, M., Carboni, M., La Bella, G., Haider, S., Stanisci, A. 2024. Ecological features facilitating spread of alien plants along Mediterranean mountain roads. *Biological Invasions* 26(11): 3879-3899. <https://doi.org/10.1007/s10530-024-03418-y>
- Schmickl, T., Romano, D. 2024. Robots and animals teaming up in the wild to tackle ecosystem challenges. *Science Robotics* 9: eado5566. <https://doi.org/10.1126/scirobotics.ado5566>
- Sillero, N., Arenas-Castro, S., Enriquez-Urzelai, U., Vale, C.G., Sousa-Guedes, D., Martínez-Freiria, F., Real, R., Mácia, B.A. 2021. Want to model a species niche? A step-by-step guideline on correlative ecological niche modelling. *Ecological Modelling* 456: 109671. <https://doi.org/10.1016/j.ecolmodel.2021.109671>
- Silvestro, D., Gorla, S., Sterner, T., Antonelli, A. 2022. Improving biodiversity protection through artificial intelligence. *Nature Sustainability* 5(5): 415-424. <https://doi.org/10.1038/s41893-022-00851-6>

- Simon, S.M., Glaum, P., Valdovinos, F.S. 2023. Interpreting random forest analysis of ecological models to move from prediction to explanation. *Scientific Reports* 13: 3881. <https://doi.org/10.1038/s41598-023-30313-8>
- Singh, K.K., Surasinghe, T.D., Frazier, A.E. 2024. Systematic review and best practices for drone remote sensing of invasive plants. *Methods in Ecology and Evolution* 15: 998-1015. <https://doi.org/10.1111/2041-210X.14330>
- Soley-Guardia, M., Alvarado-Serrano, D.F., Anderson, R.P. 2024. Top ten hazards to avoid when modeling species distributions: a didactic guide of assumptions, problems, and recommendations. *Ecography* 2024: e06852. <https://doi.org/10.1111/ecog.06852>
- Stockwell, D., Peters, D. 1999. The GARP modelling system: problems and solutions to automated spatial prediction. *International Journal of Geographical Information Science* 13: 143-158. <https://doi.org/10.1080/136588199241391>
- Stone, T.C., Davis, K.J. 2024. Using unmanned aerial vehicles to estimate body volume at scale for ecological monitoring. *Methods in Ecology and Evolution* 00: 1-15. <https://doi.org/10.1101/2023.11.23.567408>
- Sudholz, A., Denman, S., Pople, A., Brennan, M., Amos, M., Hamilton, G. 2022. A comparison of manual and automated detection of rusa deer (*Rusa timorensis*) from RPAS-derived thermal imagery. *Wildlife Research* 49(1): 46-53. <https://doi.org/10.1071/WR20169>
- Toussaint, A., Beauchard, O., Oberdorff, T., Brosse, S., Villeger, S. 2014. Historical assemblage distinctiveness and the introduction of widespread non-native species explain worldwide changes in freshwater fish taxonomic dissimilarity. *Global Ecology and Biogeography* 23(5): 574-584. <https://doi.org/10.1111/geb.12141>
- Trisos, C.H., Auerbach, J., Katti, M. 2021. Decoloniality and anti-oppressive practices for a more ethical ecology. *Nature Ecology and Evolution* 5: 1205-1212. <https://doi.org/10.1038/s41559-021-01460-w>
- Tsamardinos, I., Greasidou, E., Borboudakis, G. 2018. Bootstrapping the out-of-sample predictions for efficient and accurate cross-validation. *Machine Learning* 107: 1895-1922. <https://doi.org/10.1007/s10994-018-5714-4>
- Ulhaq, A., Adams, P., Cox, T.E., Khan, A., Low, T., Paul, M. 2021. Automated detection of animals in low-resolution airborne thermal imagery. *Remote Sensing* 13(16): 3276. <https://doi.org/10.3390/rs13163276>
- Urza, A.K., Board, D.I., Bradford, J.B., Brown, J.L., Chambers, J.C., Schlaepfer, D.R., Short, K.C. 2024. Disentangling drivers of annual grass invasion: Abiotic susceptibility vs. fire-induced conversion to cheatgrass dominance in the sagebrush biome. *Biological Conservation* 297: 110737. <https://doi.org/10.1016/j.biocon.2024.110737>
- Van Belleghem, S.M., Papa, R., Ortiz-Zuazaga, H., Hendrickx, F., Jiggins, C.D., McMillan, W.O., Counterman, B.A., et al. 2018. *patternize*: An R package for quantifying colour pattern variation. *Methods in Ecology and Evolution* 9: 390-398. <https://doi.org/10.1111/2041-210X.12853>
- van Kleunen, M., Pyšek, W., Dawson, F., Essl, H., Kreft, J., Pergl, P., Weigelt, A., et al. 2019. The Global Naturalized Alien Flora (GloNAF) database. *Ecology* 100(1): e02542.
- Veiga Branco, V., Correia, L., Cardoso, P. 2023. The use of machine learning in species threats and conservation analysis. *Biological Conservation* 283: 110091. <https://doi.org/10.1016/j.biocon.2023.110091>
- Wacquet, G., Lefebvre, A. 2022. *EcoTransLearn*: an R-package to easily use transfer learning for ecological studies—a plankton case study. *Bioinformatics* 38(24): 5469-5471. <https://doi.org/10.1093/bioinformatics/btac703>
- Walsh, I., Fishman, D., Garcia-Gasulla, D., Titma, T., Pollastri, G., ELIXIR Machine Learning Focus Group, Harrow, J., et al. 2021. DOME: recommendations for supervised machine learning validation in biology. *Nature Methods* 18: 1122-1127. <https://doi.org/10.1038/s41592-021-01205-4>
- Wang, K., Franklin, S.E., Guo, X., Cattet, M. 2010. Remote sensing of ecology, biodiversity and conservation: a review from the perspective of remote sensing specialists. *Sensors* 10, 9647–9667. <https://doi.org/10.3390/s101109647>
- Wang, L., Silvan-Cardenas, J.L., Yang, J., Frazier, A.E. 2013. Invasive saltcedar (*Tamarisk* spp.) distribution mapping using multiresolution remote sensing imagery. *Professional Geographer* 65(1): 1-15. <https://doi.org/10.1080/00330124.2012.679440>
- Weller, H.I., Hiller, A.E., Lord, N.P., Van Belleghem, S.M. 2024. *recolorize*: An R package for flexible colour segmentation of biological images. *Ecology Letters* 27: e14378. <https://doi.org/10.1111/ele.14378>
- White, D.T., Antoniou, T.M., Martin, J.M., Kmetz, W., Twiss, M.R. 2022. A machine-learning approach to predict success of a biocontrol for invasive *Eurasian watermilfoil* reduction. *Ecological Applications* 32(6): e2625. <https://doi.org/10.1002/eap.2625>
- Wiegand, J., Hirsch, P.E., Seidel, F., Rauter, G., Burkhardt-Holm, P. 2022. Flow, force, behaviour: assessment of a prototype hydraulic barrier for invasive fish. *Hydrobiologia* 849(4): 1001-1019. <https://doi.org/10.1007/s10750-021-04762-z>
- Wilson, N. 2024. Artificial intelligence helps drive new frontiers in ecology. *BioScience* 74(5): 306-311. <https://doi.org/10.1093/biosci/biae016>
- Wood, C.M., Guenther, F., Rex, A., Hofstadter, D.F., Reers, H., Kahl, S., Peery, M.Z., et al. 2024. Real-time acoustic monitoring facilitates the proactive management of biological invasions. *Biological Invasions* 26(12): 3989-3996. <https://doi.org/10.1007/s10530-024-03426-y>
- Xiao, Y., Greiner, R., Lewis, M.A. 2018. Evaluation of machine learning methods for predicting eradication of aquatic invasive species. *Biological Invasions* 20(9): 2485-2503. <https://doi.org/10.1007/s10530-018-1730-3>
- Xiong, B., Han, S., Messerschmidt, T.C., Kirwan, M.L., Gedan, K., Qi, M. 2024. Early detection of invasive *Phragmites australis* at the tidal marsh-forest ecotone with airborne LiDAR. *Ecological Indicators* 167: 112651. <https://doi.org/10.1016/j.ecolind.2024.112651>
- Yang, L., Yan, J., Li, H., Cao, X., Ge, B., Qi, Z., Yan, X. 2022. Real-time classification of invasive plant seeds based on improved YOLOv5 with attention mechanism. *Diversity* 14: 254. <https://doi.org/10.3390/d14040254>
- Yang, W., Wan, X., Deng, M. 2024. Spatial ensemble learning for predicting the potential geographical distribution of invasive species. *International Journal of Geographical Information Science* 38(11): 2216-2234. <https://doi.org/10.1080/13658816.2024.2376325>
- Zhang, M., Shi, C., Li, X., Wang, K., Qiu, Z., Shi, F. 2023. Changes in the structure and function of rhizosphere soil microbial communities induced by *Amaranthus palmeri* invasion. *Frontiers in Microbiology* 14: 1114388. <https://doi.org/10.3389/fmicb.2023.1114388>
- Zhao, J.Q., Gao, T., Du, J.J., Shi, J. 2023a. Future trends in *Obolodiplosis robiniae* distribution across the Eurasian continent under global climate change. *Insects* 14(1): 48. <https://doi.org/10.3390/insects14010048>
- Zhao, Z., Fan, C., Liu, L. 2023b. Geo SAM: A QGIS plugin using Segment Anything Model (SAM) to accelerate geospatial image segmentation (1.1.0). Zenodo.
- Zhu, W., Ding, Z., Pan, Y., Wang, Q. 2022. Using an affinity analysis to identify phytoplankton associations. *Ecology and Evolution* 12, e9047. <https://doi.org/10.1002/ece3.9047>
- Zhuang, J., Jin, X., Chen, Y., Meng, W., Wang, Y., Yu, J., Muthukumar, B. 2023. Drought stress impact on the performance of deep convolutional neural networks for weed detection in bahiagrass. *Grass and Forage Science* 78(1): 214-223. <https://doi.org/10.1111/gfs.12583>
- Zurell, D., Franklin, J., König, C., Bouchet, P.J., Dormann, C.F., Elith, J., Fandos, G., et al. 2020. A standard protocol for reporting species distribution models. *Ecography* 43: 1261-1277. <https://doi.org/10.1111/ecog.04960>