



Cartografía de áreas cubiertas por *Acacia dealbata* en imágenes multispectrales invernales y estivales captadas por dron en la comarca de Verín (Ourense, Galicia, España)

Antonio Vázquez de la Cueva^{1,*} , Isabel Aulló Maestro¹ , Fernando Montes Pita¹

(1) Centro de Investigación Forestal (CIFOR-INIA), CSIC. Ctra. de A Coruña km 7,5 28040 Madrid, España.

* Autor de correspondencia: A. Vázquez [vazquez@inia.csic.es]

> Recibido el 17 de diciembre de 2021 - Aceptado el 16 de junio de 2022

Como citar: Vázquez de la Cueva, A., Aulló Maestro, I., Montes Pita, F. 2022. Cartografía de áreas cubiertas por *Acacia dealbata* en imágenes multispectrales invernales y estivales captadas por dron en la comarca de Verín (Ourense, Galicia, España). *Ecosistemas* 31(3): 2331. <https://doi.org/10.7818/ECOS.2331>

Cartografía de áreas cubiertas por *Acacia dealbata* en imágenes multispectrales invernales y estivales captadas por dron en la comarca de Verín (Ourense, Galicia, España)

Resumen: *Acacia dealbata* es una planta invasora que se expande favorecida por perturbaciones. El objetivo de este trabajo ha sido cartografiar las áreas ocupadas por *A. dealbata* mediante el análisis de imágenes multispectrales y RGB y comparar el comportamiento de las imágenes obtenidas durante la floración invernal y las obtenidas en verano. Las imágenes fueron adquiridas mediante un dron DJI Matrice 210 en tres lugares localizados en la comarca de Verín.

La identificación de los píxeles ocupados por la *Acacia* se llevó a cabo mediante la aplicación basada en ajustes de máxima entropía MaxEnt. La verdad terreno (puntos de presencia conocida) se basó en la fotointerpretación de ortomosaicos RGB invernales mientras que las variables predictoras fueron las reflectancias en las bandas del espectro visible e infrarrojo y un índice de vegetación.

El Área Bajo la Curva (AUC) en los análisis ROC (Receiver Operating Characteristic) de los modelos MaxEnt para las tres zonas de estudio presentó valores entre 0.80 y 0.86 para las imágenes invernales y entre 0.83 y 0.90 para las estivales, indicando una alta especificidad y sensibilidad.

Estos valores, y también los derivados de las matrices de confusión, ponen de manifiesto la aplicabilidad del procedimiento para el seguimiento de la distribución de flora invasora como la *Acacia*. Los resultados muestran el mejor comportamiento de las imágenes estivales frente a las invernales en la cartografía detallada de áreas ocupadas por *A. dealbata*.

Palabras clave: especies invasoras; MicaSense RedEdge; MaxEnt; Mimosa; modelos de distribución de especies

Mapping of *Acacia dealbata* cover using winter and summer multispectral images captured by drone in Verín County (Ourense, Galicia, Spain)

Abstract: *Acacia dealbata* Link is an invasive plant that spreads favoured by disturbances. The objective of this work is to mapping the coverage of *A. dealbata* using multispectral and RGB images and to evaluate the behaviour of winter, during flowering, and summer images. These images were captured using a DJI Matrice 210 drone in three sites in Verín County.

We used a Maximum Entropy (MaxEnt) programme to estimate the probability of *A. dealbata* presence at a pixel level. Ground truth (points of known presence) were based on a visual interpretation of RGB winter orthoimages, while the set of predictor variables were the five reflectance bands and a vegetation index.

The specificity and sensitivity of the MaxEnt models for the three study sites were acceptable in terms of ROC (Receiver Operating Characteristic) analyses AUC (Area under the Curve). The AUC values ranged from 0.80 to 0.86 for the winter images and from 0.83 to 0.90 for the summer ones.

These AUC values, and also the confusion matrices' parameters obtained, have proven that our approach is a valid procedure to identify patterns of species distributions at local scale. There is also a better performance of models using summer than winter images.

Keywords: invasive species; MicaSense Red-Edge; species distribution models; Silver Wattle

Introducción

A. dealbata como especie invasora

A. dealbata es una especie arbórea naturalizada de comportamiento invasor que ha registrado en los últimos años un expansión muy relevante en numerosas áreas del noroeste peninsular

(Lorenzo et al. 2010, Vázquez de la Cueva 2014; Hernández et al. 2014) y es considerada como una de las invasoras más agresivas en Europa (Nentwig et al. 2018). *A. dealbata* supone una seria amenaza para gran número de comunidades y ecosistemas, dependiendo su impacto del tipo de comunidad (Lorenzo et al. 2012; Hernández et al. 2014; Souza-Alonso et al. 2017). La expansión de

las poblaciones de *A. dealbata* en respuesta a perturbaciones con periodos de rotación cortos (Lorenzo et al. 2010; Vázquez de la Cueva et al. 2015) como incendios, cortas, movimientos del terreno o trabajos forestales, se ve favorecida además por diversas características, como la facultad para regenerar a través de la germinación y también mediante rebrote de tallos y raíces (Ought 2001), que hacen de esta especie un invasor muy exitoso (Souza-Alonso et al. 2017).

Los drones o RPAS en la terminología actual (*Remotely Piloted Aircraft System*) y las técnicas de teledetección están revolucionando diversos ámbitos del seguimiento ambiental y la monitorización de especies (Aasen et al. 2018). Los RPAS son ya herramientas eficientes en la cartografía de la distribución y el estudio de la dinámica y conservación de especies, mejorando la eficiencia en la adquisición de información y haciendo posible la obtención de cartografía de alta resolución y modelos en 3D (Goody et al. 2017). Algoritmos fotogramétricos como el “*Structure from Motion*” (SfM) son cada vez más accesibles y eficientes (Díaz-Delgado y Múcher 2019; Gómez et al. 2020) proporcionando además parámetros precisos que pueden ser usados en el seguimiento de la vegetación a una escala local (Puliti et al. 2015, 2018).

Los productos derivados de RPAS se han empleado frecuentemente como alternativa a los muestreos de campo en la cartografía de especies que posteriormente puede expandirse espacialmente mediante el empleo de información derivada de imágenes de satélite (Álvarez-Martínez et al. 2017; Kattenborn et al. 2019; Martínez-Sánchez et al. 2019). Diversos autores han puesto de manifiesto los menores costes de los RPAS frente a muestreos de campo extensivos, constituyendo una herramienta fundamental en la detección de etapas tempranas y en el seguimiento de la dinámica de poblaciones y comunidades alteradas (Lehmann et al. 2017; de Sá et al. 2018; Lopatin et al. 2019).

Cartografía mediante Modelos de Distribución de Especies

Los Modelos de Distribución de Especies (SDM en inglés) pueden ser empleados para estimar las áreas proclives a ser invadidas (ej. Vicente et al. 2016) y también para estimar la probabilidad de presencia de la especie objeto de interés en un territorio. Esta última es la aproximación empleada en este trabajo. El SDM que empleamos es un clasificador de una sola clase basado en algoritmos de Máxima Entropía (MaxEnt) (Phillips et al. 2006, 2017) que permite modelar y cartografiar la distribución espacial de *A. dealbata* a partir de las imágenes multispectrales. MaxEnt estima la probabilidad de presencia de la especie objeto de interés basándose en la combinación de puntos de presencia conocida de la especie de interés y de un conjunto de variables predictoras independientes (Phillips et al. 2017). La salida final cuantitativa es la probabilidad relativa (entre 0 y 1) de presencia de la especie de interés en el resto del territorio. En cualquier caso hay que tener presente la necesidad de establecer claramente los objetivos y las metodologías empleadas para mitigar problemas asociados a diferentes formas de incertidumbre derivada de las decisiones tomadas en la modelización (ej. Suárez-Seoane et al. 2018).

Objetivos

Nuestra hipótesis es que la presencia/ausencia de *A. dealbata* puede ser modelada a partir de puntos de presencia conocidos mediante MaxEnt y que las imágenes invernales (mediados de marzo, en época de floración) presentarían una mejor discriminación entre *A. dealbata* y las otras cubiertas vegetales presentes que las imágenes adquiridas en verano (inicio de julio).

Los objetivos específicos han sido:

1. Evaluar la precisión de los modelos SDM basados en MaxEnt en la cartografía de *A. dealbata* en tres localizaciones de la comarca de Verín.
2. Analizar el comportamiento de las imágenes invernales (con las plantas en flor) frente a las estivales.

Material y Métodos

Descripción de la zona de estudio

Se seleccionaron tres lugares con presencia de poblaciones de *A. dealbata*, cubiertos en su mayor parte por vegetación forestal y que se han visto muy afectados por el fuego en los últimos años. En la selección de los lugares se tuvieron en cuenta las limitaciones legales al vuelo de RPAS y también la accesibilidad para la instalación de puntos GPS y el transporte del dron. Los tres lugares se encuentran en la comarca de Verín, en el sureste de la provincia de Ourense en la que se localiza una de las agrupaciones de poblaciones de *A. dealbata* más al sureste de Galicia, como se aprecia en las teselas del mapa forestal de la Figura 1. Las tres zonas presentan una vegetación muy variada y condicionada por los repetidos incendios. Además de las acacias, hay manchas dominadas por coníferas (fundamentalmente *Pinus pinaster* Ait.), otras por caducifolios (fundamentalmente *Quercus pyrenaica* L.) y matorral diverso entre los que se podrían citar los géneros *Erica*, *Cistus*, *Cytisus* y *Stauracanthus*.

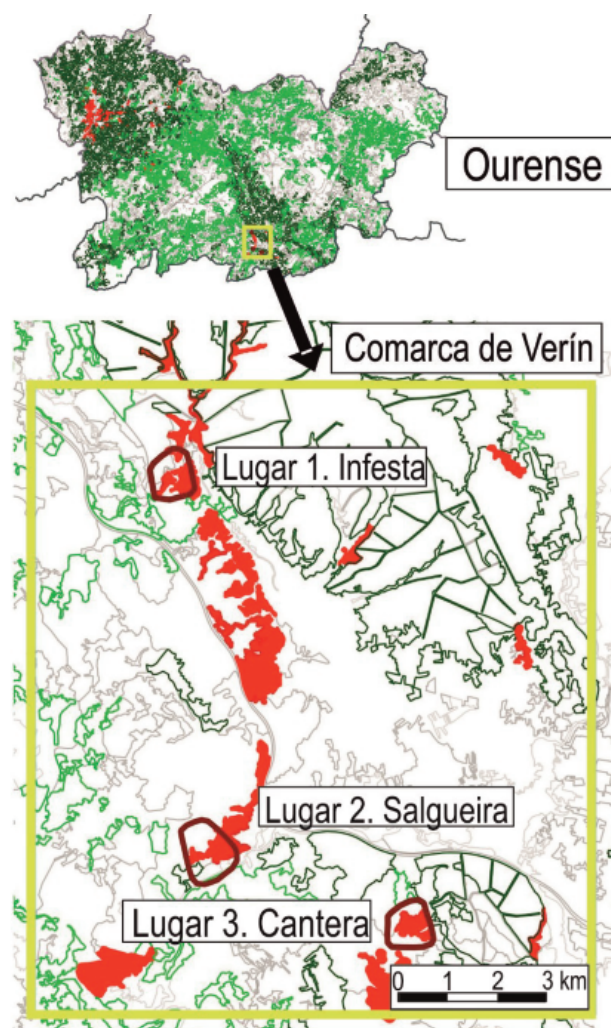


Figura 1. Localización de los tres lugares de estudio en la comarca de Verín, provincia de Ourense (Galicia). Los tres lugares se identifican en color rojo oscuro. Se muestra una reclasificación de los polígonos del Mapa Forestal de España a escala 1:25 000 más reciente en función de la especie arbórea dominante en la Comarca de Verín: rojo indica polígonos dominados por *Acacia* (*dealbata* y/o *melanoxydon*), verde oscuro corresponde a coníferas y verde claro a caducifolios.

Figure 1. Location of the three study sites in Verín County, province of Ourense within the autonomous community of Galicia, Spain. The three study sites are displayed in dark red. The colored polygons represent a reclassification of the dominant tree species according to the Forest Map of Spain at a scale of 1:25 000. Red indicates *Acacia* dominated polygons, dark green are conifers and light green is used for deciduous trees.

Captura de datos por el dron

Se empleó un multirrotor DJI Matrice 210 equipado con una cámara RGB (Zenmuse X4S) y una multispectral RedEdge-M (MicaSense) conectada a un sensor de iluminación incidente DLS (Downwelling Light Sensor) y un módulo GPS adicional.

Los vuelos de invierno se llevaron a cabo entre el 10 y 11 de marzo y los de verano entre el 30 de junio y el 2 de julio de 2020. En todos los casos se realizaron lo más cerca posible al momento de máxima elevación solar local para minimizar las sombras (Tabla 1). La superficie captada por la cámara RGB fue mayor que la captada por la multispectral y también tuvo más resolución espacial (5472x3078 frente a 1280x960 píxeles). El área total captada en los tres lugares varió entre 34 y 63 ha. Se seleccionó para ambas cámaras un solapamiento frontal y lateral de un 75%. La elevación (sobre el punto de despegue) se estableció en 120 m (el máximo según las regulaciones españolas). Con 120 m de elevación el *Ground Sampling Distance* (GSD) teórico sería de 3.29 cm/píxel en la imagen RGB y próximo a 8.3 cm/píxel en la imagen multispectral, pero el gradiente de elevación de los tres lugares dio lugar a valores de GSD mayores. La velocidad durante el vuelo se estableció en 5 m/s y la duración de cada vuelo fue cercana a los 20 minutos (Tabla 1). Justo antes de cada vuelo se tomaron imágenes del panel de reflectancias calibrado de MicaSense para poder obtener salidas de reflectancias compensadas. Tanto los vuelos de invierno como los de verano se pudieron efectuar en condiciones favorables.

Antes del vuelo y en cada lugar se colocaron unas 6 a 8 marcas (*Ground Control Point* o GCP) en el terreno que después se identificaron en diversos fotogramas individuales (al menos en 5) con el objetivo de mejorar la precisión espacial de los ortomosaicos. El centro de cada marca se midió con un receptor GNSS (Global Navigation Satellite Systems) conectado por internet a la estación del IGN (Instituto Geográfico Nacional) más cercana (Ponferrada, a unos 100 km) para una corrección en tiempo real de la posición.

Procesado de datos y digitalización de poblaciones de *A. dealbata*

Las imágenes adquiridas se procesaron mediante el software Pix4Dmapper para obtener ortomosaicos de las imágenes RGB y de las reflectancias en las cinco bandas. El tamaño inicial de los

ortomosaicos varió en los tres lugares y las dos fechas. Los errores RMS (*Root Mean Square*) en la georreferenciación fluctuaron entre 0.073 y 0.136 m en los ortomosaicos RGB y entre 0.174 y 0.312 m en los multispectrales (Tabla 1). El tamaño del píxel de salida de los ortomosaicos se estableció en 5 cm en RGB y 10 cm en los multispectrales. Los ortomosaicos RGB de invierno se muestran en la Figura 2 y los de verano en la Figura 3.

Se llevó a cabo una interpretación visual de las manchas ocupadas por *A. dealbata* en los ortomosaicos RGB invernales aprovechando que estaba en floración. La interpretación se ha realizado en pantalla a una escala aproximada de 1:375 con la ayuda de fotografías tomadas el mismo día del vuelo y del conocimiento de la vegetación local. El tamaño mínimo de los polígonos digitalizados se situó en unos 5 metros de distancia entre bordes y la separación entre manchas contiguas también en 5 m. Los ortomosaicos generados a partir de los fotogramas individuales adquiridos por el dron junto a los polígonos digitalizados (en amarillo) se muestran en la Figura 2. En esta figura se muestra también, mediante un polígono rojo, la zona común para los cuatro ortomosaicos de cada lugar (dos RGB y dos multispectrales) empleada posteriormente en los análisis y validaciones.

Proceso y valoración de los modelos MaxEnt

El programa MaxEnt estima la probabilidad de presencia a partir de puntos de presencia conocida de la especie de interés y un conjunto de variables predictoras (o ambientales) (Phillips et al. 2006, 2017). En nuestro caso estas variables han sido las reflectancias en cinco bandas espectrales (azul, verde, rojo, borde rojo, infrarrojo cercano) y el Índice de Vegetación normalizado (NDVI).

Los puntos (coordenadas) de presencia conocida se extrajeron al azar de una malla de 5x5 m superpuesta sobre la capa de poblaciones (manchas) de *A. dealbata* derivada de la interpretación visual del ortomosaico RGB invernal descrito previamente. En cada ejecución del programa (sobre los 6 ortomosaicos multispectrales) se seleccionaron 200 puntos al azar con presencia de *A. dealbata*. Tanto los puntos de presencia conocida empleados en los modelos como los empleados posteriormente en las matrices de confusión se extrajeron del área común establecida para cada uno de los tres lugares (polígonos rojos de las Figuras 2 y 3). Este área común contabiliza 10 016 nodos de la malla de 5x5 para el Lugar 1, 15 417 para el 2 y 12 640 para el 3.

Tabla 1. Información relativa a los vuelos efectuados en los tres lugares de estudio y en las dos estaciones (invierno y verano) de 2020 en la comarca de Verín. Se muestra el número de fotografías individuales para cada uno de los dos sensores, el valor medio teórico del GSD, el rango de elevaciones en cada ortomosaico, el número de GCP en tres dimensiones empleado adicionalmente y el error (RMS) de cada uno de los seis ortomosaicos.

Table 1. Information of the performed flights at the three study sites in the two seasons (winter and summer) in the Verín County. The table gives the number of individual images, the mean theoretical GSD, the elevation ranges at each site, the number of GCP finally used and the RMS obtained in the six orthomosaics.

Lugar de estudio	Estación	Fecha	Hora Inicio (UTC)	Sensor	Área total (ha)	Imágenes captadas		Rango de elevaciones		Georreferenciación	
						nº fotografías	Media GSD (cm)	Min (m)	Max (m)	3D GCP	RMS error (m)
Lugar 1. Infesta	Invierno	10-mar	13:55	RGB	45.4	201	4.20	481	655	8	0.073
				RedEdge	37.9	1440	10.84			8	0.185
	Verano	30-jun	13:09	RGB	40.9	161	4.72	483	652	6	0.089
				RedEdge	34.1	1135	12.65			6	0.174
Lugar 2. Salgueira	Invierno	11-mar	12:58	RGB	62.8	182	7.19	422	697	6	0.090
				RedEdge	46.6	1290	16.95			4	0.312
	Verano	02-jul	11:46	RGB	57.4	157	7.08	419	699	4	0.136
				RedEdge	44.4	1.12	18.37			5	0.194
Lugar 3. Cantera	Invierno	11-mar	14:53	RGB	48.9	197	4.91	459	628	6	0.123
				RedEdge	38.6	1385	12.57			7	0.246
	Verano	02-jul	10:27	RGB	45.1	184	4.93	450	633	6	0.066
				RedEdge	38.4	1305	12.95			4	0.213

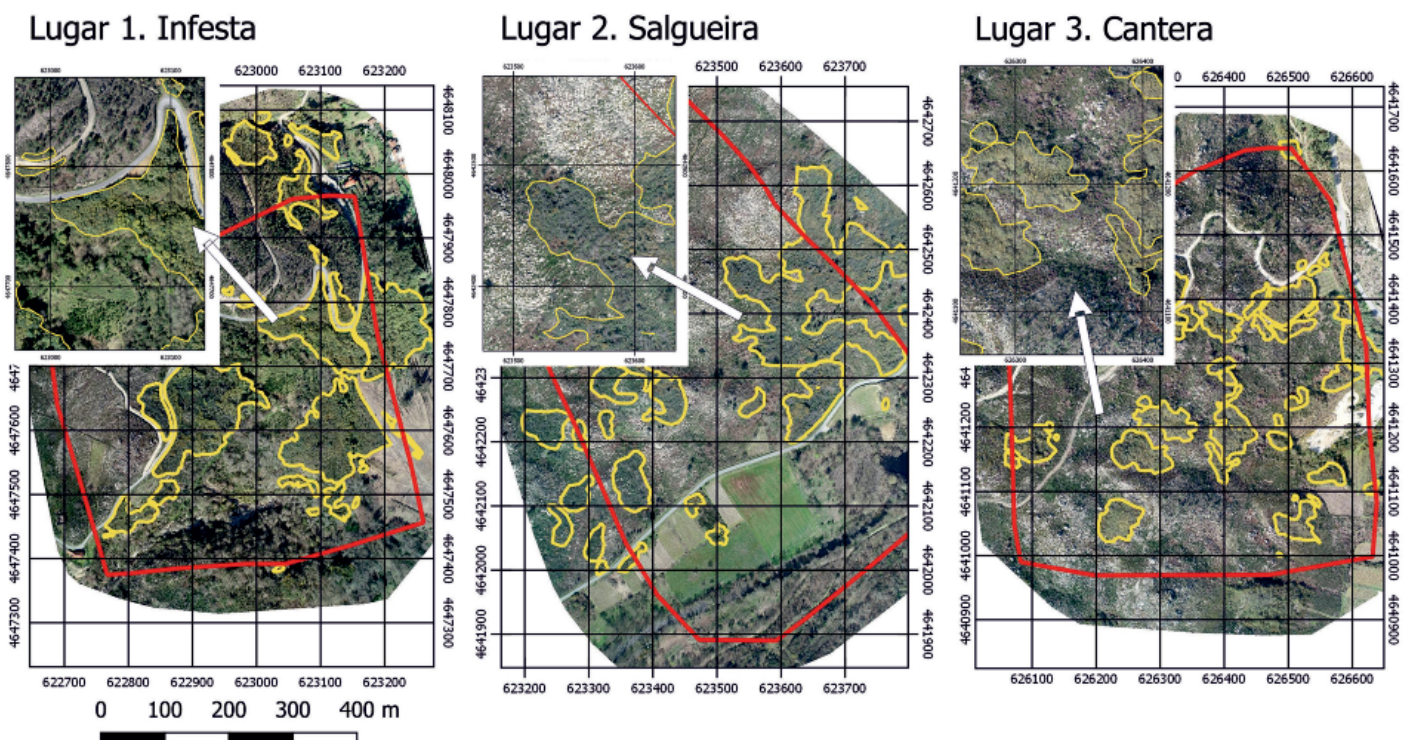


Figura 2. Ortomosaicos RGB derivados de los vuelos invernales (11 y 12 de marzo 2020) en los tres lugares de estudio. El polígono rojo exterior indica la zona analizada (que se solapa con los vuelos de verano y los ortomosaicos multispectrales). Los polígonos amarillos indican áreas identificadas como cubiertas por *A. dealbata* en la fotointerpretación visual llevada a cabo.

Figure 2. RGB orthomosaics derived from the mid-March 2020 drone flights at the three study sites. The outer red polygon delimits the common area for the RGB and the multispectral orthomosaics for which the MaxEnt analyses were performed. Yellow polygons are based on the visual interpretation performed on the winter RGB orthomosaics of the *A. dealbata* patches.

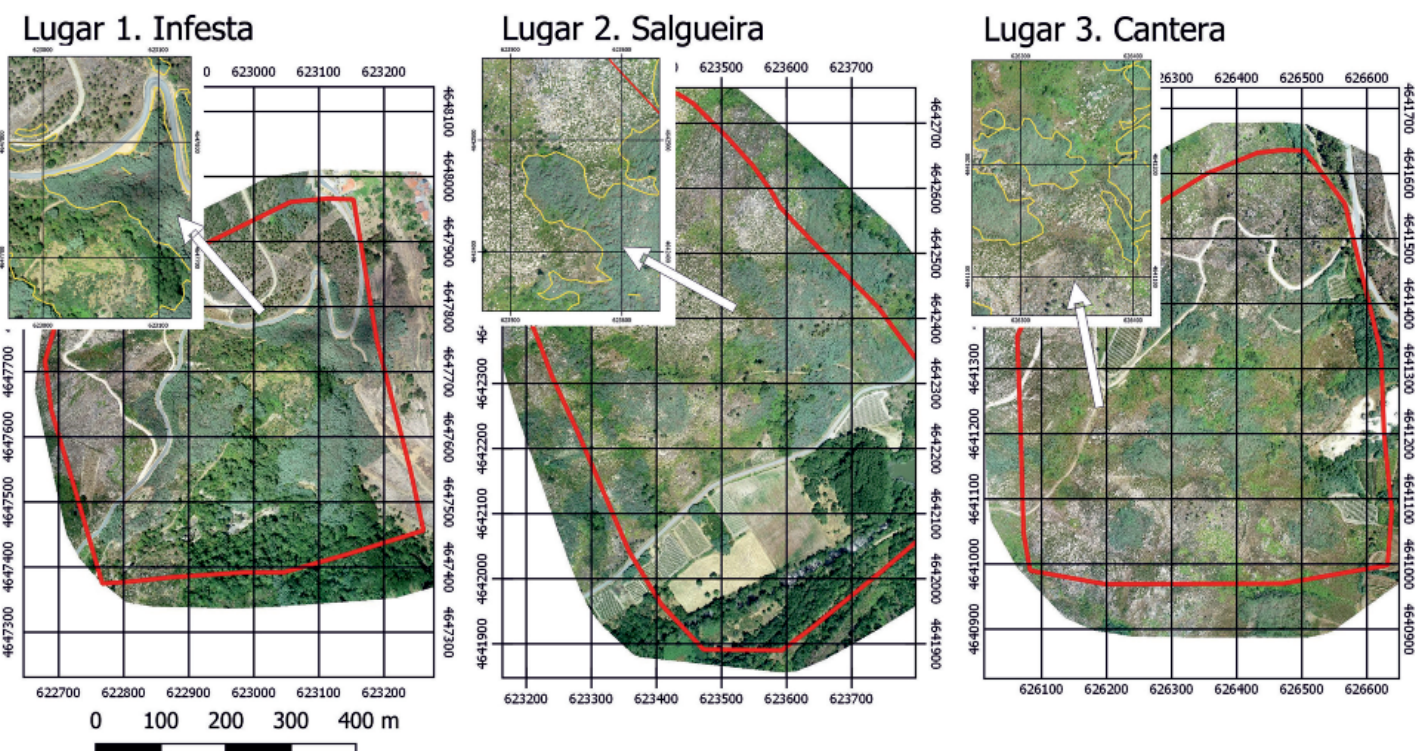


Figura 3. Ortomosaicos RGB derivados de los vuelos de verano (31 de junio a 2 de julio de 2020) en los tres lugares de estudio. El polígono rojo exterior indica la zona analizada (que se solapa con los vuelos de invierno y los ortomosaicos multispectrales). En las zonas aumentadas se han mantenido los polígonos amarillos que indican áreas identificadas como cubiertas por *A. dealbata* en la fotointerpretación visual llevada a cabo en las imágenes invernales.

Figure 3. RGB orthomosaics derived from the summer (early July) 2020 drone flights at the three study sites. The outer red polygon delimits the common area for the RGB and the multispectral orthomosaics for which the MaxEnt analyses were performed. Yellow polygons based on the visual interpretation performed on the winter RGB orthomosaics of the *A. dealbata* patches are also displayed in the zoomed areas.

MaxEnt proporciona además de los valores de idoneidad, un conjunto de resultados complementarios como el Área Bajo la Curva (AUC) de los análisis ROC (*Receiver Operating Characteristics*), usada como medida de ajuste a los datos, la importancia de las variables incluidas en el modelo y las curvas de respuesta o relación entre la probabilidad predicha y los valores de cada variable independiente (Felicísimo et al. 2012). De las 200 muestras, un 75% se emplearon en el entrenamiento del modelo y un 25% en la validación. Para el resto de los parámetros se tomaron los valores propuestos por Phillips et al. (2006, 2017). Para obtener información adicional de la relevancia de las variables implicadas se llevaron a cabo test *Jackknife*. Finalmente se obtienen las curvas de respuesta en el análisis ROC, en las que el eje horizontal representa la “fracción de área predicha” ($1 - \text{Especificidad}$) mientras que el vertical representa la “Sensibilidad” ($1 - \text{Tasa de Omisión}$) (Phillips et al. 2006). AUC se calcula como el área bajo la curva ROC y representa la capacidad del modelo para predecir adecuadamente la presencia (sensibilidad) y la ausencia (especificidad). Este estadístico mide el ajuste del modelo a los datos de entrada, suele variar en el rango 0.5 (azar) a 1.0 (ajuste perfecto) y debe interpretarse como un estimador del ajuste del modelo a los datos (Felicísimo et al. 2012).

La salida continua de MaxEnt se convirtió en mapas binarios de presencia/ausencia mediante el valor umbral determinado minimizando la diferencia en valor absoluto entre sensibilidad y especificidad en la curva ROC. Una vez clasificadas las imágenes se construyeron matrices de confusión entre los valores predichos en las clasificaciones y la verdad terreno (todos los nodos de la malla de 5x5 m dentro de los polígonos fotointerpretados como ocupados por *A. dealbata*). Por último se calcularon el valor de Kappa (índice del acuerdo), la Precisión del Usuario (UA) que representa la probabilidad de que la predicción represente la realidad, la precisión del productor (PA) que representa la calidad de las clasificaciones de los datos interpretados (verdad terreno) y la precisión global (OA) entre las clases predichas por MaxEnt y la verdad terreno derivada de la fotointerpretación.

Resultados

Especificidad y sensibilidad de los modelos MaxEnt

El valor de AUC de los modelos SDM basados en ajustes de máxima entropía realizados con MaxEnt varió para los datos de entrenamiento entre 0.80 y 0.86 para las imágenes invernales y entre 0.83 y 0.90, para las imágenes de verano en los tres lugares de estudio (Tabla 2). Los valores de AUC para los datos de validación fueron bastante parecidos y siguen el mismo patrón: en los

seis modelos los valores de AUC de las curvas ROC fueron muy próximos o superiores a 0.80, el valor umbral usualmente considerado en este estadístico como indicativo de un buen ajuste del modelo.

Contribución de las variables a los modelos MaxEnt

Las contribuciones de cada variable a las ganancias de cada modelo a partir de los test de *Jackknife* se muestran en la Figura 4. En 5 de los 6 modelos la variable con mayor ganancia cuando se considera de manera individual fue el NDVI y, en un modelo, la reflectancia en la banda azul. Otra variable relevante en la mayor parte de los modelos fue la reflectancia en el rojo. Por otra parte las variables con una menor contribución por sí solas fueron la reflectancia en el infrarrojo cercano (NIR) y en el borde rojo.

Para las imágenes de invierno la ausencia de la reflectancia en el borde-rojo es la que parece provocar un mayor descenso en la ganancia de los modelos, lo que no ocurre en las imágenes de verano, en las que los descensos más acusados se producen por la ausencia de la reflectancia en el azul o del NDVI. Además de las diferencias entre las variables en verano e invierno, también se aprecian variaciones en el papel de las distintas variables entre los tres lugares de estudio (Figura 4).

Precisión de los modelos MaxEnt y valores de idoneidad

A partir de los valores de sensibilidad y especificidad para los diferentes umbrales de idoneidad (análisis ROC), se empleó el criterio de igualdad en la sensibilidad y la especificidad resultando para el conjunto de los tres sitios en un valor umbral de 0.6. Las matrices de confusión se obtuvieron finalmente cruzando los nodos de la malla de 5x5 metros con presencia de *A. dealbata* y los datos de presencia o ausencia derivados de la reclasificación de los valores de idoneidad obtenidos en los modelos MaxEnt en esos mismos puntos (Figura 2). De esta manera se han obtenido valores de precisión global, como indicativo de la calidad de los mapas clasificados, de entre 0.82 y 0.90 para las imágenes invernales y algo más elevados (entre 0.91 y 0.95) para las imágenes de verano (Tabla 3). En general la UA ha sido más alta que PA excepto en dos de los lugares de estudio para modelos con imágenes invernales (Tabla 3).

Por último, los mapas clasificados en intervalos de idoneidad correspondientes a las ortoimágenes de invierno se muestran en la Figura 5 y los derivados de las ortoimágenes de verano en la Figura 6. En estas imágenes se aprecia claramente los mayores valores de idoneidad en torno a las manchas de *A. dealbata* obtenidos en las imágenes de verano.

Tabla 2. Valores de ganancia (regularizada y no regularizada para los datos de entrenamiento), el AUC para los dos conjuntos de puntos y la desviación estándar del AUC de los modelos MaxEnt para los tres lugares de estudio y las dos estaciones (invierno y verano de 2020) ajustados mediante 200 puntos seleccionados al azar entre las áreas con presencia conocida de *A. dealbata* (un 75% de los puntos se emplearon para el set de entrenamiento y un 25% como test).

Table 2. Values of the gain (regularized and non-regularized for the training data), the AUC for both datasets and the standard deviation of the MaxEnt models for the three study sites and the two seasons. Models are based on 200 random points with *A. dealbata* presence: 75% for training and 25% for test.

Lugar de estudio	Estación	Set de entrenamiento				Set de test	
		Ganancia no regularizada	Ganancia regularizada	Desv. St. AUC	AUC	Ganancia	AUC
Lugar 1. Infesta	Invierno	0.53	0.43	0.03	0.80	0.45	0.75
	Verano	0.76	0.65	0.04	0.83	0.65	0.81
Lugar 2. Salgueira	Invierno	0.95	0.79	0.02	0.86	0.94	0.86
	Verano	1.29	1.16	0.01	0.90	1.52	0.93
Lugar 3. Cantera	Invierno	0.73	0.49	0.03	0.84	0.57	0.81
	Verano	1.04	0.95	0.02	0.88	1.06	0.88




Figura 4. Resultados de los test de Jackknife sobre la importancia de las variables "ambientales" basado en la ganancia regularizada de los modelos MaxEnt. Se muestran los resultados para los tres lugares de estudio (filas) mientras que las columnas se corresponden con imágenes de invierno (izquierda) y de verano (derecha). Las variables consideradas han sido las reflectancias en cinco bandas espectrales y el NDVI.

Figure 4. Results of the jackknife tests on the importance of the "environmental" variables for the regularized training gain in MaxEnt models. Each plot represents the results for the three study sites (rows) and the two seasons: winter (left) and summer (right). Variables used are reflectance bands and NDVI.

Tabla 3. Parámetros de las matrices de confusión construidas a partir de los resultados de los modelos de MaxEnt (asumiendo presencia con un valor de adecuación en el modelo igual o mayor a 0.6) y considerando la verdad terreno las áreas digitalizadas en SIG a partir de los ortomosaicos invernales con las plantas en flor. Se muestran la Precisión del Productor (PA), del Usuario (UA), la Global (OA) y el valor del índice de acuerdo Kappa.

Table 3. Confusion matrix parameters for the 0.6 threshold of the suitability output values of MaxEnt models for the three study sites and the two seasons. The classification based MaxEnt suitability output values are the predicted values, while nodes in the digitalized polygons are considered the ground truth datasets. It is displayed the Producer (PA), User (UA) and Global Accuracy (OA) and the Kappa Index of agreement

		Imágenes de Invierno				Imágenes de Verano			
		Verdad terreno				Verdad terreno			
	Clasificación MaxEnt	PA	UA	OA	Kappa	PA	UA	OA	Kappa
Lugar1. Infesta	0: Ausencia	0.93	0.89			0.95	0.93		
	1: Presencia	0.61	0.73			0.77	0.82		
	Total	0.77	0.81	0.86	0.58	0.86	0.88	0.91	0.74
Lugar2. Salgueira	0: Ausencia	0.93	0.95			0.98	0.96		
	1: Presencia	0.67	0.57			0.70	0.84		
	Total	0.80	0.76	0.90	0.56	0.84	0.90	0.95	0.74
Lugar3. Cantera	0: Ausencia	0.84	0.94			0.96	0.94		
	1: Presencia	0.70	0.45			0.67	0.76		
	Total	0.77	0.69	0.82	0.44	0.82	0.85	0.92	0.66

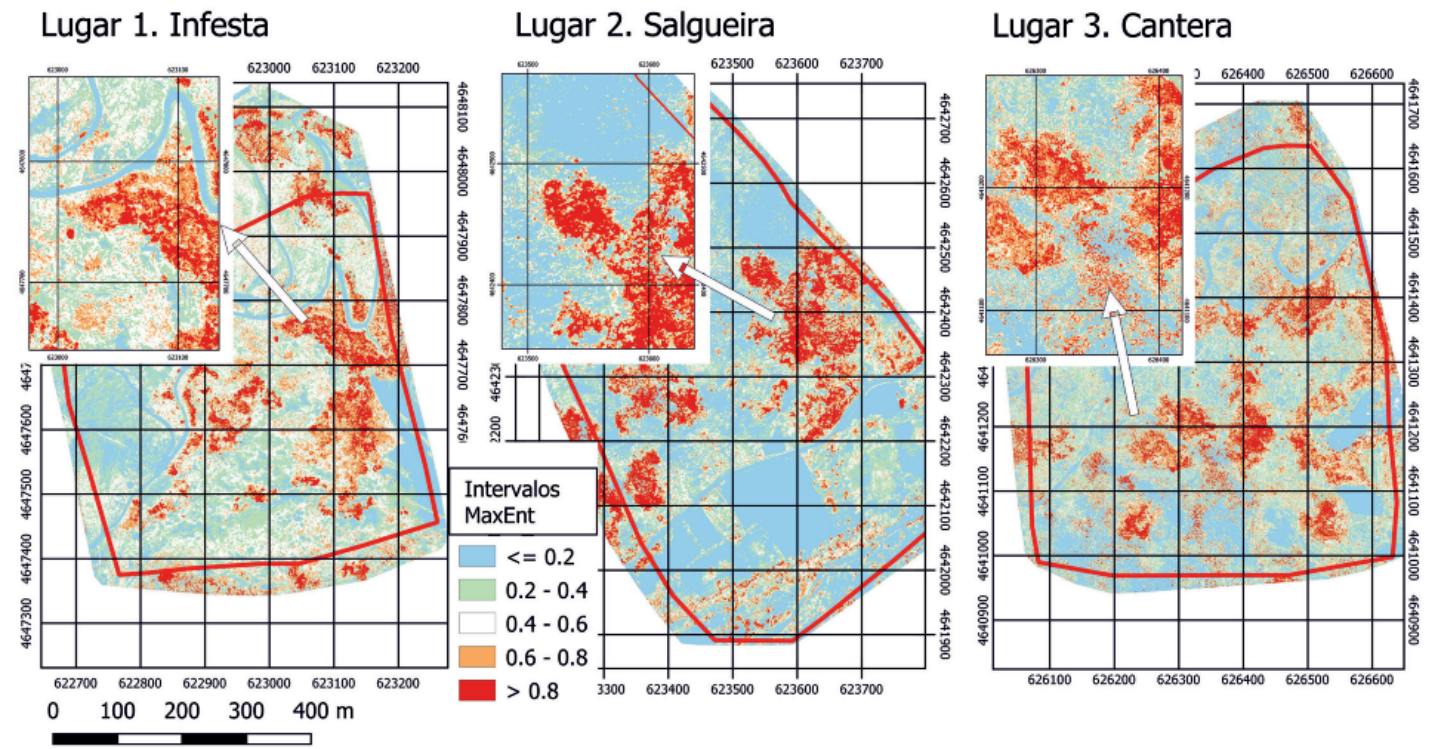


Figura 5. Mapas clasificados a partir de los valores continuos de idoneidad derivados de los modelos MaxEnt utilizando ortomosaicos multispectrales invernales para los tres lugares de estudio. Los colores naranjas (≥ 0.6 and < 0.8) y rojos (≥ 0.8) indican una probabilidad alta de presencia de *A. dealbata* en los modelos.

Figure 5. Classified maps derived from the continuous suitability values output of the MaxEnt models of the three study sites based on winter multispectral orthomosaics. Red color (≥ 0.8) and orange (≥ 0.6 and < 0.8) indicate high probability of *A. dealbata* presence in the models.

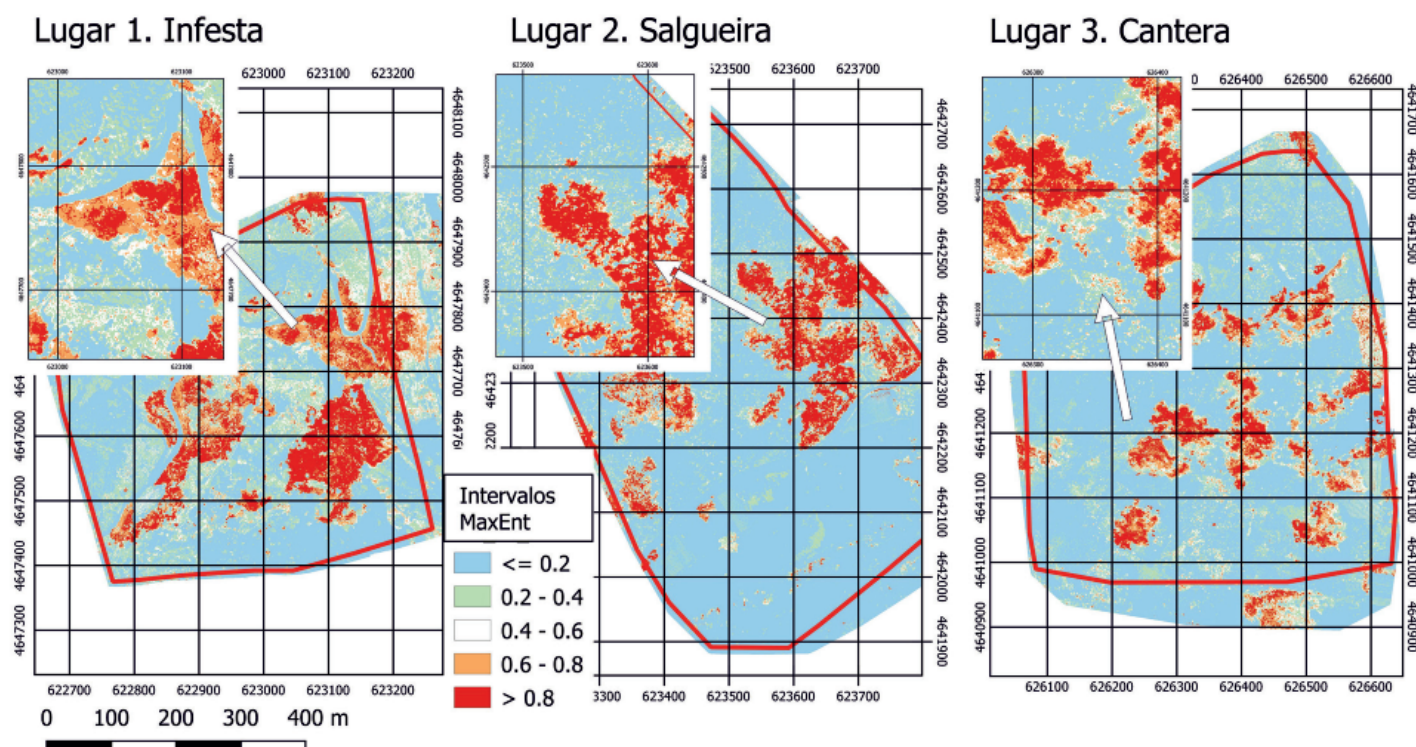


Figura 6. Mapas clasificados a partir de los valores continuos de idoneidad derivados de los modelos MaxEnt utilizando ortomosaicos multispectrales de verano para los tres lugares de estudio. Los colores naranjas (≥ 0.6 and < 0.8) y rojos (≥ 0.8) indican una probabilidad alta de presencia de *A. dealbata*.

Figure 6. Classified maps derived from the continuous suitability values output of the MaxEnt models of the three study sites based on summer multispectral orthomosaics. Red color (≥ 0.8) and orange (≥ 0.6 and < 0.8) indicate high probability of *A. dealbata* presence in the models.

Discusión

Comportamiento de los modelos basados en MaxEnt

MaxEnt ha sido empleado comúnmente como herramienta muy útil en la predicción de la distribución de especies (ej. Monterroso et al. 2009; Felicísimo et al. 2012). No obstante se está utilizando cada vez más en otros ámbitos, como empleando variables derivadas de la teledetección, en las que muestra buenos resultados (Mack et al. 2016; Stenzel et al. 2017; Amici et al. 2017; Lopatin et al. 2019; Fernández-Manso y Quintano 2020).

En nuestros análisis, los valores de AUC obtenidos en los seis modelos basados en MaxEnt fueron la mayor parte de las veces superiores a 0.80, y cercanos a 0.90 en algunos casos, lo que indica un comportamiento excelente de los modelos (Muñoz et al. 2016; Fernández-Manso y Quintano 2020). Se apreciaron algunas diferencias entre los tres lugares y más claras entre las dos estaciones analizadas: invierno y verano. Los resultados obtenidos ponen de manifiesto la aplicabilidad del procedimiento y el mejor comportamiento de las imágenes estivales frente a las invernales en la cartografía detallada de áreas ocupadas por *A. dealbata*.

Por otra parte, hay que mencionar que diversos autores plantean distintas limitaciones en el empleo de AUC fundamentalmente enfocadas a que no se utilice en la comparación entre especies distintas o con áreas de distribución dispares (ej. Lobo et al. 2007; Jiménez-Valverde 2012). No obstante estos mismos autores indican que AUC es verdaderamente informativo cuando el objetivo es la estimación de distribuciones presentes (como es nuestro caso) y no potenciales, en las que este estadístico presenta más limitaciones.

Las aproximaciones de SDM basadas en MaxEnt presentan ciertas ventajas frente a otros clasificadores (Muñoz et al. 2016; Fernández-Manso y Quintano 2020): 1) MaxEnt es un modelo no paramétrico; 2) es un sustituto atractivo frente a métodos “machine learning” dado que solo se precisan muestras de presencia para

su entrenamiento 3) su salida probabilística tiene un sentido físico que hace su interpretación fácil. En cualquier caso, el comportamiento de los SDM para cartografiar la presencia de especies invasoras es comparable con lo mostrado por otros autores usando clasificaciones binarias (ej. Lehmann et al. 2017; Piironen et al. 2018). Lopatin et al. 2019 sugiere que desde un punto de vista operativo MaxEnt es muy prometedor dado que no es preciso identificar las clases no deseadas (otras cubiertas diferentes a la considerada como objetivo) y por tanto se requiere mucho menor esfuerzo en el pre-procesamiento de los datos. MaxEnt ofrece también la posibilidad de introducir las ausencias mediante SWD format del paquete NTBOX (https://rdrr.io/github/luismurao/ntbox/man/swd_format.html), lo que podría mejorar las clasificaciones en casos en que la fracción de datos de entrenamiento fuese reducida; en el caso presentado se ha optado por maximizar el esfuerzo de muestreo de presencia, de forma que la malla de 5 x 5 m cubre todo el rango de condiciones en los que aparece *A. dealbata*. El hecho de requerir únicamente muestras de presencia facilita la capacidad de mapear tipologías de vegetación (especies o hábitats) en paisajes complejos con una gran variabilidad (Álvarez-Martínez et al. 2017).

Precisión en las predicciones y variabilidad espectral

La precisión global en los mapas de predicción es bastante alta, con valores entre 0.82 y 0.90 para las imágenes invernales y entre 0.91 y 0.95 para las estivales. Lehmann et al. (2017) empleando RPAS en una aproximación para cartografiar la invasión de *Acacia mangium* en un ecosistema de sabanas en Brasil, obtuvo una precisión global de 82.7% a partir del análisis de las imágenes. Tanto las precisiones del productor como del usuario presentan valores más elevados para las imágenes de verano, lo que sugiere una mejor calidad en la clasificación de los píxeles de entrenamiento (PA) y un mejor ajuste de las predicciones a la realidad (con menores errores de comisión).

En cualquier caso hay diversas mejoras que se podrían abordar para obtener mejores valores en los parámetros de precisión. Una de ellas, junto a la corrección del efecto de las sombras, podría ser el empleo de filtros para evitar el efecto de “sal y pimienta” de las clasificaciones (ej. [Fernández-Manso y Quintano 2020](#); [Gómez et al. 2020](#)). Otra aproximación podría ser mejorar la identificación de los puntos de presencia conocida. En nuestra aproximación se han seleccionado al azar nodos de la malla de 5x5 m situados dentro de los polígonos fotointerpretados como cubiertos por *A. dealbata* pero sin verificarlos en campo.

La variabilidad espectral dentro de las cubiertas de una misma especie se puede interpretar con un efecto colateral de la alta resolución de las imágenes captadas por los drones. En nuestro análisis con resoluciones de 5 cm en RGB y 10 cm en multiespectral las cubiertas de *A. dealbata* no presentan una respuesta espectral homogénea. Por ejemplo en las imágenes invernales en el momento de la floración hay un contraste importante entre el amarillo de las flores y el verde de las hojas. Este contraste no es tan acentuado en las imágenes de verano y puede haber contribuido a los mejores resultados obtenidos con estas últimas imágenes en los modelos MaxEnt al aumentar la ganancia del conjunto de las variables predictoras. Este patrón se repite en los tres sitios de estudio, a pesar de las diferencias en la vegetación que acompaña a la *A. dealbata*. Además, el hecho de que la mayor parte de las manchas de *Acacia* provengan de áreas perturbadas (en su mayoría por incendios en nuestro caso) introduce también variaciones importantes en las cubiertas dado que tras el fuego algunos pies rebrotan y también hay germinación, lo que introduce una mayor variabilidad en las copas.

En la presente aproximación no se ha llevado a cabo ningún procesamiento para minimizar el efecto de las sombras. Los ángulos solares más bajos de las imágenes invernales (mediados de marzo) pueden también haber contribuido a un mayor ruido en estas imágenes. A pesar de haber realizado los vuelos lo más cerca posible de la máxima elevación solar, este factor podría haber tenido algún efecto en los mejores ajustes obtenidos con las imágenes de verano.

A. dealbata florece en invierno, normalmente entre febrero y marzo dependiendo de la localidad. Su espectacular floración de flores amarillas resulta interesante a la hora de discriminar las áreas ocupadas por la especie y facilitar su clasificación. No obstante, en la literatura no hay acuerdo sobre si esta característica espectral es útil para una cartografía más precisa de su extensión. [de Sá et al. \(2017\)](#) consideró que el comportamiento de las clasificaciones con imágenes Landsat era mejor en otoño que en la época de floración (invierno) para *Acacia longifolia* en Portugal. Por otra parte, [Martins et al. \(2016\)](#) comparando imágenes ASTER de marzo y agosto concluyeron que el comportamiento de las clasificaciones basadas en la época de floración es mejor. Nuestro trabajo corrobora que la época de floración no es la más adecuada para la cartografía del área cubierta por *A. dealbata*.

Detección y propagación de *A. dealbata*

Los RPAS están contribuyendo a un incremento en las resoluciones espaciales de los SDM, y también permiten disponer de una escala intermedia entre medidas de campo y la resolución de imágenes de satélite o aeroportadas en la estimación basada en modelos. Los resultados obtenidos mediante RPAS son prometedores y pueden dar lugar al desarrollo de muestreos más efectivos desde el punto de vista del coste ([Puliti et al. 2018](#)). El descenso de costes en los muestreos basados en drones y el acceso libre a librerías de imágenes de satélite abren nuevas opciones en la cartografía de alta resolución de especies invasoras.

La integración de información a diferentes escalas para estimar la cobertura de especies invasoras ha sido abordada por diversos autores. Normalmente el primer paso se basa en una fotointerpretación visual de las cubiertas en ortomosaicos generados a partir de imágenes de RPAS. Los mapas generados mediante la interpretación visual se usan posteriormente como entrenamiento en

modelos basados en imágenes multitemporales / multiespectrales de satélite para cartografiar a gran escala la distribución de la especie de interés (ej. [Kattenborn et al. 2019](#); [Martínez-Sánchez et al. 2019](#)).

Las especies invasoras se consideran un riesgo para la biodiversidad y su seguimiento es necesario para abordar un posible control y erradicación. Por ello, investigaciones futuras deberían centrarse en la detección temprana, en la prevención de nuevas introducciones y en un manejo sostenible y rentable económicamente de los nuevos ecosistemas resultantes de la invasión ([Marchante et al. 2011](#); [Souza-Alonso et al. 2017](#)). En este contexto las aproximaciones propuestas en este trabajo se consideran relevantes.

Conclusiones

El análisis ROC y las matrices de confusión muestran que los modelos MaxEnt son adecuados para la clasificación de la presencia/ausencia de *A. dealbata* en las tres zonas de estudio y en los dos momentos del año a partir de la información multiespectral captada mediante dron, siendo la reflectancia en la banda del azul y el NDVI las variables que aportan una mayor ganancia regularizada.

Los resultados derivados del SDM empleado sostienen que las imágenes estivales son más adecuadas que las invernales, a pesar de coincidir esta últimas con la floración, en la clasificación precisa de las áreas cubiertas por *A. dealbata*. Este mejor comportamiento de las clasificaciones que usan imágenes de verano parece estar relacionado con una mayor ganancia del conjunto de las variables predictoras (bandas espectrales y NDVI).

Por tanto, la metodología propuesta se considera adecuada para realizar una cartografía detallada de la presencia de *A. dealbata* que posibilite el seguimiento de la dinámica de sus poblaciones y contribuya eventualmente al control de éstas.

Contribuciones de los Autores

Antonio Vázquez de la Cueva: conceptualización, análisis formal, redacción, validación y visualización. Isabel Aulló Maestro: análisis formal, recursos, revisión y edición. Fernando Montes Pita: conceptualización, revisión y edición.

Referencias

- Aasen, H., Honkavaara, E., Lucieer, A., Zarco-Tejada, P.J. 2018. Quantitative Remote Sensing at Ultra-High Resolution with UAV Spectroscopy: A Review of Sensor Technology, Measurement Procedures, and Data Correction Workflows. *Remote Sensing* 10, 1091; <https://doi.org/10.3390/rs10071091>
- Álvarez Martínez, J.M., Jiménez-Alfaro, B., Barquín, J., Ondiviela, B., Recio, M., Silió, A., Juanes, J.A. 2017. Modelling the area of occupancy of habitat types with remote sensing. *Methods in Ecology and Evolution* 9: 580-593.
- Amici, V., Marcantonio, M., La Porta, N., Rocchini, D. 2017. A multi-temporal approach in MaxEnt modelling: A new frontier for land use/land cover change detection. *Ecological Informatics* 40, 40–49.
- de Sá, N.C., Carvalho, S., Castro, P., Marchante, E., Marchante, H. 2017. Using Landsat Time Series to Understand How Management and Disturbances Influence the Expansion of an Invasive Tree. *IEEE Journal of selected topics in applied earth observations and remote sensing* 10 (7): 3243-3253. <https://doi.org/10.1109/JSTARS.2017.267376>
- de Sá, N.C., Castro, P., Carvalho, S., Marchante, E., López-Núñez, F.A., Marchante, H. 2018. Mapping the Flowering of an Invasive Plant Using Unmanned Aerial Vehicles: Is There Potential for Biocontrol Monitoring? *Frontiers in Plant Science* 9:293. <https://doi.org/10.3389/fpls.2018.00293>
- Díaz Delgado, R., Múcher, S. 2019. Editorial of Special Issue “Drones for Biodiversity Conservation and Ecological Monitoring”. *Drones* 3, 47; <https://doi.org/10.3390/drones3020047>
- Felícísimo, A.M., Muñoz, J., Mateo, R.G., Villalba, C.J. 2012. Vulnerabilidad de la flora y vegetación españolas ante el cambio climático. *Ecosistemas* 21(3):1-6; <https://doi.org/10.7818/ECOS.2012.21-3.01>

- Fernández-Manso, A., Quintano, C. 2020. A Synergetic Approach to Burned Area Mapping Using Maximum Entropy Modeling Trained with Hyperspectral Data and VIIRS Hotspots. *Remote Sensing* 12, 858; <https://doi.org/10.3390/rs12050858>
- Gómez, C., Goodbody, T.R.H., Coops, N.C., Alvarez-Taboada, F., Sanz-Ablanedo, E., 2020. Forest ecosystem monitoring using Unmanned Aerial Systems. En: Green, D.R., BJ Gregory, B.J., Karachok, A. (Eds.). *Unmanned Aerial Remote Sensing. UAS for Environmental Applications*, pp.173-196. CRC Press. Boca Ratón, FL., Estados Unidos.
- Goodbody, T.R.H., Coops, N.C., Marshall, P.L., Tompalski, P., Crawford, P. 2017. Unmanned aerial systems for precision forest inventory purposes: A review and case study. *The Forestry chronicle* 93 (1): 71-81.
- Hernandez, L., Martínez-Fernandez, J., Canellas, I., Vázquez de la Cueva, A. 2014. Assessing spatio-temporal rates, patterns and determinants of biological invasions in forest ecosystems. The case of *Acacia* species in NW Spain. *Forest Ecology and Management* 329: 206-213. <https://doi.org/10.1016/j.foreco.2014.05.058>
- Jiménez-Valverde, A. 2012. Insights into the area under the receiver operating characteristic curve (AUC) as a discrimination measure in species distribution modelling. *Global Ecology and Biogeography* 21, 498-507. <https://doi.org/10.1111/j.1466-8238.2011.00683.x>
- Kattenborn, T., Lopatin, J., Förster, M., Braun, A.C., Fassnacht, F.E. 2019. UAV data as alternative to field sampling to map woody invasive species based on combined Sentinel-1 and Sentinel-2 data 2 *Remote Sensing of Environment* 227, 61-73. <https://doi.org/10.1016/j.rse.2019.03.025>
- Lehmann, J.R.K., Prinz, T., Ziller, S.R., Thiele, J., Heringer, G., Meira-Neto, J.A.A., Buttschardt, T.K. 2017. Open-Source Processing and Analysis of Aerial Imagery Acquired with a Low-Cost Unmanned Aerial System to Support Invasive Plant Management. *Frontiers in Environmental Science* 5:44. <https://doi.org/10.3389/fenvs.2017.00044>
- Lobo, J.M., Jiménez-Valverde, A., Real, R. 2007. AUC: a misleading measure of the performance of predictive distribution Models. *Global Ecology and Biogeography* 17(2):145-151; <https://doi.org/10.1111/j.1466-8238.2007.00358.x>
- Lopatin, J., Dolos, K., Kattenborn, T., Fassnacht, F.E. 2019. How canopy shadow affects invasive plant species classification in high spatial resolution remote sensing. *Remote Sensing in Ecology and Conservation* 5 (4):302-317.
- Lorenzo, P., González, L., Reigosa, M.J. 2010. The genus *Acacia* as invader: the characteristic case of *Acacia dealbata* Link in Europe. *Annals of Forest Science* 67 (1), 101.
- Lorenzo, P., Pazos-Malvido, E., Rubido-Bará, M., Reigosa, M.J., González, L. 2012. Invasion by the leguminous tree *Acacia dealbata* (Mimosaceae) reduces the native understorey plant species in different communities. *Australian Journal of Botany* 60 (8), 669-675.
- Mack, B., Roscher, R., Stenzel, S., Feilhauer, H., Schmidtlein, S., Waske, B. 2016. Mapping raised bogs with an iterative one-class classification approach. *ISPRS Journal of Photogrammetry and Remote Sensing* 120, 53-64. <https://doi.org/10.1016/j.isprsjprs.2016.07.008>
- Marchante, H., Freitas, H., Hoffmann, J.H. 2011. Post-clearing recovery of coastal dunes invaded by *Acacia longifolia*: is duration of invasion relevant for management success? *Journal of Applied Ecology* 48:1295-1304
- Martínez-Sánchez, J., González-de-Santos, L.M., Novo, A., González-Jorge, H. 2019. UAV and satellite imagery applied to alien species mapping in NW Spain. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Volume XLII-2/W13, 2019 ISPRS Geospatial Week 2019, 10-14 June 2019, Enschede, Países Bajos.
- Martins, F., Alegria, C., Gil, A. 2016. Mapping invasive alien *Acacia dealbata* Link using ASTER multispectral imagery: a case study in central-eastern of Portugal. *Forest Systems* 25(3), e078; <https://doi.org/10.5424/fs/2016253-09248>
- Monterroso, P., Brito, J.C., Ferreras, P., Alves, P.C. 2009. Spatial ecology of the European wildcat in a Mediterranean ecosystem: Dealing with small radio-tracking datasets in species conservation. *Journal of Zoology* 279, 27-35.
- Muñoz, A., Santos, X., Felicísimo, A.M. 2016. Local-scale models reveal ecological niche variability in amphibian and reptile communities from two contrasting biogeographic regions. *PeerJ* 4:e2405; <https://doi.org/10.7717/peerj.2405>
- Nentwig, W., Bacher, S., Kumschick, S., Pysek, P., Vila, M. 2018. More than "100 worst" alien species in Europe. *Biological Invasions* 20:1611-1621. <https://doi.org/10.1007/s10530-017-1651-6>
- Ough, K., 2001. Regeneration of wet forest flora a decade after clear-felling or wildfire- is there a difference? *Australian Journal of Botany* 46, 645-664.
- Phillips, S.J., Anderson, R.P., Schapire, R.E. 2006. Maximum entropy modeling of species geographic distributions. *Ecological Modelling*, 190(3-4):231-259.
- Phillips, S.J., Anderson, R.P., Dudík, M., Schapire, R.E., Blair, M.E. 2017. Opening the black box: an open-source release of Maxent. *Ecography* 40: 887-893, 2017. <https://doi.org/10.1111/ecog.03049>
- Piironen, R., Fassnacht, F.E., Heiskanen, J., Maeda, E., Mack, B., Pellikka, P. 2018. Invasive tree species detection in the Eastern Arc Mountains biodiversity hotspot using one class classification. *Remote Sensing of Environment* 218, 119-131
- Puliti, S., Ørka, H.O., Gobakken, T., Næsset, E. 2015. Inventory of Small Forest Areas Using an Unmanned Aerial System, *Remote Sensing* 7, 9632-9654; <https://doi.org/10.3390/rs70809632>
- Puliti, S., Talbot, B., Astrup, R. 2018. Tree-Stump Detection, Segmentation, Classification, and Measurement Using Unmanned Aerial Vehicle (UAV) Imagery, *Forests* 9, 102; <https://doi.org/10.3390/f9030102>.
- Souza-Alonso, P., Rodríguez, J., González, L., Lorenzo, P. 2017. Here to stay. Recent advances and perspectives about *Acacia* invasion in Mediterranean areas. *Annals of Forest Science* 74:5. <https://doi.org/10.1007/s13595-017-0651-0>
- Stenzel, S., Fassnacht, F.E., Mack, B., Schmidtlein, S. 2017. Identification of high nature value grassland with remote sensing and minimal field data. *Ecological Indicators* 74, 28-38. <https://doi.org/10.1016/j.ecol-ind.2016.11.005>
- Suárez-Seoane, S., Álvarez Martínez, J.M., Palacín, C., Alonso, J.C. 2018. From general questions to specific answers. Underspecificity as a source of uncertainty in ecology. *Conservation Biology* 227: 167-180.
- Vázquez de la Cueva, A. 2014. Case studies of the expansion of *Acacia dealbata* in the valley of the river Mino (Galicia, Spain). *Forest Systems* 23(1), 3-14. <https://doi.org/10.5424/fs/2014231-02531>
- Vázquez de la Cueva, A., Climent, J.M., Casais Calo, L., Quintana, J.R. 2015. Current and future estimates for the fire frequency and the fire rotation period in the main woodland types of peninsular Spain: a case-study approach. *Forest Systems* 24(2) e031. <https://doi.org/10.5424/fs/2015242-06454>
- Vicente, J.R., Alagador, D., Guerra, C., Alonso, J.M., Kueffer, C., Vaz, A.S., Fernandes, R.F., Cabral, J.A., Araujo, M.B., Honrado, J.P. 2016. Cost-effective monitoring of biological invasions under global change: a model-based framework. *Journal of Applied Ecology* 53, 1317-1329. <https://doi.org/10.1111/1365-2664.12631>