

1 IA y Big Data para la biología de invasiones: descubrir, modelar y 2 predecir las dinámicas poblacionales de las especies invasoras

3 4 AI and Big Data for invasion biology: finding, modelling and 5 forecasting the population dynamics of invaders

6
7 **Erola Fenollosa^{1*}, Roberto Salguero-Gómez¹**

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

9 *Autor de correspondencia: E. Fenollosa [erola.fenollosaromani@biology.ox.ac.uk,
10 erola.fenollosa@gmail.com]

11 12 13 **RESUMEN (250)**

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

31
32
33 **Palabras clave:** Aprendizaje automático; Demografía; Especies exóticas; Inteligencia Artificial (IA);
34 Modelos de distribución de especies; Teledetección.

35
36 **English Abstract:** Artificial intelligence (AI) is rapidly transforming the study and management of
37 invasive species through analytical and predictive tools that optimize detection, monitoring, and

38 automated eradication. In this work, we reviewed the fundamental principles of machine learning and
39 deep learning, illustrated with recent case studies on invasive species. We also present the first
40 systematic review of AI applications in the field of biological invasions and demography, encompassing
41 278 articles published since 1999, with 50% of them appearing in the last five years, highlighting the
42 rapid progress in this area and its applications. We observe that most studies focused on plants and
43 detection tasks, utilizing satellite images, drones, and digital cameras as primary data sources, enabling
44 unprecedented precision and efficiency in monitoring invasions. Deep learning algorithms stand out for
45 their ability to process complex visual data, while ensemble modelling approaches produce more robust
46 predictions. The growing availability of global databases, images, and collaborative platforms has
47 significantly reduced fieldwork costs, improved access to larger and remote areas, and enabled the use
48 of algorithms without requiring advanced programming expertise. This work serves as a practical and
49 accessible guide for researchers new to AI, highlighting the most recent advances and its transformative
50 potential to address the challenges of biological invasions.

51

52 **Keywords:** Artificial intelligence (AI), Demography, Exotic species, Machine learning, Remote sensing,
53 Species distribution models.

54

55 **Inteligencia artificial en ecología, una pequeña introducción para principiantes**

56 La inteligencia artificial (IA) está transformando rápidamente muchas áreas del conocimiento, y la
57 ecología no es una excepción (Christin et al., 2019; Borowiec et al., 2022; Cui et al., 2023; Han et al.,
58 2023; Pichler y Hartig, 2023; Wilson, 2024). Con el aumento de datos ambientales y la necesidad de
59 análisis complejos, la IA ha emergido como una herramienta de gran potencial para abordar preguntas
60 ecológicas a gran escala y alta resolución (Galaz García et al., 2023; Veiga Branco et al., 2023). La IA
61 permite procesar grandes volúmenes de información (el “*Big Data*”), lo que resulta especialmente útil
62 en el contexto de la ecología, donde cada vez es más común integrar múltiples fuentes como imágenes
63 satelitales, sensores remotos, o estudios de campo (Buchelt et al., 2024).

64

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

76

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

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

101
102 A continuación, expondremos el funcionamiento del aprendizaje automático sobre ejemplos concretos.
103 Para determinar si en una fotografía aparece una especie invasora en particular, es necesario contar
104 con muchas imágenes etiquetadas que indiquen si la especie está presente o no. Publicaciones
105 recientes utilizando estas técnicas incorporan desde 300 (Mqingwana et al., 2024), 4,200 (Matsushashi
106 et al., 2024) o hasta 309,373 fotografías (Chaity y van Aardt, 2024). Una vez que hemos examinado
107 parte de esas fotografías (conjunto de entrenamiento) y sus atributos relevantes (como la forma y
108 disposición de las hojas, el tamaño, el color de la flor, etc.), seremos capaces de identificar si en una
109 nueva foto (conjunto de prueba) esa especie está o no presente. Cuando esta tarea la realiza un
110 sistema computacional, hablamos de **aprendizaje supervisado**, ya que sabiendo la categoría de cada
111 imagen (presencia o no de la especie), supervisamos como realiza la clasificación el sistema de IA. En
112 cambio, si no tenemos información sobre qué especies aparecen en cada fotografía (datos no
113 etiquetados), el modelo no podrá aprender a identificar la presencia de una especie específica, pero sí
114 podrá agrupar las imágenes en función de similitudes, como el tipo de planta (herbácea, arbusto, árbol)
115 o el color de las flores. Este tipo de aproximación es un caso de **aprendizaje no supervisado**, ya que
116 el algoritmo detecta patrones de agrupación basándose únicamente en datos no etiquetados.

117

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

129

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

140

141 Además de estos dos tipos de aprendizaje (supervisado y no supervisado), existen opciones mixtas,
142 como el aprendizaje **semi-supervisado** y el **aprendizaje por refuerzo**. En el aprendizaje semi-
143 supervisado (Hastie et al., 2009) se emplea una combinación de datos etiquetados y no etiquetados,
144 como por ejemplo para reconocer biodiversidad acuática con pocos registros etiquetados (Ma et al.,
145 2024). En contraste, el aprendizaje por refuerzo ("*reinforcement learning*", Lapeyrolerie et al., 2022)
146 introduce un elemento adicional: la recompensa. En este tipo de aprendizaje, el modelo toma acciones,
147 recibe información del entorno resultante y una evaluación de sus decisiones. Ha sido especialmente
148 de interés para la toma de decisiones de conservación (Lapeyrolerie et al., 2022), como la optimización
149 de recursos en gestión de fauna (Fonnesbeck, 2008) o balancear costos y beneficios de la protección
150 de la biodiversidad en diferentes áreas (Silvestro et al., 2022).

151

152 Existen diferentes aproximaciones para el aprendizaje en función del nivel de transparencia del modelo.
153 Las tareas de regresión, clasificación, agrupación y asociación se pueden resolver con diferentes
154 aproximaciones en función de si especificamos las variables a partir de las que queremos que el
155 modelo aprenda (aprendizaje automático), o si dejamos que el modelo identifique las variables más
156 relevantes (aprendizaje profundo). En el **aprendizaje profundo** ("*deep learning*"; Christin et al., 2019;

157 Borowiec et al., 2022), el algoritmo detecta y extrae los atributos más relevantes de nuestros datos
158 gracias a la descomposición de estos en múltiples capas y nodos que se relacionan de una forma
159 similar a una red neuronal (Olden et al., 2008). Las redes neuronales convolucionales (CNN) y las
160 redes neuronales recurrentes (RNN) son las arquitecturas de redes neuronales más usadas en
161 ecología (Christin et al., 2019) y pueden ser adaptadas tanto a tareas de regresión como clasificación.
162 Ejemplos en ecología incluyen la cuantificación del daño foliar (Loyani, 2024), o la detección de peces
163 a partir de videos submarinos (Fleure et al., 2024). Especialmente en aprendizaje profundo se ha
164 popularizado recientemente el uso de **aprendizaje por transferencia** ("*transfer learning*", Pan y Yang,
165 2010), en que se reutiliza o adapta unos datos nuevos un modelo previamente entrenado con otros
166 datos. Por ejemplo, bases de datos de imágenes públicas como ImageNet puede ser utilizado para
167 pre-entrenar un modelo descargable en línea que después se puede utilizar para identificación de tipos
168 de plancton a través del paquete de R EcoTransLearn (Wacquet y Lefebvre, 2022).

169

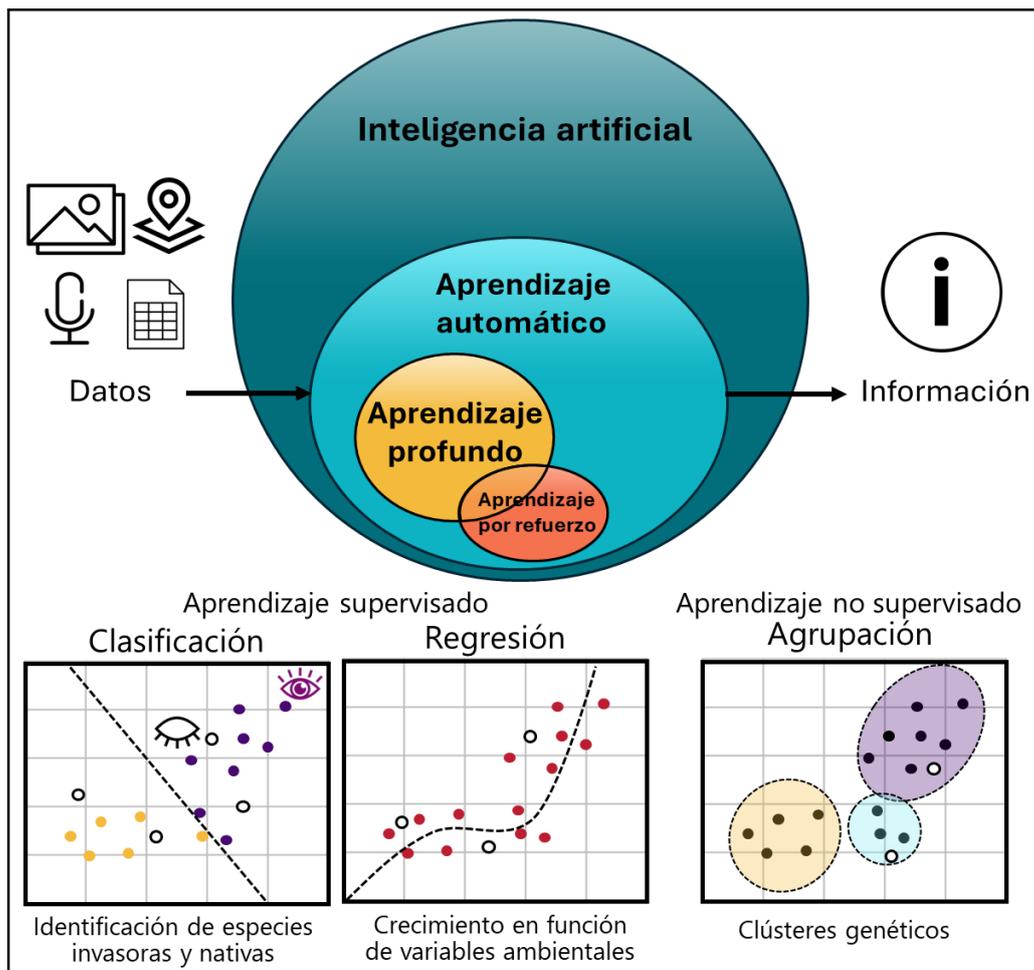
170 En los últimos años se ha considerado no sólo de baterías de algoritmos para ver cual resulta en una
171 mayor capacidad de resolver nuestro problema, sino también el **ensamblaje** (Cao et al., 2020) de
172 múltiples algoritmos para un resultado más robusto, combinando las ventajas de cada modelo
173 individual. Existen diferentes métodos de ensamblaje de modelos, los más utilizados son el *bagging*
174 (múltiples modelos son entrenados en subconjuntos de los datos y promediados) y el *boosting*
175 (entrenamiento secuencial de modelos) (Dietterich, 2000).

176

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

190

191



192

193

194

195

196

197

198

199

200

201

202

203

204

205

206

207

Figura 1. IA para principiantes. Diagrama de Van 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 testear 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. 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.

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

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

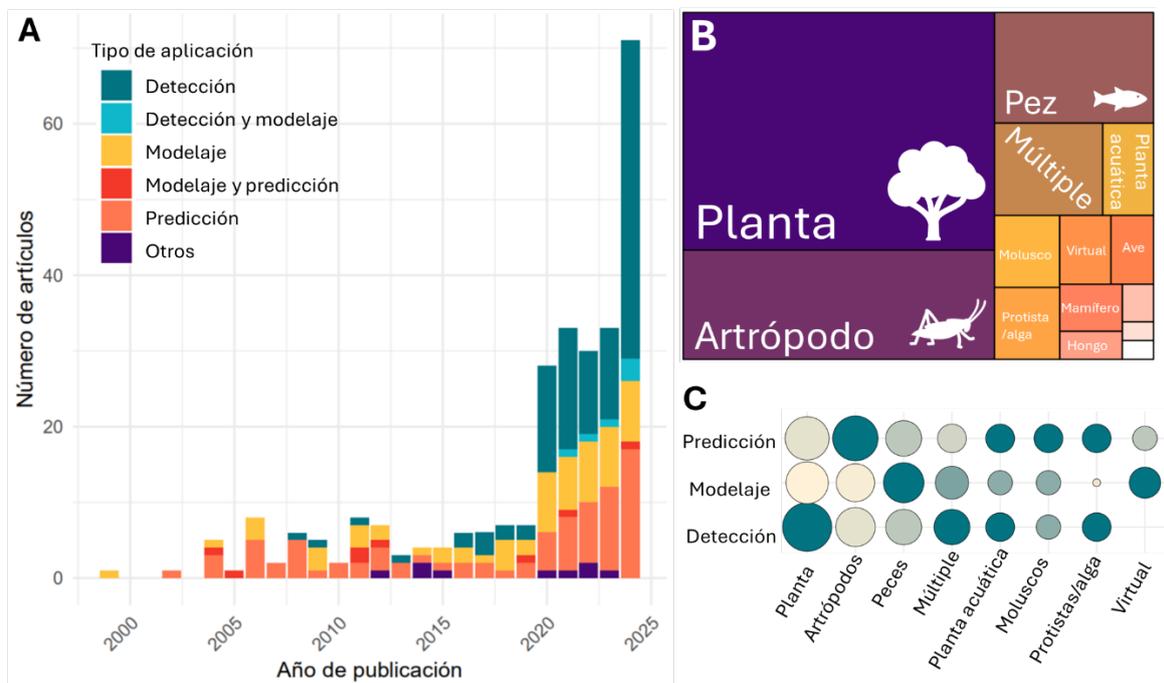
235
236 La producción de artículos sobre IA e invasiones ha crecido significativamente en los últimos años.
237 Aunque el uso de la IA en este campo data de 1999, casi la mitad de los artículos (48.16%) se han
238 publicado entre 2022 y 2024 (**Figura 2A**). Dichos estudios se han centrado principalmente en tres
239 grupos taxonómicos: plantas (45.3%), artrópodos (20.9%) y peces (10.8%) (**Figura 2B**). Este sesgo
240 taxonómico coincide con las tendencias globales de especies invasoras, donde las plantas son el grupo
241 más numeroso, seguidas por insectos y otros taxones, como crustáceos y moluscos (Roy et al., 2024).

242
243 En la última década, la detección de especies invasoras ha sido la aplicación más destacada de la IA.
244 Este crecimiento se refleja en el aumento exponencial de publicaciones, con un máximo de 45 artículos
245 en 2024, a pesar de ser un año aún incompleto al momento de la revisión (30 de octubre; Figura 2A).
246 Las primeras aplicaciones de IA en invasiones biológicas se centraron en el modelado y la predicción.
247 Por ejemplo, en 1999, Aussem y Hill utilizaron redes neuronales para simular la expansión y biomasa

248 del alga invasora comúnmente llamada alga asesina (*Caulerpa taxifolia*) en el Mediterráneo. También
 249 en esos años, Iguchi et al. (2004) usa un algoritmo genético para construir un modelo de distribución
 250 de especies en función de las características climáticas de las zonas que ocupa para predecir el
 251 potencial invasor de dos especies de perca nativas del norte de América, en Japón. Las aplicaciones
 252 de la IA en invasiones biológicas han variado según el taxón, con predominancia por la detección en
 253 plantas (e.g., Marzialetti et al., 2021), modelado en peces (e.g., Epstein et al., 2018) y predicción en
 254 artrópodos (e.g., Gil-Tapetado et al., 2024) (Figura 2C).

255
 256 Los algoritmos más utilizados en los estudios revisados incluyen modelos de regresión y clasificación.
 257 Los modelos de regresión han sido aplicados para predecir la presencia de especies en función de
 258 variables climáticas (e.g., Yang et al., 2024 o Urza et al., 2024), mientras que los modelos de
 259 clasificación han sido utilizados, por ejemplo, para identificar huevos de peces invasores a partir de
 260 datos morfológicos (Camacho et al., 2019). En contraste, los modelos de agregación y el aprendizaje
 261 por refuerzo han sido menos comunes. Entre los modelos de agregación se encuentran aplicaciones
 262 como agrupar los patrones de comportamiento de un caracol invasor en función de la temperatura (Bae
 263 et al., 2021). Sólo cuatro estudios aplicaron aprendizaje por refuerzo en nuestra búsqueda,
 264 principalmente en simulaciones complejas, como interacciones entre especies (Prober et al., 2012;
 265 Blonder et al., 2024) o modelos de gestión óptima en ecosistemas acuáticos (Potapov, 2009).

266
 267



268
 269 **Figura 2.** Revisión sistemática del uso de inteligencia artificial para el estudio de especies invasoras
 270 en la literatura científica. A) Cronograma de los artículos encontrados (1999-2024, búsqueda el 30 de
 271 octubre de 2024) y la clasificación de la aplicación por la cual se utiliza la IA. B) Mapa de árbol
 272 representando el número de estudios en diferentes grupos taxonómicos, destacando los que agruparon
 273 mayor número de artículos: plantas, artrópodos y peces. C) Mapa de puntos relacionando las diferentes

274 tareas de la IA con los taxones para los que se encontraron más de cinco artículos. Mientras que el
275 tamaño del punto representa el número relativo de artículos totales, la intensidad de color representa
276 la tarea mayoritaria en cada grupo taxonómico (que coincide con el tamaño de punto más grande para
277 cada taxón).

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

286

287 **Descubrir: Métodos de detección de especies invasoras con IA**

288 La detección de especies invasoras es una de las aplicaciones más importantes de la inteligencia
289 artificial (IA) en la disciplina de la biología de la invasión, especialmente en los últimos años (**Figura**
290 **2**). La detección y especialmente la detección temprana son cruciales en la gestión de especies
291 invasoras, para reducir sus impactos a largo plazo (Latombe et al., 2017). Las mejoras en la captura
292 (Nazir y Kaleem, 2021) y procesamiento de imágenes (Wang et al., 2010; Krizhevsky et al., 2017), así como
293 la disponibilidad de imágenes digitales (Depauw et al., 2022) y satelitales (Cavender-Bares et al.,
294 2022), han facilitado mucho el desarrollo de múltiples herramientas para la identificación automática
295 de especies invasoras (Martinez et al., 2020).

296

297 La mayoría de los estudios de detección se basaron en imágenes como fuente principal de datos. Más
298 del 90% de los artículos revisados ($n = 278$) utilizaron imágenes obtenidas de satélites (32.4%),
299 cámaras digitales (29.4%), drones o vehículos controlados remotamente (27.5%) y tipos de cámaras o
300 sensores especializados (10.8%, imágenes termales, cámaras hiperespectrales, Lidar, etc.). Sin
301 embargo, también se han empleado datos alternativos como grabaciones de audio (Gugele et al., 2021;
302 Wood et al., 2024), trayectorias de movimiento (Wiegler et al., 2022) o características morfológicas
303 (Camacho et al., 2019).

304

305 Los algoritmos de aprendizaje profundo, especialmente las redes neuronales convolucionales (CNN),
306 son predominantes en la detección de especies invasoras. Estos algoritmos destacan por su capacidad
307 para procesar datos visuales sin necesidad de variables predefinidas (García-Navarrete et al., 2024).
308 Las redes neuronales convolucionales (CNN), diseñadas específicamente para analizar imágenes, han
309 sido utilizadas en numerosos estudios para identificar plantas, insectos y animales invasores (por
310 ejemplo, Dunker et al., 2018; Champ et al., 2020; Gupta et al., 2020; Horning et al., 2020; Kattenborn
311 et al., 2020; Mkonyi et al., 2020; Tang et al., 2021; Sudholz et al., 2022, Almalky y Ahmed, 2023;
312 Kulkarni y Minin, 2023; Cardoso et al., 2024; Keerthinathan et al., 2024). Es de especial interés el que

313 las CNN se pueden construir con diferentes arquitecturas (diferente número y estructura de capas y
314 neuronas) y existen algunas arquitecturas predefinidas de interés, como AlexNet (Zhuang et al., 2023),
315 ResNet (Bao et al., 2024), EfficientNet (Devi et al., 2023), o YOLO (Liu et al., 2022; Zhuang et al., 2023;
316 Matsuhashi et al., 2024; Salcedo et al., 2024), las cuales son discutidas en más extensión a
317 continuación.

318

319 Las imágenes satelitales ofrecen una herramienta poderosa para la detección de plantas invasoras.
320 Estudios como el de Castillo et al. (2008) marcaron el inicio de esta línea de investigación, utilizando
321 imágenes de MODIS 250m RGB para detectar la planta acuática *Lemna obscura*. Hasta el momento,
322 únicamente encontramos el uso de imágenes de satélite para la detección de plantas invasoras,
323 probablemente por la naturaleza sésil de estas, que permite en principio obtener ocurrencias completas
324 de plantas invasoras en ciertas áreas a partir de imágenes de satélite multiespectrales (Wang et al.,
325 2013; Meerdink et al., 2024). La ventaja del uso de imágenes de satélite respecto a métodos más
326 tradicionales como censos poblacionales de campo (Salguero-Gómez y Gamelon, 2021) o estudios
327 fenológicos mediante observación directa (Fenner, 1998) radica en la cobertura espacial y temporal,
328 que permite monitorear grandes áreas y realizar análisis estacionales (Cavender-Bares et al., 2022;
329 Katal et al., 2022). No obstante, una desventaja de las imágenes de satélite multiespectrales es su
330 actual resolución. Actualmente, la máxima resolución se encuentra entre 0.3 y 0.5 m (EOSDA
331 LandViewer), pero la eficiencia de la detección de especies dependerá, no solo del tamaño de estas
332 sino también del contraste en los hábitats que ocupa, siendo por ejemplo útil para la detección de
333 ballenas o elefantes en entornos homogéneos, pero no para individuos de ñu en biomas complejos
334 (Hollings et al., 2018). En algunas especies el uso de imágenes en diferentes momentos permitió una
335 detección más precisa, como al principio de la temporada de crecimiento y durante el proceso de
336 senescencia en praderas (Raab et al., 2018), o antes y durante la floración en acacia azul (*Acacia*
337 *saligna*, Marzioletti et al., 2021).

338

339 El uso de cámaras digitales (incluyendo cámaras montadas en vehículos remotos) agrupa la mayor
340 cantidad de artículos que usan IA para la detección de especies invasoras (29.4% cámaras digitales,
341 27.5% vehículos remotos). Por ejemplo, Yang et al. (2022) construyó una base de datos con 3,000
342 imágenes de semillas 12 especies invasoras para entrenar una CNN para detectarlas en el transito
343 global. En este trabajo, Yang et al., utilizó una de las arquitecturas de CNN comentada anteriormente
344 y que ha ganado más fama últimamente, el modelo YOLO (Solo miras una vez, “*You Only Look Once*”)
345 que también se ha utilizado para detectar la avispa asiática (*Vespa velutina*; O’Shea-Wheller et al.,
346 2024), la chinche hedionda (*Halyomorpha halys*; Palazzetti et al., 2024), o ciervo de Timor (*Rusa*
347 *timorensis*; Sudholz et al., 2022). Algunos de los modelos comentados en el anterior párrafo utilizan no
348 sólo una arquitectura de red neuronal predefinida, sino también una red pre-entrenada (aprendizaje
349 por transferencia), reduciendo así la demanda de datos. Éste es el caso de Gupta et al. (2020) para la
350 detección de plántulas no deseadas en base a fotografías de RGB, o Ulhaq et al. (2021) para detectar
351 cerdos, conejos y canguros en base a imágenes térmicas.

352

353 La disponibilidad de imágenes digitales en línea ha permitido aplicaciones de detección de especies
354 invasoras sin recogida de datos en campo. Por ejemplo, las imágenes de *Google Street View* permiten
355 detectar especies invasoras a lo largo de carreteras (Kotowska et al., 2021). También imágenes en
356 redes sociales (Flickr, Twitter, Instagram, y Facebook) han permitido la detección temprana de la hierba
357 de la pampa (*Cortaderia selloana*; Cardoso et al., 2024) y datos de redes sociales en general también
358 son especialmente útiles para entender la dimensión social de las especies invasoras (Novoa et al.,
359 2024).

360

361 El uso de drones para el monitoreo de especies invasoras ha incrementado rápidamente en la última
362 década (Dash et al., 2019; Singh et al., 2024). En su revisión, Singh et al. comentó que la mayoría de
363 los estudios hasta la fecha se centran en el testeo de diferentes algoritmos de aprendizaje automático
364 y profundo para clasificar especies invasoras, y menos estudios que presentan monitoreo de éstas. En
365 este contexto, las imágenes de dron resultan especialmente útiles para cubrir grandes extensiones en
366 áreas remotas o poco accesibles (**Figura 3**), obteniendo así de forma precisa la cobertura vegetal
367 (Kattenborn et al., 2020; Bravo-Diaz et al., 2024). El estudio de James y Bradshaw (2020) presenta
368 una metodología para la detección de plantas con drones durante el vuelo, dónde en base a redes
369 neuronales y el desarrollo en la aplicación DJI SDK UXSDKDEMO ([https://github.com/DJI-Mobile-SDK-](https://github.com/DJI-Mobile-SDK-Tutorials/Android-UXSDKDemo)
370 [Tutorials/Android-UXSDKDemo](https://github.com/DJI-Mobile-SDK-Tutorials/Android-UXSDKDemo)) se muestra en pantalla y en vivo las áreas donde la especie de interés
371 se encuentra, de alto interés para especies invasoras. No sólo para detectar la presencia de individuos
372 sino también para su conteo, el uso de imágenes de dron ha demostrado ser más eficiente que el
373 conteo humano (Hodgson et al., 2018).

374

375 Las imágenes térmicas o el uso de videos pueden proporcionar más precisión que las imágenes
376 digitales para detectar algunas especies invasoras en particular. La detección de mamíferos (o de
377 cualquier especie con metabolismo activo; endotermos; Stone y Davis, 2024) es especialmente
378 eficiente a través de imágenes térmicas (Ulhaq et al., 2021; Gonzalez et al., 2016). El uso de videos
379 para la detección de especies invasoras proporciona mucha resolución temporal, así como un mayor
380 número de imágenes totales (González et al., 2016; Ulhaq et al., 2021; Sudholz et al., 2022; Dyrmann
381 et al., 2024). Los videos resultan especialmente útiles para el monitoreo de organismos móviles,
382 incluyendo animales marinos (Fleure et al., 2024) o mamíferos (Ulhaq et al., 2021) y también la
383 detección en movimiento, como la detección de plantas invasoras en carreteras a partir de videos de
384 un coche con alta velocidad (Dyrmann et al., 2024).

385

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

392 avances consolidan la IA como una herramienta esencial para la gestión y el monitoreo de especies
393 invasoras.
394

395 **Modelar: importancia de variables y adquisición de datos**

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

401
402 La IA permite identificar la importancia relativa de predictores sobre variables de interés de manera
403 eficiente. Los algoritmos de aprendizaje automatizado facilitan el manejo de relaciones no lineales y la
404 identificación de factores clave en procesos biológicos. Entre las aplicaciones destacadas en
405 invasiones biológicas se encuentran la explicación de la presencia o abundancia de especies (Sampaio
406 Franco et al., 2021; White et al., 2022), la riqueza de especies invasoras (Toussaint et al., 2014;
407 Santoianni et al., 2024), la dispersión de especies (Pontin et al., 2011) y el éxito de programas de
408 erradicación (Xiao et al., 2018). También destacamos la existencia de múltiples trabajos que se enfocan
409 en identificar características que determinan el comportamiento invasor mediante bases de datos de
410 atributos (Kolar, 2004; Philibert et al., 2011; Keller et al., 2011).

411
412 A parte de determinar la importancia de factores, otra aplicación de la IA para modelar las invasiones
413 biológicas es ampliar o acelerar la captura de datos. El aprendizaje automático y profundo se han
414 utilizado para entrenar modelos que nos permitan una adquisición de datos más rápida y menos
415 costosa con una alta precisión (**Figura 3**). El desarrollo de cámaras y lentes ha permitido plantear la
416 sustitución de las largas visitas al campo por el vuelo de drones o los costosos análisis al laboratorio
417 por fotografías hiperespectrales. Por ejemplo, gracias al desarrollo de métodos de reconstrucción 3D
418 es posible estimar el volumen corporal de animales de forma remota a través del vuelo de un dron (Los
419 et al., 2023; Stone y Davis, 2024). En invasiones biológicas se han empleado imágenes para
420 caracterizar el crecimiento y estructura poblacional (Benzer y Benzer, 2020; Bednarsek et al., 2022),
421 componentes esenciales para cuantificar las dinámicas de invasión. Otra fuente de datos que la IA nos
422 permite explotar mejor es la literatura publicada. Por ejemplo, para entender las aproximaciones en la
423 restauración forestal, Nunez-Mir et al. (2015) hacen una revisión sistemática con análisis de contenido
424 automático, lo que denominamos “*big literature*” (Bolaños et al., 2024).

425
426 La IA se ha utilizado no sólo para entender los determinantes de la invasión, o cuantificar su
427 demografía, sino también para evaluar sus impactos. Por ejemplo, para cuantificar los impactos
428 específicos sobre otra especie, como cuantificar el nivel de daño foliar sobre hojas de tomate por parte
429 de la polilla del tomate (*Tuta absoluta*; Loyani, 2024). De forma similar, el uso de la IA también resulta
430 útil para reducir datos multidimensionales, como la composición del microbioma del suelo (Li et al.,

431 2022) o propiedades fisicoquímicas (Zhang et al., 2023) y encontrar marcadores de interés que nos
432 ayuden a detectar los impactos de la invasión.

433

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

439



440

441 **Figura 3.** Detección, modelaje y predicción de plantas invasoras a partir de imágenes de dron e
442 inteligencia artificial. La captura de datos demográficos a partir de aplicar la IA en imágenes de dron
443 permite capturar el tamaño de la población manteniendo las distancias con especies invasoras dañinas
444 como la chumbera (A), acceder a terrenos difíciles (B) y cubrir grandes extensiones (C). Gracias al
445 entrenamiento de modelos de aprendizaje automático podemos detectar nuevos individuos, cuantificar
446 tasas vitales (supervivencia, crecimiento y reproducción), evaluar el éxito de programas de
447 erradicación, identificar patrones de distribución espacial o proyectar la dinámica poblacional en el
448 tiempo. Fotografías: Erola Fenollosa, 2024.

449

450 **Figure 3.** Detection, modelling, and prediction of invasive plants using drone images and artificial
451 intelligence. The use of AI on drone imagery enables the capture of demographic data, allowing the
452 estimation of population size while maintaining safe distances from harmful invasive species such as
453 prickly pear cactus (A), accessing difficult terrains (B), and covering large areas (C). Through machine
454 learning, it is possible to detect new individuals, quantify vital rates (survival, growth, and reproduction),
455 assess the success of eradication programs, identify spatial distribution patterns, or project population
456 dynamics over time. Pictures: Erola Fenollosa, 2024.

457

458 **Predecir: Modelos de distribución de especies invasoras**

459 Los modelos de distribución de especies (SDMs, por sus siglas en inglés “*species distribution models*”,
460 Pearson, 2003) son herramientas fundamentales para predecir la idoneidad ambiental de las especies
461 (Guisan et al., 2017). Por esta razón, han sido ampliamente empleados para predecir la distribución
462 potencial de las especies invasoras (Guisan et al., 2014). Los SDMs capturan la relación entre los
463 registros de presencia de especies y diferentes predictores (por ejemplo, temperatura, precipitación o
464 tipo de suelo), utilizando estas relaciones para mapear la probabilidad de presencia de una especie
465 invasora (Davis et al., 2024).

466

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

474

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

487

488 En nuestra revisión sistemática encontramos la predominancia del uso de un solo algoritmo de
489 aprendizaje automático, especialmente GARP y también Maxent. Maxent (“*Maximum Entropy*
490 *Modelling*”; Phillips et al., 2006) es un método de modelado estadístico que busca la distribución más
491 uniforme (máxima entropía) que se ajuste a los datos de ocurrencia y a las restricciones ambientales
492 disponibles. Maxent es popular en la comunidad ecológica por su capacidad para trabajar con datos
493 de presencia únicamente y por generar modelos robustos incluso con conjuntos de datos incompletos
494 o limitados (Jiang et al., 2018; Adepoju et al., 2020; More y Venette, 2020). No obstante, Maxent tiene
495 sus limitaciones (Elith et al., 2011). A partir de aproximadamente 2016 ya no hay artículos usando
496 GARP, mientras que algoritmos basados en arboles de decisiones como los *random forest* y redes
497 neuronales ganan terreno, así como el uso de baterías de algoritmos en vez de uno de sólo. Por

498 ejemplo, Pasha y Reddy (2024) ajustaron múltiples modelos incluyendo MaxEnt, modelos lineales
499 generalizados, modelos aditivos generalizados, redes neuronales, modelo potenciado generalizado y
500 *random forest*, seleccionando el que presenta mejor ajuste para predecir la distribución del arbusto
501 mezquite (*Prosopis juliflora*) a distintos escenarios de cambio climático. Otros estudios no sólo
502 compararon todos estos modelos, sino que ensamblan sus resultados para producir una distribución
503 final. Tal es el caso de Mathur y Mathur (2024), que utilizaron ensamblaje de modelos para predecir la
504 distribución de la chumbera (*Opuntia ficus-indica*) bajo múltiples escenarios de cambio climático. Los
505 autores incluyeron modelos lineales generalizados, modelos aditivos generalizados, *support vector*
506 *machine*, árboles de decisión, *random forest*, Maxent, MARS (*Multivariate adaptive regression splines*)
507 y redes neuronales, combinando las proyecciones resultantes de cada modelo en una sola capa
508 promedio. Es también el caso de Nisin et al. (2023) que proyectó la distribución del pez piracú
509 (*Arapaima gigas*) a través de promediar las probabilidades de presencia de la especie de una selección
510 de los mejores modelos entre 10 algoritmos.

511
512 Aunque útiles, los SDMs presentan limitaciones importantes que deben considerarse. Existen múltiples
513 artículos revisando cómo construir SDMs de forma apropiada (por ejemplo, Araújo et al. 2019; Zurell
514 et al. 2020; Sillero et al. 2021; Hui 2023; Soley-Guardia et al. 2024; Davis et al. 2024). Sin embargo,
515 estos modelos se basan en correlaciones, no en causalidad, y son sensibles a los datos de ocurrencias,
516 que suelen ser imperfectos (Chen et al., 2012) Por ello, los SDMs mecanicistas, que incorporan
517 procesos ecológicos explícitos, son una alternativa prometedora, aunque requieren una alta
518 disponibilidad de datos (Briscoe et al., 2019).

519

520 **Gestión automatizada de especies invasoras con IA**

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

528

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

535

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

547
548 La IA también se emplea en soluciones interactivas y específicas para gestionar fauna invasora. Un
549 ejemplo es el uso de sistemas de captura con cebo automatizado, como el desarrollado por Charlton
550 et al. (2024), que utiliza algoritmos para clasificar especies invasoras y dispensar cebos personalizados
551 para fauna invasora. Asimismo, tecnologías basadas en aprendizaje profundo permiten ahuyentar aves
552 invasoras mediante la detección de su canto y la reproducción de sonidos específicos para proteger
553 cultivos (Chen et al., 2024). El uso de robots basados en animales permite la interacción directa y
554 promete ser clave para la conservación de la biodiversidad (Schmickl y Romano, 2024). Por ejemplo,
555 robots mimetizando predadores se han utilizado para proteger renacuajos nativos de peces invasores
556 (gambusia, *Gambusia affinis*) (Polverino et al., 2022).

557
558 Las tecnologías basadas en IA facilitan la detección de introducciones o reintroducciones a través de
559 aplicaciones innovadoras. En controles de bioseguridad, Yang et al. (2022) entrenó un modelo para
560 identificar semillas invasoras mediante imágenes, mientras que Kulkarni y Di Minin (2023) han utilizado
561 IA para rastrear el comercio ilegal de fauna a partir de fotografías en plataformas digitales.

562
563 La IA transforma la gestión de especies invasoras mediante herramientas que permiten la detección
564 temprana, la interacción en tiempo real y la automatización de acciones específicas. Tal y como hemos
565 presentado en esta sección, robots y sistemas autónomos con IA facilitan la gestión a tiempo real,
566 mientras que el uso de aprendizaje profundo y análisis de datos mejora la vigilancia continua y la
567 evaluación de los esfuerzos de erradicación. Estas innovaciones no solo aumentan la eficiencia de las
568 intervenciones, sino que también reducen significativamente los costos operativos, posicionando a la
569 IA como un componente esencial en la lucha contra las invasiones biológicas.

570

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

572 El ciclo de vida de los proyectos de datos proporciona un marco estructurado para implementar la IA
573 (**Figura 4**). Este proceso circular, regresivo en ocasiones, comienza con la delimitación del problema
574 y finaliza con la comunicación de resultados. En este apartado, se examinan los componentes clave

575 de este ciclo, destacando consideraciones específicas como fuentes de datos y aspectos éticos
576 relevantes para las invasiones biológicas.

577

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

588

589 Una vez planteado el problema y el diseño experimental procederemos a la colección de datos. Como
590 hemos visto en la revisión sistemática, muchos estudios hacen uso de bases de datos o imágenes de
591 acceso libre, permitiendo extender las dimensiones temporales y espaciales de los proyectos. Por ello
592 aquí revisaremos fuentes de datos de interés para proyectos de IA con especies invasoras. Algunas
593 bases de datos de referencia para especies invasoras (Coughlan et al., 2020) son *Global Invasive*
594 *Species Database* (<http://www.iucngisd.org/gisd/>), *Global Naturalized Alien Flora database*
595 (<https://glonaf.org/>), *Global Alien Species First Record Database*
596 (<https://dataportal.senckenberg.de/dataset/global-alien-species-first-record-database>), *European Alien*
597 *Species Information Network* (<https://easin.jrc.ec.europa.eu/easin>) o recientemente GIATAR (*Spatio-*
598 *temporal dataset of global invasive and alien species and their traits*; Saffer et al., 2024). Estas bases
599 de datos proporcionan datos de la ecología, estatus invasor, fechas de introducción, atributos o
600 impactos descritos de especies invasoras, que podemos utilizar para análisis comparativos (Heger et
601 al., 2021). Destacamos también la base de datos de atributos funcionales TRY para plantas que incluye
602 muchas plantas invasoras (Kattge et al., 2020). También destacamos las bases de datos demográficos
603 COMPADRE (Salguero-Gómez et al., 2015), COMADRE (Salguero-Gómez et al., 2016) y PADRINO
604 (Levin et al., 2022) que compilan las tasas vitales (supervivencia, crecimiento y reproducción) de
605 múltiples especies vegetales y animales, incluyendo especies invasoras.

606

607 Otras fuentes de datos que son de interés para el monitoreo de especies invasoras son las imágenes
608 satelitales, los registros de ocurrencias e imágenes de redes sociales. En España destacamos el centro
609 nacional de información geográfica (www.centrodedescargas.cnig.es) que centraliza bases de datos
610 de imágenes satelitales. Adicionalmente, hace poco se desarrolló una base de datos de imágenes de
611 dron, GeoNadir (<https://geonadir.com/>) que podrían proporcionar mayor resolución en sitios
612 específicos, especialmente para el entrenamiento de detección vegetal. Para datos de registros de
613 especies invasoras, GBIF es el portal más empleado (www.gbif.org), así como iNaturalist que permite
614 también el análisis de imágenes geolocalizadas (www.inaturalist.org). Debido a la importancia de la

615 especie humana en las invasiones biológicas, datos de redes sociales, tendencias en Google o
616 comercio electrónico pueden ser especialmente útiles para el monitoreo de la invasión (Novoa et al.,
617 2024). Para la captura de datos en portales web recomendamos las técnicas de raspado web (*Web*
618 *scrapping*) que permite la extracción de contenido HTML de múltiples páginas de forma automática
619 como a partir de anuncios de venta de plantas para detectar tráfico ilegal (Maher et al., 2023).

620

621 La elección del enfoque de aprendizaje condiciona los resultados y la metodología del proyecto.
622 Mientras el aprendizaje profundo es ideal para datos complejos como imágenes, requiere grandes
623 volúmenes de datos. En contraste, el aprendizaje automatizado es más transparente y adecuado para
624 entender condicionantes, pero podría necesitar un procesamiento previo de las variables de interés.
625 Para el análisis de imágenes existen algunos complementos para automatizar esta extracción de
626 atributos para entrenar modelos de aprendizaje automático como el CIMMYT MaizeScanner en ImageJ
627 (<https://github.com/sckefauver/CIMMYT>) o los paquetes *patternizes* (Van Belleghem et al., 2017),
628 *pliman* (Olivoto, 2022) o *recolorize* (Weller et al., 2024) en R. En problemas más simples, o con pocos
629 datos métodos estadísticos tradicionales pueden ser más eficaces (Ley et al., 2022).

630

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

643

644 Las aplicaciones sin programación amplían el acceso a la IA, haciendo más inclusivo su uso en
645 invasiones biológicas. En caso de que no tengamos experiencia en programación existen múltiples
646 aplicaciones específicas basadas en clics que nos permiten el uso de aprendizaje automático y
647 profundo sin necesidad de programar. Empezando por las aplicaciones más específicas, encontramos
648 que algunos artículos de la revisión sistemática realizada incluyeron una aplicación web que permite
649 el uso directo del modelo ya entrenado, como *WhoseEgg* que permite subir datos de morfología de
650 diferentes huevos y en base a un modelo ya entrenado clasifica la especie y si es invasora o no (Goode
651 et al., 2023). De forma similar, Palazzetti et al. (2014) presenta una aplicación para Android que permite
652 la detección a tiempo real de la chinche hedionda (*Halyomorpha halys*) a partir de imágenes
653 usando un modelo entrenado con redes neuronales. De forma más general, no específico para plantas
654 invasoras, destacamos que existen complementos que podemos añadir a herramientas de análisis

655 espacial para segmentar individuos invasores a partir de imágenes, como por ejemplo el complemento
656 de acceso abierto para QGIS GeoSAM basado en el famoso modelo SegmentAnything (Zhao et al.,
657 2023b; Prado Osco et al., 2023). Un último ejemplo del potencial de aplicaciones concretas para acortar
658 distancias con la IA son portales como *Roboflow* o *liner.ai*. Estos portales con modelo *freemium* (parte
659 de los servicios son gratuitos) permiten de forma muy simple entrenar diferentes algoritmos en base a
660 imágenes, con una interfaz muy amigable y permitiendo el etiquetado colaborativo de imágenes.

661
662 El uso de la IA es cada vez una tarea más sencilla, pero no está exenta de responsabilidad. Los
663 patrones que observamos gracias a los modelos de IA dependen (y se limitan) a las variables y datos
664 que hemos considerado y por ende está sujeto a sesgo. Este agosto de 2024 entró en vigor el primer
665 marco jurídico sobre IA en Europa (Ley de AI de la UE, Reglamento 2024/1689) que ahora se está
666 implementando en los estados miembros. En este marco se ha redactado el Código de buenas
667 prácticas de IA de propósito general (GPAI) que se publicará durante la primavera de 2025. Sin
668 embargo, queremos destacar algunos aspectos esenciales, específicamente sobre el uso de
669 algoritmos de aprendizaje automático y considerando los tipos de datos mayoritariamente usados en
670 el campo de las invasiones biológicas.

671
672 Entre buenas prácticas podemos encontrar aspectos técnicos de la construcción de los modelos,
673 aspectos de representatividad de los datos, aspectos de calidad e interpretación del modelo,
674 consideraciones éticas y de privacidad y principios FAIR (Fáciles de encontrar, accesibles,
675 interoperables y reutilizables) (Heil et al., 2021).

676
677 En cuanto a los aspectos técnicos algunos aspectos imprescindibles es asegurar que guardemos una
678 parte de los datos representativa para el testeo a través de técnicas de muestreo estructurado por
679 ejemplo y testeando diferentes particiones. Otro aspecto técnico es la inclusión de muchas variables
680 colineales en algunos modelos de aprendizaje automático. Recomendamos revisar las demandas de
681 cada algoritmo específicamente, así como revisar los parámetros del modelo testeando su impacto de
682 forma estructurada (Fourcade, 2021). Además, de forma general se recomienda preparar el modelo de
683 forma escalable, empezando con las partes más críticas y añadiendo complejidad de forma progresiva.

684
685 Respecto la representatividad de los datos, es común que estos no sean totalmente representativos
686 de la realidad, sino que estén sesgados por múltiples ejes. Por ejemplo, la huella colonialista sigue
687 presente en la actualidad, y es reconocible en los patrones de especies invasoras (Lenzner et al.,
688 2022), impactando en la cantidad de estudios y datos ecológicos disponibles y por tanto en la
689 representatividad de áreas con menos privilegios y realidades minoritarias (Trisos et al., 2021).
690 Recomendamos incluir análisis de representatividad para datos sensibles (Clemmensen y Kjærsgaard,
691 2022) que delimitaran la posibilidad de generalización.

692
693 La interpretación del modelo es requisito indispensable en proyectos con IA. Recomendamos
694 contrastar las predicciones obtenidas con un modelo nulo o previo y la revisión biológica de los

695 resultados. Por ejemplo, el uso SDM para la modelización de la presencia de especies de cuevas sin
 696 tener en cuenta la disponibilidad de hábitat nos retornará predicciones especialmente disparatadas
 697 (Mammola y Leroy, 2017). Durante la evaluación del modelo deberemos incluir diferentes métricos en
 698 función del tipo de tarea realizada e informar no solo de la precisión con los datos de prueba sino
 699 también en los datos de entrenamiento (Rainio et al., 2024).

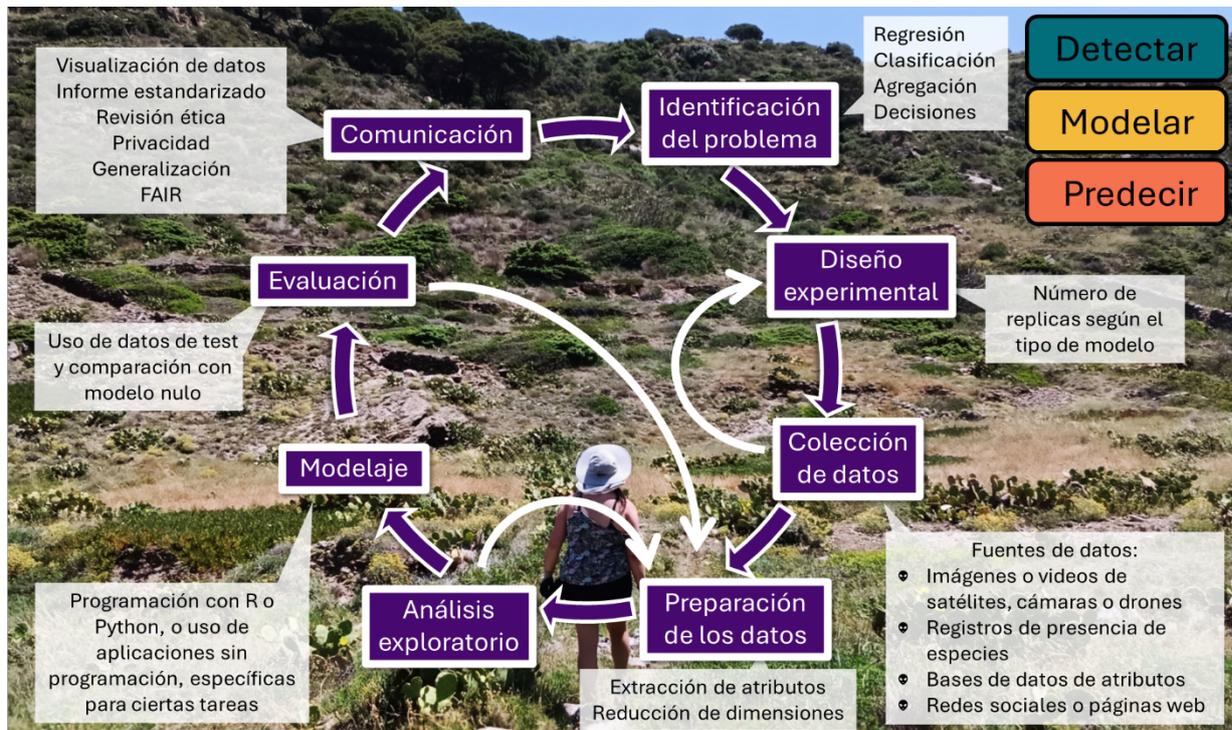
700

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

707

708

709



710

711 **Figura 4:** Ciclo de vida en los proyectos de datos para el estudio de especies invasoras, des de la
 712 identificación del problema y la aplicación de la IA (detectar, modelar, predecir), hasta la comunicación
 713 de resultados, que puede llevar a la identificación de nuevas preguntas. Ver más información en el
 714 texto. Fotografía: Erola Fenollosa 2024.

715 **Figure 4.** Data science lifecycle for the study of invasive species. The lifecycle spans from problem
 716 identification and AI application (detection, modelling, prediction) to the communication of results, which
 717 may lead to the formulation of new questions. See further details in the text. Picture: Erola Fenollosa,
 718 2024.

719

720 **Conclusiones y visión de futuro**

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

729
730 La disponibilidad y calidad de los datos son factores clave que condicionan el éxito de los proyectos
731 de IA en invasiones biológicas. Las herramientas de aprendizaje profundo, como las CNN, destacan
732 en su capacidad para manejar datos visuales complejos, mientras que los modelos de ensamblaje han
733 mejorado la robustez de las predicciones al combinar múltiples algoritmos. Sin embargo, persisten
734 desafíos relacionados con la representatividad de los datos, los sesgos inherentes y la opacidad de
735 algunos algoritmos. Es crucial priorizar el análisis crítico de los datos utilizados y fomentar el acceso a
736 bases de datos diversas y completas.

737
738 Las perspectivas futuras en el uso de la IA para especies invasoras incluyen el desarrollo de modelos
739 más integrados y adaptativos. La combinación de enfoques mecanicistas y de aprendizaje profundo
740 utilizando aprendizaje por transferencia puede mejorar nuestra comprensión de los procesos
741 ecológicos subyacentes en base a conjuntos de datos más limitados y permitir predicciones más
742 precisas. Además, la democratización de las herramientas de IA mediante plataformas accesibles y
743 aplicaciones específicas fomentará la colaboración interdisciplinaria y la integración de múltiples
744 fuentes de datos. Es esencial promover buenas prácticas, incluyendo la adherencia a principios FAIR,
745 evaluación de sesgos, la transparencia en los métodos y la evaluación crítica de las herramientas
746 utilizadas.

747

748 **Contribución de los autores**

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

751

752 **Disponibilidad de datos**

753 La lista de artículos producto de la revisión sistemática y el código para generar las figuras se publicará
754 en FigShare junto con la publicación del artículo. Insertar el DOI aquí.

755

756 **Agradecimientos**

757 E.F. agradece la financiación por parte de UKRI Marie Skłodowska-Curie Actions Fellowship

758 (EP/Y02873/1) bajo la supervisión de R.S.G. R.S.G. agradece la financiación de NERC Pushing the
759 Frontiers grant (NE/X013766/1). No hay conflictos de interés.
760

761 **Referencias bibliográficas**

762 Agathokleous, E., Saitanis, C. J., Fang, C. y Yu, Z. 2023. Use of ChatGPT: What does it mean for
763 biology and environmental science? *Science of the Total Environment* 888: 164154.
764 <https://doi.org/10.1016/j.scitotenv.2023.164154> Almalky, A. M. M. y Ahmed, K. R. R. 2023. Deep
765 Learning for Detecting and Classifying the Impact of Invasive Species. *Agronomy* 13(3): 934.
766 <https://doi.org/10.3390/agronomy13030934>

767 Anandhavalli, M., Ghose, M. K. y Gauthaman, K. 2010. Association rule mining in genomics.
768 *International Journal of Computer Theory and Engineering* 2(2): 269-273.

769 Araújo, M. B., Anderson, R. P., Barbosa, A. M., Beale, C. M., Dormann, C. F., Early, R., Garcia, R. A.,
770 Guisan, A., Maiorano, L., Naimi, B., O'Hara, R. B., Zimmermann, N. E. y Rahbek, C. 2019.
771 Standards for distribution models in biodiversity assessments. *Science Advances* 5: eaat4858.
772 [10.1126/sciadv.aat4858](https://doi.org/10.1126/sciadv.aat4858)

773 Assessment of ChatGPT's potential as an innovative tool in searching for information on wild mammals.
774 *Ecological Informatics* 83(1): 102810. <https://doi.org/10.1016/j.ecoinf.2024.102810>

775 Aussem, A. y Hill, D. 1999. Wedding connectionist and algorithmic modelling: Applications to ecological
776 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)

777 Bao, G., Weng, B. y Xv, H. 2024. Application of deep neural network identification models based on
778 garden environment perception in plant protection. *Crop Protection* 184: 106833.
779 <https://doi.org/10.1016/j.cropro.2024.106833>

780 Barbosa, F. G., Schneck, F. y Melo, A. S. 2012. Use of ecological niche models to predict the distribution
781 of invasive species: a scientometric analysis. *Brazilian Journal of Biology* 72(4): 821-829.
782 <https://doi.org/10.1590/S1519-69842012000500007>

783 Bednarsek, N., Beck, M. W., Pelletier, G., Applebaum, S. L., Feely, R. A., Butler, R., Byrne, M.,
784 Peabody, B., Davis, J. y Strus, J. 2022. Natural Analogues in pH Variability and Predictability
785 across the Coastal Pacific Estuaries: Extrapolation of the Increased Oyster Dissolution under
786 Increased pH Amplitude and Low Predictability Related to Ocean Acidification. *Environmental
787 Science & Technology* 56(12): 9015-9028. <https://doi.org/10.1021/acs.est.2c00010>

788 Bae, M.-J., Kim, E.-J. y Park, Y.-S. 2021. Comparison of invasive apple snail (*Pomacea canaliculata*)
789 behaviors in different water temperature gradients. *Water* 13(9): 1149.
790 <https://doi.org/10.3390/w13091149>

- 791 Benzer, S. y Benzer, R. 2020. Growth and length-weight relationships of *Pseudorasbora parva*
792 (Temminck & Schlegel, 1846) in Hirfanli Dam Lake: Comparison with traditional and artificial neural
793 networks approaches. *Iranian Journal of Fisheries Sciences* 19(3): 1098-1110.
794 <https://doi.org/10.22092/ijfs.2018.119889>
- 795 Biswas, S. S. 2023. Potential Use of ChatGPT in Global Warming. *Annals of Biomedical Engineering*
796 51: 1126-1127. <https://doi.org/10.1007/s10439-023-03171-8>
- 797 Blonder, B. W., Lim, M. H. y Godoy, O. 2024. Predicting and Prioritising Community Assembly: Learning
798 Outcomes via Experiments. *Ecology Letters* 27(10): e14535. <https://doi.org/10.1111/ele.14535>
- 799 Bolaños, F., Salatino, A., Osborne, F. et al. 2024. Artificial intelligence for literature reviews:
800 opportunities and challenges. *Artificial Intelligence Review* 57: 259. [https://doi.org/10.1007/s10462-](https://doi.org/10.1007/s10462-024-10902-3)
801 [024-10902-3](https://doi.org/10.1007/s10462-024-10902-3)
- 802 Borowiec, M. L., Dikow, R. B., Frandsen, P. B., McKeeken, A., Valentini, G. y White, A. E. 2022. Deep
803 learning as a tool for ecology and evolution. *Methods in Ecology and Evolution* 13: 1640-1660.
804 <https://doi.org/10.1111/2041-210X.13901>
- 805 Bravo-Diaz, A., Moreno, S. y Lopatin, J. 2024. Evaluating the ability of convolutional neural networks
806 for transfer learning in *Pinus radiata* cover predictions. *Ecological Informatics* 82: 102684.
807 <https://doi.org/10.1016/j.ecoinf.2024.102684>
- 808 Bravo-Diaz, A., Moreno, S. y Lopatin, J. 2024. Evaluating the ability of convolutional neural networks
809 for transfer learning in *Pinus radiata* cover predictions. *Ecological Informatics* 82: 102684.
810 <https://doi.org/10.1016/j.ecoinf.2024.102684>
- 811 Briscoe, N. J., Elith, J., Salguero-Gómez, R., Lahoz-Monfort, J. J., Camac, J. S., Giljohann, K. M.,
812 Holden, M. H., Hradsky, B. A., Kearney, M. R., McMahon, S. M., Phillips, B. L., Regan, T. J.,
813 Rhodes, J. R., Vesk, P. A., Wintle, B. A., Yen, J. D. L. y Guillera-Aroita, G. 2019. Forecasting
814 species range dynamics with process-explicit models: matching methods to applications. *Ecology*
815 *Letters* 22: 1940-1956. <https://doi.org/10.1111/ele.13348>
- 816 Buchelt, A., Adrowitzer, A., Kieseberg, P., Gollob, C., Nothdurft, A., Eresheim, S., Tschitschek, S.,
817 Stampfer, K. y Holzinger, A. 2024. Exploring artificial intelligence for applications of drones in forest
818 ecology and management. *Forest Ecology and Management* 551: 121530.
819 <https://doi.org/10.1016/j.foreco.2023.121530>
- 820 Bzdok, D., Krzywinski, M. y Altman, N. 2018. Machine learning: supervised methods. *Nature Methods*
821 15: 5-6. <https://doi.org/10.1038/nmeth.4551>
- 822 Cao, Y., Geddes, T. A., Yang, J. Y. H y Yang P. 2020. Ensemble deep learning in bioinformatics. *Nature*
823 *Machine Intelligence* 2: 500-508. <https://doi.org/10.1038/s42256-020-0217-y>

- 824 Cardoso, A. S., Malta-Pinto, E. y Tabik, S. 2024. Can citizen science and social media images support
825 biodiversity monitoring? *Ecological Informatics* 81: 102602.
826 <https://doi.org/10.1016/j.ecoinf.2024.102602>
- 827 Castillo, C., Chollett, I. y Klein, E. 2008. Enhanced duckweed detection using bootstrapped SVM
828 classification on medium resolution RGB MODIS imagery. *International Journal of Remote Sensing*
829 29(19): 5595-5604. <https://doi.org/10.1080/01431160801961375>
- 830 Cavender-Bares, J., Schneider, F.D., Santos, M.J., Armstrong, A., Carnaval, A., Dahlin, K.M., Fatoyinbo,
831 L., Hurtt, G.C., Schimel, D., Townsend, P.A., Ustin, S.L., Want, Z., y Wilscon, A.M. 2022. Integrating
832 remote sensing with ecology and evolution to advance biodiversity conservation. *Nature Ecology
833 & Evolution* 6, 506–519. <https://doi.org/10.1038/s41559-022-01702-5>
- 834 Chaity, M. D. y van Aardt, J. 2024. Exploring the limits of species identification via a convolutional neural
835 network in a complex forest scene through simulated imaging spectroscopy. *Remote Sensing*
836 16(3): 498. <https://doi.org/10.3390/rs16030498>
- 837 Champ, J., Mora-Fallas, A., Goeau, H., Mata-Montero, E., Bonnet, P. y Joly, A. 2020. Instance
838 segmentation for the fine detection of crop and weed plants by precision agricultural robots.
839 *Applications in Plant Sciences* 8(7): e11373. <https://doi.org/10.1002/aps3.11373>
- 840 Charlton, G., Falzon, G., Shepley, A., Fleming, P. J. S., Ballard, G. y Meek, P. D. 2024. The Sentinel
841 Bait Station: an automated, intelligent design pest animal baiting system. *Wildlife Research* 51(1).
842 <https://doi.org/10.1071/WR22183>
- 843 Chen, G., Kéry, M., Plattner, M., Ma, K. y Gardner, B. 2013. Imperfect detection is the rule rather than
844 the exception in plant distribution studies. *Journal of Ecology* 101: 183-191.
845 <https://doi.org/10.1111/1365-2745.12021>
- 846 Chen, Q., Xie, J., Yu, Q., Liu, C., Ding, W., Li, X. y Zhou, H. 2024. An experimental study of acoustic
847 bird repellents for reducing bird encroachment in pear orchards. *Frontiers in Plant Science* 15:
848 1365275. <https://doi.org/10.3389/fpls.2024.1365275>
- 849 Christin, S., Hervet, É. y Lecomte, N. 2019. Applications for deep learning in ecology. *Methods in
850 Ecology and Evolution* 10: 1632-1644. <https://doi.org/10.1111/2041-210X.13256>
- 851 Clemmensen, L. y Kjærsgaard, R. 2022. Data representativity for machine learning and AI systems.
852 *arXiv*. <https://doi.org/10.48550/arXiv.2203.04706>
- 853 Coughlan, N. E., Lyne, L., Cuthbert, R. N., Cunningham, E. M., Lucy, F., Davis, E., Caffrey, J. M. y Dick,
854 J. T. 2020. In the black: Information harmonisation and educational potential amongst international
855 databases for invasive alien species designated as of Union Concern. *Global Ecology and
856 Conservation* 241. e01332. <https://doi.org/10.1016/j.gecco.2020.e01332>

- 857 Cui, S., Gao, Y., Huang, Y., Shen, L., Zhao, Q., Pan, Y. y Zhuang, S. 2023. Advances and applications
858 of machine learning and deep learning in environmental ecology and health. *Environmental*
859 *Pollution* 335: 122358. <https://doi.org/10.1016/j.envpol.2023.122358>
- 860 Dar, S. A., Sharief, A., Kumar, V., Singh, H., Joshi, B. D., Bhattacharjee, S., Dutta, R., Dolker, S., Singh,
861 A. P., Singh, V. K., Sidhu, A. K., Thakur, M. y Sharma, L. K. 2023. Free-ranging dogs are seriously
862 threatening Himalayan environment: delineating the high-risk areas for curbing free-ranging dog
863 infestation in the Trans-Himalayan region. *Environmental Monitoring and Assessment* 195: 1386.
864 <https://doi.org/10.1007/s10661-023-11972-6>
- 865 Dara, R., Hazrati Fard, S. M. y Kaur, J. 2022. Recommendations for ethical and responsible use of
866 artificial intelligence in digital agriculture. *Frontiers in Artificial Intelligence* 5: 884192.
867 <https://doi.org/10.3389/frai.2022.884192>
- 868 Dash, J. P., Watt, M. S., Paul, T. S. H., Morgenroth, J. y Hartley, R. 2019. Taking a closer look at
869 invasive alien plant research: A review of the current state, opportunities, and future directions for
870 UAVs. *Methods in Ecology and Evolution* 10: 2020-2033. <https://doi.org/10.1111/2041-210X.13296>
- 871 Davis, A. J. S., Groom, Q., Adriaens, T., Vanderhoeven, S., De Troch, R., Oldoni, D., Desmet, P.,
872 Reyserhove, L., Lens, L. y Strubbe, D. 2024. Reproducible WiSDM: a workflow for reproducible
873 invasive alien species risk maps under climate change scenarios using standardized open data.
874 *Frontiers in Ecology and Evolution* 12: 1148895. <https://doi.org/10.3389/fevo.2024.1148895>
- 875 Depauw, L., Blondeel, H., De Lombaerde, E., De Pauw, K., Landuyt, D., Lorier, E., Vangansbeke, P.,
876 Vanneste, T., Verheyen, K. y De Frenne, P. 2022. The use of photos to investigate ecological
877 change. *Journal of Ecology* 110: 1220–1236. <https://doi.org/10.1111/1365-2745.13876>
- 878 Devi, N., Sarma, K. K. y Laskar, S. 2023. Design of an intelligent bean cultivation approach using
879 computer vision, IoT and spatio-temporal deep learning structures. *Ecological Informatics* 75:
880 102044. <https://doi.org/10.1016/j.ecoinf.2023.102044>
- 881 Dietterich, T.G. 2000. Ensemble Methods in Machine Learning. In: *Multiple Classifier Systems*. MCS
882 2000. *Lecture Notes in Computer Science*, vol 1857. Springer, Berlin, Heidelberg.
883 https://doi.org/10.1007/3-540-45014-9_1
- 884 Dunker, S., Boho, D., Waeldchen, J. y Maeder, P. 2018. Combining high-throughput imaging flow
885 cytometry and deep learning for efficient species and life-cycle stage identification of
886 phytoplankton. *BMC Ecology* 18: 51. <https://doi.org/10.1186/s12898-018-0209-5>
- 887 Dyrmann, M., Skovsen, S. K., Christiansen, P. H., Kragh, M. F. y Mortensen, A. K. 2024. High-speed
888 camera system for efficient monitoring of invasive plant species along roadways. *F1000Research*
889 13: 360. <https://doi.org/10.12688/f1000research.141992.2>

- 890 Elith, J., C. Graham, y NCEAS species distribution modeling group. 2006. Novel methods improve
891 prediction of species' distributions from occurrence data. *Ecography* 29: 129-151.
892 <https://doi.org/10.1111/j.2006.0906-7590.04596.x>
- 893 Elith, J., Kearney, M., y Phillips, S. 2011. The art of modelling range-shifting species. *Methods in*
894 *Ecology and Evolution*, 1(4), 330–342. <https://doi.org/10.1111/j.2041-210X.2010.00036.x>
- 895 Epstein, J. M., Pine, W. E. III, Romagosa, C. M., Scott, M. C., Phillips, C. T., Marion, C. A. y Baiser, B.
896 2018. State- and regional-scale patterns and drivers of freshwater fish functional diversity in the
897 southeastern USA. *Transactions of the American Fisheries Society* 147(6): 1179-1198.
898 <https://doi.org/10.1002/tafs.10110>
- 899 Fenner, M. 1998. The phenology of growth and reproduction in plants. *Perspectives in Plant Ecology,*
900 *Evolution and Systematics* 1(1): 78-91. <https://doi.org/10.1078/1433-8319-00053>
- 901 Fleure, V., Magneville, C., Mouillot, D. y Villeger, S. 2024. Automated identification of invasive
902 rabbitfishes in underwater images from the Mediterranean Sea. *Aquatic Conservation: Marine and*
903 *Freshwater Ecosystems* 34(1). <https://doi.org/10.1002/aqc.4073>
- 904 Fonnesebeck, C. J. 2008. Solving dynamic wildlife resource optimization problems using reinforcement
905 learning. *Natural Resource Modeling* 18(1): 1-40. <https://doi.org/10.1111/j.1939-7445.2005.tb00147.x>
- 907 Fourcade, Y. 2021. Fine-tuning niche models matters in invasion ecology: A lesson from the land
908 planarian *Obama nungara*. *Ecological Modelling* 457: 109686.
909 <https://doi.org/10.1016/j.ecolmodel.2021.109686>
- 910 Galaz García, C., Bagstad, K. J., Brun, J., Chaplin-Kramer, R., Dhu, T., Murray, N. J., Nolan, C. J.,
911 Ricketts, T. H., Sosik, H. M., Sousa, D., Willard, G., Halpern, B. S. 2023. The future of ecosystem
912 assessments is automation, collaboration, and artificial intelligence. *Environmental Research*
913 *Letters* 18(1): 011003. <https://doi.org/10.1088/1748-9326/acab19>
- 914 García-Navarrete, O. L., Correa-Guimaraes, A. y Navas-Gracia, L. M. 2024. Application of
915 Convolutional Neural Networks in weed detection and identification: A systematic review.
916 *Agriculture* 14: 568. <https://doi.org/10.3390/agriculture14040568>
- 917 Gil-Tapetado, D., Koken, M., De Cock, R., Gomez, J. F., Cabrero-Sanudo, F. J. y Polidori, C. 2024.
918 Across the firefly-verse: comparison of niche suitability of an exotic firefly in its native and colonized
919 range. *Journal of Insect Conservation* 28(1): 43-56. <https://doi.org/10.1007/s10841-023-00522-7>
- 920 Gonzalez, L. F., Montes, G. A., Puig, E., Johnson, S., Mengersen, K. y Gaston, K. J. 2016. Unmanned
921 Aerial Vehicles (UAVs) and Artificial Intelligence Revolutionizing Wildlife Monitoring and
922 Conservation. *Sensors* 16(1): 97. <https://doi.org/10.3390/s16010097>

- 923 Goode, K., Weber, M. J. y Dixon, P. M. 2023. WhoseEgg: classification software for invasive carp eggs.
924 PeerJ 11: e14787. <https://doi.org/10.7717/peerj.14787>
- 925 Greener, J. G., Kandathil, S. M., Moffat, L. y Jonas, D. T. 2022. A guide to machine learning for
926 biologists. *Nature Reviews Molecular Cell Biology* 23: 40-55. [https://doi.org/10.1038/s41580-021-](https://doi.org/10.1038/s41580-021-00407-0)
927 00407-0
- 928 Gugele, S. M., Widmer, M., Baer, J., DeWeber, J. T., Balk, H. y Brinker, A. 2021. Differentiation of two
929 swim bladdered fish species using next generation wideband hydroacoustics. *Scientific Reports*
930 11(1): 10520. <https://doi.org/10.1038/s41598-021-89941-7>
- 931 Guisan, A., Petitpierre, B., Broennimann, O., Daehler, C. y Kueffer, C. 2014. Unifying niche shift studies:
932 insights from biological invasions. *Trends in Ecology & Evolution* 29: 260-269.
933 <https://doi.org/10.1016/j.tree.2014.02.009>
- 934 Guisan, A., Thuiller, W. y Zimmermann, N. E. 2017. *Habitat Suitability and Distribution Models: With*
935 *Applications in R*. Cambridge University Press. <https://doi.org/10.1017/9781139028271>
- 936 Gupta, K., Rani, R. y Bahia, N. 2020. Plant-Seedling Classification Using Transfer Learning.
937 *International Journal of Agricultural and Environmental Information Systems* 11(4): 25-40.
938 <https://doi.org/10.4018/IJAEIS.2020100102>
- 939 Haase, C. G., Yang, A., McNyset, K. M. y Blackburn, J. K. 2021. GARPTools: R software for data
940 preparation and model evaluation of GARP models. *Ecography* 44: 1790-1796.
941 <https://doi.org/10.1111/ecog.05642>
- 942 Hamilton SA, Murphy DD (2020) Use of affinity analysis to guide habitat restoration and enhancement
943 for the imperiled delta smelt. *Endang Species Res* 43:103-120. <https://doi.org/10.3354/esr01057>
- 944 Han, B. A., Varshney, K. R., LaDeau, S., Subramaniam, A., Weathers, K. C. y Zwart, J. 2023. A
945 synergistic future for AI and ecology. *Proceedings of the National Academy of Sciences of the*
946 *United States of America* 120(38): e2220283120. <https://doi.org/10.1073/pnas.2220283120>
- 947 Hastie, T., Tibshirani, R. y Friedman, J. 2009. *The elements of statistical learning: data mining,*
948 *inference, and prediction*. 2^a ed. Springer Science & Business Media. [https://doi.org/10.1007/978-](https://doi.org/10.1007/978-0-387-84858-7)
949 0-387-84858-7
- 950 Heger, T., Jeschke, J. M. y Kollmann, J. 2021. Some reflections on current invasion science and
951 perspectives for an exciting future. *NeoBiota* 68: 79-100.
952 <https://doi.org/10.3897/neobiota.68.68997>
- 953 Heil, B. J., Hoffman, M. M., Markowetz, F., Lee, S.-I., Greene, C.S., y Hicks, S.C. 2021. Reproducibility
954 standards for machine learning in the life sciences. *Nature Methods* 18: 1132-1135.
955 <https://doi.org/10.1038/s41592-021-01256-7> Ben-Hur, A., Ong, C. S., Sonnenburg, S., Schölkopf,

956 B. y Rätsch, G. 2008. Support vector machines and kernels for computational biology. PLoS
957 Computational Biology 4: e1000173. <https://doi.org/10.1371/journal.pcbi.1000173>

958 Hodgson, J.C., Mott, R., Baylis, S.M., Pham, T.T., Wotherspoon, S., Kilpatrick, A.D., Segaran, R.R.,
959 Reid, I., Terauds, A., y Koh, L.P. 2018. Drones count wildlife more accurately and precisely than
960 humans. *Methods in Ecology and Evolution* 9: 1160–1167. <https://doi.org/10.1111/2041-210X.12974>
961

962 Hollings, T., Burgman, M., van Andel, M., Gilbert, M., Robinson, T. y Robinson, A. 2018. How do you
963 find the green sheep? A critical review of the use of remotely sensed imagery to detect and count
964 animals. *Methods in Ecology and Evolution* 9: 881-892. <https://doi.org/10.1111/2041-210X.12973>

965 Horning, N., Fleishman, E. y Ersts, P. J. 2020. Mapping of land cover with open-source software and
966 cloud computing in the Galápagos. *Remote Sensing in Ecology and Conservation* 6(4): 487-497.
967 <https://doi.org/10.1002/rse2.144>

968 Hui, C. 2023. The dos and don'ts for predicting invasion dynamics with species distribution models.
969 *Biological Invasions* 25: 947-953. <https://doi.org/10.1007/s10530-022-02976-3>

970 Iguchi, K., Matsuura, K., McNyset, K. M., Peterson, A. T., Scachetti-Pereira, R., Powers, K. A., Vieglais,
971 D. A., Wiley, E. O. y Yodo, T. 2004. Predicting invasions of North American basses in Japan using
972 native range data and a genetic algorithm. *Transactions of the American Fisheries Society* 133(4):
973 845-854. <https://doi.org/10.1577/T03-172.1>

974 Jain, A. K. 2010. Data clustering: 50 years beyond K-means. *Pattern Recognition Letters* 31: 651–666.
975 <https://doi.org/10.1016/j.patrec.2009.09.011>

976 James, K. y Bradshaw, K. 2020. Detecting plant species in the field with deep learning and drone
977 technology. *Methods in Ecology and Evolution* 11(11): 1509-1519. <https://doi.org/10.1111/2041-210X.13473>
978

979 Javed, Q., Azeem, A., Sun, J., Ullah, I., Du, D., Imran, M. A., Nawaz, M. I. y Chattha, H. T. 2022. Growth
980 prediction of *Alternanthera philoxeroides* under salt stress by application of artificial neural
981 networking. *Plant Biosystems* 156(1): 61-67. <https://doi.org/10.1080/11263504.2020.1832603>

982 Jeschke, J. M. y Strayer, D. L. 2008. Usefulness of bioclimatic models for studying climate change and
983 invasive species. En: Ostfeld, R. S. y Schlesinger, W. H. (eds.). *Year in Ecology and Conservation*
984 *Biology* 2008. *Annals of the New York Academy of Sciences* 1134: 1-24.
985 <https://doi.org/10.1196/annals.1439.002>

986 Jia, H., Cai, D., Yang, J., Qian, W., Wang, C. 2023. Efficient and privacy-preserving image classification
987 using homomorphic encryption and chunk-based convolutional neural network. *Journal of Cloud*
988 *Computing* 12: 175. <https://doi.org/10.1186/s13677-023-00537-0>

- 989 Jiang, D., Chen, S., Hao, M., Fu, J. y Ding, F. 2018. Mapping the potential global codling moth (*Cydia*
990 *pomonella* L.) distribution based on a machine learning method. *Scientific Reports* 8: 13093.
991 <https://doi.org/10.1038/s41598-018-31478-3>
- 992 Katal, N., Rzanny, M., Mäder, P. y Wäldchen, J. 2022. Deep learning in plant phenological research: A
993 systematic literature review. *Frontiers in Plant Science* 13: 805738.
994 <https://doi.org/10.3389/fpls.2022.805738>
- 995 Kattenborn, T., Eichel, J. y Wisser, S. 2020. Convolutional Neural Networks accurately predict cover
996 fractions of invasive plant species using aerial imagery. *Remote Sensing in Ecology and*
997 *Conservation* 6(4): 472-486. <https://doi.org/10.1002/rse2.146>
- 998 Kattenborn, T., Eichel, J., Wisser, S., Burrows, L., Fassnacht, F. E. y Schmidtlein, S. 2020. Convolutional
999 Neural Networks accurately predict cover fractions of plant species and communities in Unmanned
1000 Aerial Vehicle imagery. *Remote Sensing in Ecology and Conservation* 6(4): 472-486.
1001 <https://doi.org/10.1002/rse2.146>
- 1002 Kattge, J., Bönisch, G., Díaz, S., et al. 2020. TRY plant trait database – enhanced coverage and open
1003 access. *Global Change Biology* 26: 119-188. <https://doi.org/10.1111/gcb.14904>
- 1004 Keerthinathan, P., Amarasingam, N. y Desilva, A. 2024. African Lovegrass Segmentation with Artificial
1005 Intelligence. *Remote Sensing* 16(13): 2363. <https://doi.org/10.3390/rs16132363>
- 1006 Keller, R. P., Kocev, D. y Dzeroski, S. 2011. Trait-based risk assessment for invasive species: high
1007 performance across diverse taxonomic groups, geographic ranges and machine learning/statistical
1008 tools. *Diversity and Distributions* 17(3): 451-461. <https://doi.org/10.1111/j.1472-4642.2011.00748.x>
- 1009 Knight, E., Hannah, K., Foley, G., Scott, C., Brigham, R. y Bayne, E. 2017. Recommendations for
1010 acoustic recognizer performance assessment with application to five common automated signal
1011 recognition programs. *Avian Conservation and Ecology* 12(2). [https://doi.org/10.5751/ACE-01114-](https://doi.org/10.5751/ACE-01114-120214)
1012 [120214](https://doi.org/10.5751/ACE-01114-120214)
- 1013 Kolar, C. 2004. Risk assessment and screening for potentially invasive fishes. *New Zealand Journal of*
1014 *Marine and Freshwater Research* 38(3): 391-397.
1015 <https://doi.org/10.1080/00288330.2004.9517247>
- 1016 Kotowska, D., Pärt, T. y Žmihorski, M. 2021. Evaluating Google Street View for tracking invasive alien
1017 plants along roads. *Ecological Indicators* 121: 107020.
1018 <https://doi.org/10.1016/j.ecolind.2020.107020>
- 1019 Krizhevsky, A., Sutskever, I. y Hinton, G. 2017. ImageNet classification with deep convolutional neural
1020 networks. *Communications of the ACM* 60(6): 84-90. <https://doi.org/10.1145/3065386>
- 1021 Kulkarni, R. y Di Minin, E. 2023. Towards automatic detection of wildlife trade using machine vision

- 1022 models. *Biological Conservation* 279: 109924. <https://doi.org/10.1016/j.biocon.2023.109924>
- 1023 Lapeyrolerie, M., Chapman, M. S., Norman, K. E. A., y Boettiger, C. 2022. Deep reinforcement learning
1024 for conservation decisions. *Methods in Ecology and Evolution* 13: 2649–2662.
1025 <https://doi.org/10.1111/2041-210X.13954>
- 1026 Latombe, G., Pyšek, P., Jeschke, J. M., Blackburn, T. M., Bacher, S., Capinha, C., Costello, M. J.,
1027 Fernández, M., Gregory, R. D., Hobern, D., Hui, C., Jetz, W., Kumschick, S., McGrannachan, C.,
1028 Pergl, J., Roy, H. E., Scalera, R., Squires, Z. E., Wilson, J. R. U., Winter, M. y McGeoch, M. A.
1029 2017. A vision for global monitoring of biological invasions. *Biological Conservation* 213(B): 295-
1030 308. <https://doi.org/10.1016/j.biocon.2016.06.013>
- 1031 Leathwick, J.R., J. Elith, y T. Hastie. 2006. Comparative performance of generalized additive models
1032 and multivariate adaptive regression splines for statistical modelling of species distributions.
1033 *Ecological Modelling* 199: 188-196. <https://doi.org/10.1016/j.ecolmodel.2006.05.022>
- 1034 Lehman, A., J.M. Overton, y J.R. Leathwick. 2002. GRASP: generalized regression analysis and spatial
1035 prediction. *Ecological Modelling* 157: 189-207. [https://doi.org/10.1016/S0304-3800\(02\)00354-X](https://doi.org/10.1016/S0304-3800(02)00354-X)
- 1036 Lenzner, B., Latombe, G., Schertler, A., Seebens, H., Yang, Q., Winter, M., Weigelt, P., van Kleunen,
1037 M., Pyšek, P., Pergl, J., Kreft, H., Dawson, W., Dullinger, S., & Essl, F. (2022). Naturalized alien
1038 floras still carry the legacy of European colonialism. *Nature Ecology & Evolution*, 6(11), 1723–1732.
1039 <https://doi.org/10.1038/s41559-022-01865-1>
- 1040 Levin, S. C., Evers, S., Potter, T., Guerrero, M. P., Childs, D. Z., Compagnoni, A., Knight, T. M. y
1041 Salguero-Gómez, R. 2022. Rpadrino: An R package to access and use PADRINO, an open access
1042 database of Integral Projection Models. *Methods in Ecology and Evolution* 13: 1923-1929.
1043 <https://doi.org/10.1111/2041-210X.13910>
- 1044 Ley, C., Martin, R. K., Pareek, A., et al. 2022. Machine learning and conventional statistics: making
1045 sense of the differences. *Knee Surgery, Sports Traumatology, Arthroscopy* 30: 753-757.
1046 <https://doi.org/10.1007/s00167-022-06896-6>
- 1047 Li, C., Bo, H., Song, B., et al. 2022. Reshaping of the soil microbiome by the expansion of invasive
1048 plants: shifts in structure, diversity, co-occurrence, niche breadth, and assembly processes. *Plant
1049 and Soil* 477: 629-646. <https://doi.org/10.1007/s11104-022-05445-x>
- 1050 Liu, X., Xing, Z., Liu, H., Peng, H., Xu, H., Yuan, J. y Gou, Z. 2022. Combination of UAV and Raspberry
1051 Pi 4B: airspace detection of red imported fire ant nests using an improved YOLOv4 model.
1052 *Mathematical Biosciences and Engineering* 19(12): 13582-13606.
1053 <https://doi.org/10.3934/mbe.2022634>
- 1054 Los, S., Múcher, C. A., Kramer, H., Franke, G. J., & Kamphuis, C. 2023. Estimating body dimensions

- 1055 and weight of cattle on pasture with 3D models from UAV imagery. *Smart Agricultural Technology*,
1056 4: 100167. <https://doi.org/10.1016/j.atech.2022.100167>
- 1057 Loyani, L. 2024. Segmentation-based quantification of *Tuta absoluta*'s damage on tomato plants. *Smart*
1058 *Agricultural Technology* 7: 100415. <https://doi.org/10.1016/j.atech.2024.100415>
- 1059 Ma, D., Wei, J., Zhu, L., Zhao, F., Wu, H., Chen, X., Li, Y. y Liu, M. 2024. Semi-supervised learning
1060 advances species recognition for aquatic biodiversity monitoring. *Frontiers in Marine Science* 11:
1061 1373755. <https://doi.org/10.3389/fmars.2024.1373755>
- 1062 Maher, J., Stringham, O. C., Moncayo, S., Wood, L., Lassaline, C. R., Virtue, J. y Cassey, P. 2023.
1063 Weed wide web: characterising illegal online trade of invasive plants in Australia. *NeoBiota* 87: 45-
1064 72. <https://doi.org/10.3897/neobiota.87.104472>
- 1065 Mammola, S. y Leroy, B. 2018. Applying species distribution models to caves and other subterranean
1066 habitats. *Ecography* 41: 1194-1208. <https://doi.org/10.1111/ecog.03464>
- 1067 Martinez, B., Reaser, J. K., Dehgan, A., et al. 2020. Technology innovation: advancing capacities for
1068 the early detection of and rapid response to invasive species. *Biological Invasions* 22: 75-100.
1069 <https://doi.org/10.1007/s10530-019-02146-y>
- 1070 Martinez-Vega, J., Diaz, A., Miguel Nava, J., Gallardo, M. y Echavarría, P. 2017. Assessing land use-
1071 cover changes and modelling change scenarios in two mountain Spanish national parks.
1072 *Environments* 4(4): 79. <https://doi.org/10.3390/environments4040079>
- 1073 Marzialesi, F., Frate, L., De Simone, W., Frattaroli, A. R., Acosta, A. T. R. y Carranza, M. L. 2021.
1074 Unmanned Aerial Vehicle (UAV)-Based Mapping of *Acacia saligna* Invasion in the Mediterranean
1075 Coast. *Remote Sensing* 13(17): 3361. <https://doi.org/10.3390/rs13173361>
- 1076 Mathur, M. y Mathur, P. 2024. Habitat suitability of *Opuntia ficus-indica* (L.) Mill. (Cactaceae): a
1077 comparative temporal evaluation using diverse bio-climatic earth system models and ensemble
1078 machine learning approach. *Environmental Monitoring and Assessment* 196(3): 232.
1079 <https://doi.org/10.1007/s10661-024-12406-7>
- 1080 Matsuhashi, S., Oishi, Y., Koarai, A. y Sugiura, R. 2024. Enhancing image recognition robustness in
1081 early weed detection through optimal training data curation. *Weed Science*.
1082 <https://doi.org/10.1017/wsc.2024.63>
- 1083 Matsuhashi, S., Oishi, Y., Koarai, A. y Sugiura, R. 2024. Enhancing image recognition robustness in
1084 early weed detection through optimal training data curation. *Weed Science*.
1085 <https://doi.org/10.1017/wsc.2024.63>
- 1086 Meerdink, S., Hiatt, D., Flory, S. L. y Zare, A. 2024. Dealing with imperfect data for invasive species
1087 detection using multispectral imagery. *Ecological Informatics* 79: 102432.

- 1088 <https://doi.org/10.1016/j.ecoinf.2023.102432>
- 1089 Meerdink, S., Hiatt, D., Flory, S. L. y Zare, A. 2024. Dealing with imperfect data for invasive species
1090 detection using multispectral imagery. *Ecological Informatics* 79: 102432.
1091 <https://doi.org/10.1016/j.ecoinf.2023.102432>
- 1092 Mkonyi, L., Rubanga, D., Richard, M., Zekeya, N., Shimada, S., Maiseli, B. y Machuve, D. 2020. Early
1093 identification of *Tuta absoluta* in tomato plants using deep learning. *Scientific African* 10: e00590.
1094 <https://doi.org/10.1016/j.sciaf.2020.e00590>
- 1095 Morey, A. C. y Venette, R. C. 2020. Minimizing risk and maximizing spatial transferability: challenges
1096 in constructing a useful model of potential suitability for an invasive insect. *Annals of the*
1097 *Entomological Society of America* 113(2): 100-113. <https://doi.org/10.1093/aesa/saz049>
- 1098 Mqingwana, P., Shoko, C., Gxokwe, S. y Dube, T. 2024. Monitoring and assessing the effectiveness of
1099 the biological control implemented to address the invasion of water hyacinth (*Eichhornia crassipes*)
1100 in Hartbeespoort Dam, South Africa. *Remote Sensing Applications: Society and Environment* 36:
1101 101295. <https://doi.org/10.1016/j.rsase.2024.101295>
- 1102 Nazir, S. y Kaleem, M. 2021. Advances in image acquisition and processing technologies transforming
1103 animal ecological studies. *Ecological Informatics* 61, 101212.
1104 <https://doi.org/10.1016/j.ecoinf.2021.101212>
- 1105 Nisin, M. K. M. N., Ramanathan, S. K. K., Sreeram, M. P. y Sudheesan, D. 2023. Ensemble modelling
1106 of Pirarucu (*Arapaima gigas*) distribution in biodiversity hotspot to understand its invasion risk.
1107 *Ecology of Freshwater Fish* 32(3): 528-537. <https://doi.org/10.1111/eff.12704>
- 1108 Novoa, A., Jarić, I., Pipek, P. y Pyšek, P. 2024. Culturomics and iEcology provide novel opportunities
1109 to study human and social dimensions of alien species introductions. *Trends in Ecology &*
1110 *Evolution*. [In Press]. <https://doi.org/10.1016/j.tree.2024.08.012>
- 1111 Nunez-Mir, G. C., Iannone, B. V. III, Curtis, K. y Fei, S. 2015. Evaluating the evolution of forest
1112 restoration research in a changing world: a big literature review. *New Forests* 46(5-6): 669-682.
1113 <https://doi.org/10.1007/s11056-015-9503-7>
- 1114 Olden, J. D., Lawler, J. J. y Poff, N. L. 2008. Machine learning methods without tears: A primer for
1115 ecologists. *The Quarterly Review of Biology* 83(2): 171-193. <https://doi.org/10.1086/587826>
- 1116 Olivoto, T. 2022. Lights, camera, pliman! An R package for plant image analysis. *Methods in Ecology*
1117 *and Evolution* 13: 789-798. <https://doi.org/10.1111/2041-210X.13803>
- 1118 Orenstein, E. C., Ayata, S.-D., Maps, F., Becker, É. C., Benedetti, F., Biard, T., de Garidel-Thoron, T.,
1119 Ellen, J. S., Ferrario, F., Giering, S. L. C., Guy-Haim, T., Hoebeke, L., Iversen, M. H., Kiørboe, T.,
1120 Lalonde, J.-F., Lana, A., Laviale, M., Lombard, F., Lorimer, T., Martini, S., Meyer, A., Möller, K. O.,

- 1121 Niehoff, B., Ohman, M. D., Pradalier, C., Romagnan, J.-B., Schröder, S.-M., Sonnet, V., Sosik, H.
1122 M., Stemmann, L. S., Stock, M., Terbiyik-Kurt, T., Valcárcel-Pérez, N., Vilgrain, L., Wacquet, G.,
1123 Waite, A. M. y Irisson, J.-O. 2022. Machine learning techniques to characterize functional traits of
1124 plankton from image data. *Limnology and Oceanography* 67: 1647-1669.
1125 <https://doi.org/10.1002/lno.12101>
- 1126 Orouji, S., Liu, M. C., Korem, T. y Peters, M. A. K. 2024. Domain adaptation in small-scale and
1127 heterogeneous biological datasets. *arXiv* 2405.19221. <https://doi.org/10.48550/arXiv.2405.19221>
- 1128 O'Shea-Wheller, T. A., Corbett, A., Osborne, J. L., Recker, M. y Kennedy, P. J. 2024. VespAI: a deep
1129 learning-based system for the detection of invasive hornets. *Communications Biology* 7(1).
- 1130 Palazzetti, L., Rangarajan, A. K., Dinca, A., Boom, B., Popescu, D., Offermans, P. y Pinotti, C. M. 2024.
1131 The hawk eye scan: Halyomorpha halys detection relying on aerial tele photos and neural
1132 networks. *Computers and Electronics in Agriculture* 226: 109365.
1133 <https://doi.org/10.1016/j.compag.2024.109365>
- 1134 Pan, S. J. y Yang, Q. 2010. A survey on transfer learning. *IEEE Transactions on Knowledge and Data*
1135 *Engineering* 22: 1345-1359. <https://doi.org/10.1109/TKDE.2009.191>
- 1136 Pasha, S. V. y Reddy, C. S. 2024. Global spatial distribution of *Prosopis juliflora* - one of the world's
1137 worst 100 invasive alien species under changing climate using multiple machine learning models.
1138 *Environmental Monitoring and Assessment* 196(2): 196. [https://doi.org/10.1007/s10661-024-](https://doi.org/10.1007/s10661-024-12347-1)
1139 [12347-1](https://doi.org/10.1007/s10661-024-12347-1)
- 1140 Patel, M., Jernigan, S., Richardson, R., Ferguson, S., y Buckner, G. 2019. Autonomous Robotics for
1141 Identification and Management of Invasive Aquatic Plant Species. *Applied Sciences* 9(12):2410.
1142 <https://doi.org/10.3390/app9122410>
- 1143 Pearson, R.G. 2003. Species' Distribution Modeling for Conservation Educators and Practitioners.
1144 *Lessons in Conservation* 3, 54-89: Network of Conservation Educators and Practitioners, Center
1145 for Biodiversity and Conservation, American Museum of Natural History
- 1146 Pearson, R.G., T.P. Dawson, P.M. Berry, y P.A. Harrison. 2002. Species: A spatial evaluation of climate
1147 impact on the envelope of species. *Ecological Modelling* 154: 289-300.
1148 [https://doi.org/10.1016/S0304-3800\(02\)00056-X](https://doi.org/10.1016/S0304-3800(02)00056-X)
- 1149 Philibert, A., Desprez-Loustau, M. L., Fabre, B., Frey, P., Halkett, F., Husson, C., Lung-Escarmant, B.,
1150 Marcais, B., Robin, C., Vacher, C. y Makowski, D. 2011. Predicting invasion success of forest
1151 pathogenic fungi from species traits. *Journal of Applied Ecology* 48(6): 1381-1390.
1152 <https://doi.org/10.1111/j.1365-2664.2011.02039.x>
- 1153 Phillips, S.J., R.P. Anderson, y R.E. Schapire. 2006. Maximum entropy modeling of species geographic

- 1154 distributions. *Ecological Modelling* 190: 231-259. <https://doi.org/10.1016/j.ecolmodel.2005.03.026>
- 1155 Pichler, M. y Hartig, F. 2023. Machine learning and deep learning—a review for ecologists. *Methods in*
1156 *Ecology and Evolution* 14(4): 994-1016. <https://doi.org/10.1111/2041-210X.14061>
- 1157 Polverino, G., Soman, V.R., Karakaya, M., Gasparini, C., Evans, J. P., y Porfiri M. 2022. Ecology of fear
1158 in highly invasive fish revealed by robots. *iScience* 25: 103529.
1159 <https://doi.org/10.1126/scirobotics.ado5566>
- 1160 Pontin, D. R., Schliebs, S., Worner, S. P. y Watts, M. J. 2011. Determining factors that influence the
1161 dispersal of a pelagic species: A comparison between artificial neural networks and evolutionary
1162 algorithms. *Ecological Modelling* 222(10): 1657-1665.
1163 <https://doi.org/10.1016/j.ecolmodel.2011.03.002>
- 1164 Potapov, A. 2009. Stochastic model of lake system invasion and its optimal control: neurodynamic
1165 programming as a solution method. *Natural Resource Modeling* 22(2): 257-288.
1166 <https://doi.org/10.1111/j.1939-7445.2008.00036.x>
- 1167 Prado Osco, L., Wu, Q., Lopes de Lemos, E., Nunes Gonçalves, W., Marques Ramos, A. P., Li, J. y
1168 Marcato Junior, J. 2023. The Segment Anything Model (SAM) for remote sensing applications:
1169 From zero to one shot. *International Journal of Applied Earth Observation and Geoinformation* 124:
1170 103540. <https://doi.org/10.1016/j.jag.2023.103540>
- 1171 Prober, S. M., Hilbert, D. W., Ferrier, S., Dunlop, M. y Gobbett, D. 2012. Combining community-level
1172 spatial modelling and expert knowledge to inform climate adaptation in temperate grassy eucalypt
1173 woodlands and related grasslands. *Biodiversity and Conservation* 21(7): 1627-1650.
1174 <https://doi.org/10.1007/s10531-012-0268-4>
- 1175 Pyron, R. A. 2023. Unsupervised machine learning for species delimitation, integrative taxonomy, and
1176 biodiversity conservation. *Molecular Phylogenetics and Evolution* 189: 107939.
1177 <https://doi.org/10.1016/j.ympev.2023.107939>
- 1178 Raab, C., Stroh, H. G., Tonn, B., Meissner, M., Rohwer, N., Balkenhol, N. e Isselstein, J. 2018. Mapping
1179 semi-natural grassland communities using multi-temporal RapidEye remote sensing data.
1180 *International Journal of Remote Sensing* 39(17): 5638-5659.
1181 <https://doi.org/10.1080/01431161.2018.1504344>
- 1182 Rainio, O., Teuho, J. y Klén, R. 2024. Evaluation metrics and statistical tests for machine learning.
1183 *Scientific Reports* 14: 6086. <https://doi.org/10.1038/s41598-024-56706-x>
- 1184 Roberts, J. y Florentine, S. 2024. Advancements and developments in the detection and control of
1185 invasive weeds: A global review of the current challenges and future opportunities. *Weed Science*
1186 72(3): 205-215. <https://doi.org/10.1017/wsc.2024.13>

- 1187 Roy, H. E., Pauchard, A., Stoett, P. J., Renard Truong, T., Meyerson, L. A., Bacher, S., Galil, B. S.,
1188 Hulme, P. E., Ikeda, T., Kavileveetil, S., et al. 2024. Curbing the major and growing threats from
1189 invasive alien species is urgent and achievable. *Nature Ecology & Evolution* 8: 1216-1223.
1190 <https://doi.org/10.1038/s41559-024-02412-w>
- 1191 Saffer, A., Worm, T., Takeuchi, Y. y Meentemeyer, R. 2024. GIATAR: a spatio-temporal dataset of
1192 global invasive and alien species and their traits. *Scientific Data* 11: 991.
1193 <https://doi.org/10.1038/s41597-024-03824-w>
- 1194 Salcedo, E., Uchani, Y., Mamani, M. y Fernandez, M. 2024. Towards continuous floating invasive plant
1195 removal using unmanned surface vehicles and computer vision. *IEEE Access* 12: 6649-6662.
1196 <https://doi.org/10.1109/ACCESS.2024.3351764>
- 1197 Salguero-Gómez, R. y Gamelon, M. (eds). 2021. *Demographic Methods across the Tree of Life*. Oxford
1198 University Press. <https://doi.org/10.1093/oso/9780198838609.001.0001>
- 1199 Salguero-Gómez, R., Jones, O. R., Archer, C. R., Bein, C., de Buhr, H., Farack, C., Gottschalk, F.,
1200 Hartmann, A., Henning, A., Hoppe, G., Römer, G., Ruoff, T., Sommer, V., Wille, J., Voigt, J., Zeh,
1201 S., Vieregg, D., Buckley, Y. M., Che-Castaldo, J., Hodgson, D., Scheuerlein, A., Caswell, H. y
1202 Vaupel, J. W. 2016. COMADRE: a global data base of animal demography. *Journal of Animal*
1203 *Ecology* 85: 371-384. <https://doi.org/10.1111/1365-2656.12482>
- 1204 Salguero-Gómez, R., Jones, O. R., Archer, C. R., Buckley, Y. M., Che-Castaldo, J., Caswell, H.,
1205 Hodgson, D., Scheuerlein, A., Conde, D. A., Brinks, E., de Buhr, H., Farack, C., Gottschalk, F.,
1206 Hartmann, A., Henning, A., Hoppe, G., Römer, G., Runge, J., Ruoff, T., Wille, J., Zeh, S., Davison,
1207 R., Vieregg, D., Baudisch, A., Altwegg, R., Colchero, F., Dong, M., de Kroon, H., Lebreton, J.-D.,
1208 Metcalf, C. J. E., Neel, M. M., Parker, I. M., Takada, T., Valverde, T., Vélez-Espino, L. A., Wardle,
1209 G. M., Franco, M. y Vaupel, J. W. 2015. The compadre Plant Matrix Database: an open online
1210 repository for plant demography. *Journal of Ecology* 103: 202-218. [https://doi.org/10.1111/1365-](https://doi.org/10.1111/1365-2745.12334)
1211 [2745.12334](https://doi.org/10.1111/1365-2745.12334)
- 1212 Sampaio Franco, A. C., Garcia-Berthou, E. y Neves dos Santos, L. 2021. Ecological impacts of an
1213 invasive top predator fish across South America. *Science of the Total Environment* 761: 143296.
1214 <https://doi.org/10.1016/j.scitotenv.2020.143296>
- 1215 Santoianni, L. A., Innangi, M., Varricchione, M., Carboni, M., La Bella, G., Haider, S. y Stanisci, A. 2024.
1216 Ecological features facilitating spread of alien plants along Mediterranean mountain roads.
1217 *Biological Invasions* 26(11): 3879-3899. <https://doi.org/10.1007/s10530-024-03418-y>
- 1218 Schmickl, T., y Romano, D. 2024. Robots and animals teaming up in the wild to tackle ecosystem
1219 challenges. *Science Robotics* 9: eado5566. <https://doi.org/10.1126/scirobotics.ado5566>
- 1220 Sillero, N., Arenas-Castro, S., Enriquez-Urzelai, U., Vale, C. G., Sousa-Guedes, D., Martínez-Freiría,

- 1221 F., Real, R. y Mácia, B. A. 2021. Want to model a species niche? A step-by-step guideline on
1222 correlative ecological niche modelling. *Ecological Modelling* 456: 109671.
1223 <https://doi.org/10.1016/j.ecolmodel.2021.109671>
- 1224 Silvestro, D., Gorla, S., Sterner, T. y Antonelli, A. 2022. Improving biodiversity protection through
1225 artificial intelligence. *Nature Sustainability* 5(5): 415-424. [https://doi.org/10.1038/s41893-022-](https://doi.org/10.1038/s41893-022-00851-6)
1226 [00851-6](https://doi.org/10.1038/s41893-022-00851-6)
- 1227 Simon, S.M., Glaum, P. y Valdovinos, F.S. 2023. Interpreting random forest analysis of ecological
1228 models to move from prediction to explanation. *Scientific Reports* 13: 3881.
1229 <https://doi.org/10.1038/s41598-023-30313-8>
- 1230 Singh, K. K., Surasinghe, T. D. y Frazier, A. E. 2024. Systematic review and best practices for drone
1231 remote sensing of invasive plants. *Methods in Ecology and Evolution* 15: 998-1015.
1232 <https://doi.org/10.1111/2041-210X.14330>
- 1233 Soley-Guardia, M., Alvarado-Serrano, D. F. y Anderson, R. P. 2024. Top ten hazards to avoid when
1234 modeling species distributions: a didactic guide of assumptions, problems, and recommendations.
1235 *Ecography* 2024: e06852. <https://doi.org/10.1111/ecog.06852>
- 1236 Stockwell, D. y Peters, D. 1999. The GARP modelling system: problems and solutions to automated
1237 spatial prediction. *International Journal of Geographical Information Science* 13: 143-158.
1238 <https://doi.org/10.1080/136588199241391>
- 1239 Stockwell, D.R.B. y D.P. Peters. 1999. The GARP modelling system: Problems and solutions to
1240 automated spatial prediction. *International Journal of Geographical Information Systems* 13: 143-
1241 158. <https://doi.org/10.1080/136588199241391>
- 1242 Stone, T. C. y Davis, K. J. 2024. Using unmanned aerial vehicles to estimate body volume at scale for
1243 ecological monitoring. *Methods in Ecology and Evolution* 00: 1-15. [https://doi.org/10.1111/2041-](https://doi.org/10.1111/2041-210X.14457)
1244 [210X.14457](https://doi.org/10.1111/2041-210X.14457)
- 1245 Sudholz, A., Denman, S., Pople, A., Brennan, M., Amos, M. y Hamilton, G. 2022. A comparison of
1246 manual and automated detection of rusa deer (*Rusa timorensis*) from RPAS-derived thermal
1247 imagery. *Wildlife Research* 49(1): 46-53. <https://doi.org/10.1071/WR20169>
- 1248 Tang, F., Zhang, D. y Zhao, X. 2021. Efficiently deep learning for monitoring *Ipomoea cairica* (L.) sweets
1249 in the wild. *Mathematical Biosciences and Engineering* 18(2): 1121-1135.
1250 <https://doi.org/10.3934/mbe.2021060>
- 1251 Toussaint, A., Beauchard, O., Oberdorff, T., Brosse, S. y Villeger, S. 2014. Historical assemblage
1252 distinctiveness and the introduction of widespread non-native species explain worldwide changes
1253 in freshwater fish taxonomic dissimilarity. *Global Ecology and Biogeography* 23(5): 574-584.

- 1254 <https://doi.org/10.1111/geb.12141>
- 1255 Trisos, C. H., Auerbach, J. y Katti, M. 2021. Decoloniality and anti-oppressive practices for a more
1256 ethical ecology. *Nature Ecology & Evolution* 5: 1205-1212. [https://doi.org/10.1038/s41559-021-](https://doi.org/10.1038/s41559-021-01460-w)
1257 [01460-w](https://doi.org/10.1038/s41559-021-01460-w)
- 1258 Tsamardinos, I., Greasidou, E. y Borboudakis, G. 2018. Bootstrapping the out-of-sample predictions for
1259 efficient and accurate cross-validation. *Machine Learning* 107: 1895-1922.
1260 <https://doi.org/10.1007/s10994-018-5714-4>
- 1261 Ulhaq, A., Adams, P., Cox, T. E., Khan, A., Low, T. y Paul, M. 2021. Automated detection of animals in
1262 low-resolution airborne thermal imagery. *Remote Sensing* 13(16): 3276.
1263 <https://doi.org/10.3390/rs13163276>
- 1264 Urza, A. K., Board, D. I., Bradford, J. B., Brown, J. L., Chambers, J. C., Schlaepfer, D. R. y Short, K. C.
1265 2024. Disentangling drivers of annual grass invasion: Abiotic susceptibility vs. fire-induced
1266 conversion to cheatgrass dominance in the sagebrush biome. *Biological Conservation* 297:
1267 110737. <https://doi.org/10.1016/j.biocon.2024.110737>
- 1268 Van Belleghem, S. M., Papa, R., Ortiz-Zuazaga, H., et al. 2018. patternize: An R package for quantifying
1269 colour pattern variation. *Methods in Ecology and Evolution* 9: 390-398.
1270 <https://doi.org/10.1111/2041-210X.12853>
- 1271 Veiga Branco, V., Correia, L. y Cardoso, P. 2023. The use of machine learning in species threats and
1272 conservation analysis. *Biological Conservation* 283: 110091.
1273 <https://doi.org/10.1016/j.biocon.2023.110091>
- 1274 Wacquet, G. y Lefebvre, A. 2022. EcoTransLearn: an R-package to easily use transfer learning for
1275 ecological studies—a plankton case study. *Bioinformatics* 38(24): 5469-5471.
1276 <https://doi.org/10.1093/bioinformatics/btac703>
- 1277 Walsh, I., Fishman, D., Garcia-Gasulla, D., Titma, T., Pollastri, G., ELIXIR Machine Learning Focus
1278 Group, Harrow, J., Psomopoulos, F.E., y Tosatto, S.C.E. 2021. DOME: recommendations for
1279 supervised machine learning validation in biology. *Nature Methods* 18: 1122-1127.
1280 <https://doi.org/10.1038/s41592-021-01205-4>
- 1281 Wang, K., Franklin, S.E., Guo, X., Cattet, M., 2010. Remote sensing of ecology, biodiversity and
1282 conservation: a review from the perspective of remote sensing specialists. *Sensors* 10, 9647–9667.
1283 <https://doi.org/10.3390/s101109647>.
- 1284 Wang, L., Silvan-Cardenas, J. L., Yang, J. y Frazier, A. E. 2013. Invasive saltcedar (*Tamarisk* spp.)
1285 distribution mapping using multiresolution remote sensing imagery. *Professional Geographer*
1286 65(1): 1-15. <https://doi.org/10.1080/00330124.2012.679440>

- 1287 Weller, H. I., Hiller, A. E., Lord, N. P. y Van Belleghem, S. M. 2024. recolorize: An R package for flexible
1288 colour segmentation of biological images. *Ecology Letters* 27: e14378.
1289 <https://doi.org/10.1111/ele.14378>
- 1290 White, D. T., Antoniou, T. M., Martin, J. M., Kmetz, W. y Twiss, M. R. 2022. A machine-learning
1291 approach to predict success of a biocontrol for invasive Eurasian watermilfoil reduction. *Ecological*
1292 *Applications* 32(6): e2625. <https://doi.org/10.1002/eap.2625>
- 1293 Wiegleb, J., Hirsch, P. E., Seidel, F., Rauter, G. y Burkhardt-Holm, P. 2022. Flow, force, behaviour:
1294 assessment of a prototype hydraulic barrier for invasive fish. *Hydrobiologia* 849(4): 1001-1019.
1295 <https://doi.org/10.1007/s10750-021-04762-z>
- 1296 Wilson, N. 2024. Artificial intelligence helps drive new frontiers in ecology. *BioScience* 74(5): 306-311.
1297 <https://doi.org/10.1093/biosci/biae016>
- 1298 Wood, C. M., Guenther, F., Rex, A., Hofstadter, D. F., Reers, H., Kahl, S., Peery, M. Z. y Klinck, H.
1299 2024. Real-time acoustic monitoring facilitates the proactive management of biological invasions.
1300 *Biological Invasions*. <https://doi.org/10.1007/s10530-024-03426-y>
- 1301 Xiao, Y., Greiner, R. y Lewis, M. A. 2018. Evaluation of machine learning methods for predicting
1302 eradication of aquatic invasive species. *Biological Invasions* 20(9): 2485-2503.
1303 <https://doi.org/10.1007/s10530-018-1715-2>
- 1304 Xiong, B., Han, S., Messerschmidt, T. C., Kirwan, M. L., Gedan, K. y Qi, M. 2024. Early detection of
1305 invasive *Phragmites australis* at the tidal marsh-forest ecotone with airborne LiDAR. *Ecological*
1306 *Indicators* 167: 112651. <https://doi.org/10.1016/j.ecolind.2024.112651>
- 1307 Yang, L., Yan, J., Li, H., Cao, X., Ge, B., Qi, Z. y Yan, X. 2022. Real-time classification of invasive plant
1308 seeds based on improved YOLOv5 with attention mechanism. *Diversity* 14: 254.
1309 <https://doi.org/10.3390/d14040254>
- 1310 Yang, W., Wan, X. y Deng, M. 2024. Spatial ensemble learning for predicting the potential geographical
1311 distribution of invasive species. *International Journal of Geographical Information Science* 38(11):
1312 2216-2234. <https://doi.org/10.1080/13658816.2024.2376325>
- 1313 Zhang, M., Shi, C., Li, X., Wang, K., Qiu, Z. y Shi, F. 2023. Changes in the structure and function of
1314 rhizosphere soil microbial communities induced by *Amaranthus palmeri* invasion. *Frontiers in*
1315 *Microbiology* 14: 1114388. <https://doi.org/10.3389/fmicb.2023.1114388>
- 1316 Zhang, X., Shi, Y., Li, S., Yang, Y., Xu, B., Wang, X., Su, H. y Li, F. 2024. Climate change enables
1317 invasion of the portunid crab *Charybdis bimaculata* into the southern Bohai Sea. *Frontiers in Marine*
1318 *Science* 11: 1-10. <https://doi.org/10.3389/fmars.2024.16006039588>
- 1319 Zhao, J. Q., Gao, T., Du, J. J. y Shi, J. 2023a. Future trends in *Obolodiplosis robiniae* distribution across

- 1320 the Eurasian continent under global climate change. *Insects* 14(1): 48.
1321 <https://doi.org/10.3390/insects14010048>
- 1322 Zhao, Z., Fan, C. y Liu, L. 2023b. Geo SAM: A QGIS plugin using Segment Anything Model (SAM) to
1323 accelerate geospatial image segmentation (1.1.0). Zenodo.
1324 <https://doi.org/10.5281/zenodo.8191039>
- 1325 Zhu, W., Ding, Z., Pan, Y., & Wang, Q. (2022). Using an affinity analysis to identify phytoplankton
1326 associations. *Ecology and Evolution*, 12, e9047. <https://doi.org/10.1002/ece3.9047>
- 1327 Zhuang, J., Jin, X., Chen, Y., Meng, W., Wang, Y., Yu, J. y Muthukumar, B. 2023. Drought stress impact
1328 on the performance of deep convolutional neural networks for weed detection in bahiagrass. *Grass*
1329 *and Forage Science* 78(1): 214-223. <https://doi.org/10.1111/gfs.12583>
- 1330 Zurell, D., Franklin, J., König, C., Bouchet, P. J., Dormann, C. F., Elith, J., Fandos, G., Feng, X., Guillerá-
1331 Arroita, G., Guisan, A., et al. 2020. A standard protocol for reporting species distribution models.
1332 *Ecography* 43: 1261-1277. <https://doi.org/10.1111/ecog.04960>