



8º CONGRESO FORESTAL ESPAÑOL

La **Ciencia forestal** y su contribución a
los **Objetivos de Desarrollo Sostenible**



8CFE

Edita: Sociedad Española de Ciencias Forestales

Cataluña | Catalunya - 27 junio | juny - 1 julio | juliol 2022

ISBN 978-84-941695-6-4

© Sociedad Española de Ciencias Forestales

Organiza



El papel de las fuentes de datos espaciales en la modelización de la disponibilidad del hábitat de carnívoros

CISNEROS ARAUJO, P.¹, GOICOLEA MARIN, T.¹, FERNÁNDEZ-LANDA, A², ALGEET ABARQUERO, N.², TOMÉ MORÁN J.L.², MARCHAMALO SACRISTÁN, M.³, MATEO-SÁNCHEZ M.C.¹, GASTÓN GONZÁLEZ, A.¹ y GARCÍA VIÑAS J.I.¹

¹ Universidad Politécnica de Madrid. ETS de Ingeniería de Montes, Forestal y del Medio Natural

² Agresta S. Coop.

³ Universidad Politécnica de Madrid. ETS de Ingeniería de Caminos, Canales y Puertos

Resumen

La oferta de datos espaciales es cada vez más diversa y variada sobre todo en cuanto a coste, disponibilidad geográfica y resolución (espacial y temporal) se refiere. Es importante considerar estas características en la selección de las variables medioambientales predictoras de los modelos de selección de hábitat, ya que determinan la calidad de las predicciones. En este estudio, evaluamos cómo las diferentes resoluciones espaciales, temáticas y temporales de los conjuntos de datos afectan a la capacidad predictiva de los modelos a múltiples escalas para poblaciones de oso pardo cantábrico y lince ibérico. Los resultados apoyan el uso de datos de teledetección globales (Sentinel) como fuentes de datos fiables para la modelización. Sin embargo, los modelos basados en fuentes de datos de ámbito europeo o nacional obtuvieron mejores resultados, posiblemente debido a la mayor resolución temática de estas fuentes de datos. En concreto, los datos LiDAR (PNOA) produjeron los mejores modelos debido a su alta resolución espacial y su capacidad para identificar diferentes tipos de hábitat en función de la estructura de la vegetación, lo cual permitió analizar en detalle las preferencias ecológicas de ambas especies. Nuestros resultados abogan por un uso combinado de fuentes de datos espaciales para la modelización de la selección de hábitat de carnívoros.

Palabras clave

Teledetección; conservación de la biodiversidad; LiDAR; Sentinel; especies amenazadas.

1. Introducción

La pérdida de biodiversidad es uno de los mayores desafíos a los que la conservación de la naturaleza se enfrenta actualmente. Para combatirla, científicos y administraciones realizan múltiples esfuerzos de conservación, muchos de los cuales se basan en los resultados obtenidos a través de la modelización estadística. Esto se debe a que los modelos son reconocidos como uno de los instrumentos más útiles e imparciales para guiar el diseño de planes y políticas de gestión y conservación. Entre ellos, los modelos de disponibilidad del hábitat y conectividad son especialmente útiles para la obtención de información espacialmente explícita que sirva para guiar las acciones de conservación (BELLAMY et al., 2020; BENNETT & MULONGOY, 2006; CIANFRANI et al., 2010; GUISAN et al., 2013; GURRUTXAGA & SAURA, 2014; TURNER et al., 1995). No obstante, es necesario que los datos usados por los modelos cuenten con una resolución espacial suficiente y que las variables ambientales sean correctamente seleccionadas para poder garantizar un rendimiento fiable (SCHWARTZ, 2012). Por ello, se ha realizado un esfuerzo considerable con el objetivo de aumentar la resolución espacial. En consecuencia, el uso de datos provenientes de la teledetección está cobrando relevancia debido a la alta resolución espacial que pueden ofrecer y a su amplia cobertura regional y disponibilidad temporal y espacial (ÁLVAREZ-MARTÍNEZ et al., 2018; PLUMMER, 2000; SKIDMORE et al., 2015).

Estudios previos acerca de los efectos del uso de diferentes fuentes de datos espaciales para la modelización de las relaciones especies-hábitat (CHUST et al., 2004; SEOANE et al., 2004; VENIER et al., 2004) obtuvieron resultados similares independientemente de las fuentes de datos utilizadas en los modelos. No obstante, obtuvieron ligeras variaciones en su rendimiento causadas por las diferentes resoluciones espaciales y temáticas (diversidad de clases categóricas en una capa espacial) de los conjuntos de datos. Otros estudios también respaldan esta idea al indicar un rendimiento mejorado de los modelos cuando se utilizan datos de teledetección de alta resolución (CAMATHIAS et al., 2013; SHEEHAN, 2017). Por ejemplo, la utilización de datos de teledetección y LiDAR puede mejorar el rendimiento de los modelos debido a su capacidad para informar acerca de la estructura de la vegetación y de los hábitats (GASTÓN et al., 2017; PETTORELLI et al., 2018; TATTINI et al., 2012). Igualmente, el uso de imágenes satélite de alta resolución espacial también produce buenos resultados en la modelización del hábitat (SHEEHAN, 2017). Sin embargo, estos datos espaciales pueden ser costosos (Quickbird, Pleiades, SPOT, Worldview, IKONOS) o pueden estar disponibles solo a escala nacional. Por ejemplo, LiDAR solo está disponible gratuitamente en algunos países como España, Dinamarca o Gran Bretaña. Como alternativa, algunas misiones de observación terrestre, como Sentinel y Landsat, ofrecen actualmente datos de alta resolución (ópticos y de radar) de manera gratuita y a escala global. En particular, las constelaciones Sentinel-1 y 2 tienen la ventaja de tener una cobertura global y un tiempo de revisita de seis y cinco días en el ecuador, respectivamente (FILIPPONI, 2019; GATTI & GALOPPO, 2018; LI & ROY, 2017). Estas propiedades permiten a los gestores de la naturaleza acceder a datos espaciales de su región de interés para poder estimar variables de biodiversidad basadas en la teledetección (PETTORELLI et al., 2016) y para poder caracterizar los usos del suelo y coberturas vegetales independientemente de su ubicación. Además, los gestores tienen la posibilidad de actualizar periódicamente sus resultados, lo que es beneficioso para el seguimiento de las medidas de conservación (O'CONNOR et al., 2015; ROSE et al., 2015). Otras alternativas incluyen los productos espaciales paneuropeos de *Copernicus Land Monitoring Services* (CLMS). Esta plataforma no ofrece datos para la totalidad del planeta, pero ofrece capas de alta resolución y mapas de coberturas vegetales de manera gratuita a escala europea, las cuales pueden ser una opción rentable para proyectos basados en este continente. Las capas en CLMS se derivan principalmente de imágenes satélite ópticas, especialmente de Sentinel-2 y Landsat-8. Entre las capas disponibles destaca el *Forest Type Product* (FTY) que proporciona una caracterización de la cubierta forestal en Europa (LANGANKE et al., 2017) y *Corine Land Cover* (CLC) que distingue hasta 44 tipos de usos del suelo mediante la fotointerpretación de imágenes satélite (BÜTTNER et al., 2017). A pesar de todas estas alternativas, se han realizado pocos estudios que comparan como diversas fuentes de datos espaciales que difieren en disponibilidad y cobertura afectan al rendimiento de los modelos de disponibilidad del hábitat.

2. Objetivos

Este estudio tiene como objetivo determinar si el rendimiento de los modelos de hábitat estimados en base a imágenes satélite globales y gratuitas puede equipararse al rendimiento de los modelos producidos en base a fuentes de datos espaciales restringidas regionalmente. Igualmente, se pretende demostrar la alta capacidad predictiva de los modelos de disponibilidad del hábitat basados en fuentes de datos espaciales a nivel nacional debido a su alta resolución espacial y temática.

3. Metodología

3.1. Oso pardo

Para el ajuste de los modelos de hábitat en primer lugar se utilizaron datos de presencia del oso pardo de las subpoblaciones oriental y occidental de la Cordillera Cantábrica recopilados entre 2000 y 2010 por observadores profesionales y guardabosques a través de observaciones directas y

evidencias indirectas incluyendo excrementos, huellas, ataques de colmenas y muestras del pelaje (detalles en MATEO-SÁNCHEZ et al., 2016). Los registros de presencia fueron unificados y remuestreados a un tamaño de píxel de 1 hectárea para mejorar el tiempo de procesamiento. En total, se obtuvieron 6207 ubicaciones de oso pardo para el ajuste de modelos de disponibilidad del hábitat.

Igualmente, se emplearon un total de seis variables ambientales para caracterizar (1) los recursos alimenticios del oso, el refugio (expresado mediante (2) la superficie forestal y (3) la rugosidad del terreno) y la presión antropogénica (expresada mediante (4) la densidad de edificios, (5) autopistas y (6) carreteras). Estudios previos han demostrado que este conjunto de variables ambientales predicen efectivamente la presencia del oso pardo en la Cordillera Cantábrica (GASTÓN et al., 2017; MATEO-SÁNCHEZ et al., 2016). Los recursos alimenticios y las variables del área forestal se obtuvieron de (1) un mapa de usos del suelo obtenido en base a datos de Sentinel-1 y 2 de 2016–2017 (SLCM) (MERCIER et al., 2019), (2) el Forest Type Product 2015 (LANGANKE et al., 2017) de CLMS, (3) el mapa CORINE Land Cover 2018 (BÜTTNER et al., 2017), (4) el Mapa Forestal de España (MITECO, 2006) (MFE; 1998–2007) y (5) datos LiDAR (2009–2012) del Plan Nacional de Ortofotografía Aérea de España (MITMA, 2015). Las variables de rugosidad del terreno y presión humana fueron constantes en todos los modelos y se derivaron de las mismas fuentes de datos.

Los datos espaciales de las fuentes anteriores se combinaron en tres conjuntos de datos según su cobertura espacial (global, continental o nacional), para producir las variables ambientales utilizadas como predictores de la disponibilidad del hábitat. No obstante, la extensión del análisis fue constante (es decir, la Cordillera Cantábrica) y los términos “global”, “continental” y “nacional” solo se utilizaron para indicar las características comunes del conjunto de datos en relación a la cobertura espacial, la disponibilidad de datos y la resolución temática, espacial y temporal. Por lo tanto, para el nivel global, se utilizó únicamente el SLCM. Mientras tanto, CLC18 y FTY se usaron de manera conjunta para el nivel continental, y LiDAR junto al MFE para el nivel nacional.

Las variables ambientales se volvieron a remuestrear a un tamaño de píxel de 1 hectárea para hacerla coincidir con la resolución espacial de los datos de presencia del oso. Se consideraron nueve escalas espaciales diferentes para cada variable. Cada escala representa el punto de vista y la reacción de un oso pardo al medio ambiente. Este gradiente ambiental es de particular relevancia para sus conocer los requerimientos de hábitat de la especie, ya que el oso pardo puede comportarse de manera diferente al seleccionar recursos en una escala a nivel de tesela o en escalas mayores a nivel de paisaje (MATEO SÁNCHEZ et al., 2014). Se calculó la media mediante ventanas móviles circulares con nueve radios diferentes (0,25, 0,5, 1, 2, 4, 8, 16, 32 y 64 km) aplicadas a cada variable y se estandarizaron todas las variables restando la media y dividiendo por la desviación estándar.

Estimamos la variable de recursos alimenticios del oso como la abundancia de especies de plantas (árboles, arbustos y herbáceas) ponderada por la importancia de cada especie en la dieta del oso pardo (para más detalles MATEO-SÁNCHEZ et al., 2016). La importancia se obtuvo de un informe anterior acerca de la dieta del oso pardo basado en muestreos de excrementos (MARQUÍNEZ et al., 2002). La abundancia se calculó de diferentes maneras dependiendo de la información disponible para cada conjunto de datos espaciales. Para el conjunto de datos nacional, se utilizó la información disponible en el MFE, que incluye la identificación de las especies arboladas, la fracción de cabida cubierta (FCC) y el porcentaje de abundancia para cada especie arbolada. Sin embargo, se reemplazó la FCC del MFE por la derivada de los datos LiDAR, la cual es más detallada debido a su alta resolución espacial (25 m). La abundancia de especies no arbóreas se estimó combinando información proveniente de inventarios florísticos, modelos de nichos ecológicos ajustados mediante regresión logística penalizada y basados en predictores climáticos y litológicos (GASTÓN & GARCÍA-VÍNAS, 2013), y conocimiento experto sobre la presencia potencial de especies vegetales específicas

dentro de comunidades vegetales identificadas por el MFE. Únicamente se utilizaron especies de plantas que son básicas para la dieta del oso pardo. Para los conjuntos de datos continentales y globales, se usaron las abundancias estimadas en (MARQUÍNEZ et al., 2002), pero adaptándolas para que se ajustasen a las clases del CLC18 y del SCLM mediante el promedio de los valores de abundancia originales de cada clase. Además, para el conjunto de datos continental, se reemplazaron las cubiertas forestales del CLC18 por las del FTY debido a su tamaño menor tamaño de pixel.

La superficie forestal y la rugosidad del terreno se usaron para representar el refugio del oso pardo siguiendo los métodos descritos en GASTÓN et al., 2017 y MATEO-SÁNCHEZ et al., 2016. La superficie forestal se estimó de manera ligeramente diferente para cada conjunto de datos. Para el conjunto de datos global, se obtuvo de la clase de bosque del SLCM. El FTY se usó para el conjunto de datos continental. Para el conjunto de datos nacional, para determinar los píxeles de bosque se utilizó un umbral del 10% de la FCC de los datos LiDAR que es el mismo umbral que se aplica al FTY (LANGANKE et al., 2017). La rugosidad del terreno (RILEY et al., 1999) se estimó a partir del Modelo Digital de Elevaciones de España a 25 m (MDT, MITMA, 2015).

Para estudiar la presión antropogénica, se usaron tres variables espaciales que representan los edificios y las infraestructuras de transporte presentes en el paisaje: la densidad de edificios, las autopistas y las carreteras convencionales. Los datos de edificios se obtuvieron del Mapa Topográfico Nacional a escala 1:25.000 (MTN25 2015; MITMA, 2015) y las infraestructuras de transporte de *Open Street Maps* (descargado de *OpenStreetMap*, 2015). Las infraestructuras de transporte se dividieron en carreteras convencionales y autopistas debido a sus diferentes volúmenes de tráfico y capacidades para limitar la distribución del oso pardo. Ambos capas vectoriales se rasterizaron con un tamaño de píxel de 100 m y se procesaron de la misma manera que las otras variables para el análisis multiescala.

Para ajustar los modelos de disponibilidad de hábitat, primero se estimaron modelos univariable, ajustando un modelo para cada combinación de variable ambiental, escala (radios de la ventana móvil circular) y conjunto de datos (global, continental y nacional). De esta manera, se pudo encontrar la escala operativa, que es aquella que correlaciona mejor con los datos de presencia de la especie (GRAND et al., 2004; MATEO-SÁNCHEZ et al., 2014, 2016). Se utilizaron las funciones *Irm* y *pretrace* del paquete *rms* R (HARRELL, 2019) para ajustar regresiones logísticas penalizadas usando cada escala de cada variable como único predictor y asumiendo una respuesta monótona. La variable binaria resultante se obtuvo combinando las presencias de la especie con 20.000 pseudoausencias generadas aleatoriamente dentro del área de estudio. El modelo con el mejor Akaike Information Criterion fue el seleccionado para cada variable (AIC; AKAIKE, 1973). La escala del modelo con mejor rendimiento se identificó como la escala operativa (es decir, la escala que mejor representa el patrón de selección de hábitat de la especie para cada variable). En segundo lugar, se utilizó cada variable ambiental en su escala operativa para ajustar modelos de disponibilidad de hábitat multivariable y multiescala para cada uno de los tres conjuntos de datos. Se calcularon modelos de regresión logística penalizados usando términos lineales y sin interacciones entre las variables predictoras, usando las funciones *Irm* y *pretrace* del paquete *rms*. Para estudiar la capacidad predictiva de cada uno de los tres modelos multivariable se empleó el área bajo la curva (AUC; FIELDING & BELL, 1997) obtenida mediante *10-fold cross-validation*. Posteriormente, se comprobó si las diferencias entre los valores de AUC de los modelos eran significativas estadísticamente mediante el test de DeLong (DELONG et al., 1988). Los valores de disponibilidad del hábitat predichos por cada modelo multiescala se proyectaron en tres mapas disponibilidad del hábitat (uno para cada conjunto de datos).

3.2. Lince Iberico.

Para el caso del lince ibérico, se modelizó la disponibilidad del hábitat para su movimiento debido al interés que existe para conocer mejor sus patrones de selección de hábitat durante fases dispersivas y así poder estudiar y comprender mejor la conectividad entre sus poblaciones. Para ello, se utilizaron 12,370 localizaciones de movimientos exploratorios de 57 linces obtenidas entre 2008 y 2015 y proporcionadas por el proyecto Life+IBERLINCE. Las localizaciones provienen de datos obtenidos mediante seguimiento con collares GPS y cuentan con 4-h de intervalo temporal entre localizaciones. El estudio se ha realizado en el sureste de España, en una superficie que ocupa 67.673 km² y que abarca la mayor parte de la distribución conocida del lince ibérico en España.

La selección de hábitat durante los movimientos exploratorios se estimó mediante *Point Selection Functions* (LALIBERTÉ & ST-LAURENT, 2020; PULLINGER & JOHNSON, 2010). Se calcularon un total de 5 modelos que varían según los datos espaciales utilizados para la estimación de hasta 19 variables predictoras. Los datos espaciales se obtuvieron de diferentes fuentes: (1) un mapa de coberturas del suelo de alta resolución (LCM, desarrollado en colaboración con Agresta Soc. Coop. utilizando imágenes satélite de Sentinel-2 y datos LiDAR); (2) datos LiDAR de FCC tanto para arbolado como matorral (MITMA, 2015); (3) CLC18; (4) la capa *Dominant Leaf Type* de CLMS; (5) la capa *Tree Cover Density* de CLMS; (6) una capa de pendientes obtenida a partir del MDT (MITMA, 2015); y (7) con una capa de carreteras obtenida a partir de datos de *OpenStreetMap*. Todas las variables utilizadas contaron con una resolución espacial de 25 m y se combinaron tal y como se puede observar en la Tabla 2 para obtener 5 modelos de preferencias del hábitat del lince ibérico diferentes. Para la modelización del hábitat se comparó el hábitat utilizado (seleccionado por los linces) y el disponible (alcanzable pero presumiblemente no seleccionado). El hábitat se caracterizó como la proporción de cada tipo de uso del suelo que cubre las áreas utilizadas y disponibles alrededor de cada ubicación GPS: El hábitat utilizado se corresponde con la proporción de cada tipo de cobertura en cada localización y sus ocho píxeles anejos (para considerar el error propio de las localizaciones GPS); y el hábitat disponible se estimó como el promedio ponderado por la distancia a la localización GPS de cada tipo de cobertura en una circunferencia alcanzable alrededor de dicha localización. El radio de esta circunferencia (5,72 km) se seleccionó a partir del percentil 99 de las distancias en línea recta entre cada par de puntos consecutivos. Este radio disponible representa la distancia máxima alcanzable en un intervalo de 4 h, omitiendo los valores atípicos. Los pesos se obtuvieron de una distribución generalizada de Pareto ajustada a la distribución empírica de las distancias de desplazamiento en 4 h (ZELLER et al., 2017), es decir, los píxeles más cercanos al punto GPS contaron con un mayor peso que los píxeles más lejanos. Usando una combinación de los datos mencionados, se ajustó un modelo de regresión logística condicional (ZELLER et al., 2016) para estimar la probabilidad de selección de hábitat con la función *glm* en R y usando los pastizales como la clase de uso del suelo de referencia. Para validar el rendimiento del modelo, se llevó a cabo i) una validación cruzada de *10-fold* (PEARCE & FERRIER, 2000) y ii) una validación cruzada espacial (ROBERTS et al., 2017). La capacidad predictiva del modelo se evaluó utilizando el AUC. Posteriormente, se usó el modelo para predecir probabilidad de selección de hábitat en toda el área de estudio del lince, generando una superficie ráster con la disponibilidad de cada píxel para ser utilizado por los linces en fases dispersivas.

4. Resultados

4.1. Oso pardo.

Las escalas operativas de las variables de vegetación seleccionadas por los modelos univariable fueron diferentes para cada modelo. Para los recursos alimenticios estas fueron similares entre los conjuntos de datos globales (0,5 km) y continentales (2 km), pero fueron significativamente diferentes al del nacional (16 km). La superficie forestal, por el contrario, las escalas operativas fueron similares para los tres conjuntos de datos: una variación de entre 0,5 y 1 km. La rugosidad del

terreno influyó a una escala relativamente pequeña de 2 km y todas las variables de presión antropogénica rindieron mejor a una escala de 16 km en los tres modelos (Tabla 1).

Tabla 1. Modelos de disponibilidad del hábitat del oso pardo para los tres conjuntos de datos resultantes de las diferentes fuentes de datos utilizadas para estimar las variables de vegetación (es decir, recursos alimenticios y superficie forestal).

*Las variables de presión humana y rugosidad del terreno son constantes en los tres modelos. “Escala” es la escala operativa (km) para cada variable ambiental y fuente de datos. Niveles de significancia: *<0,001.*

Variable	Global		Continental		Nacional	
	Escala	Coeficiente	Escala	Coeficiente	Escala	Coeficiente
Rec. Alimenticios	0.5	1.081*	2	0.547*	16	1.854*
Area Forestal	1	-0.512*	1	0.210*	0.5	0.400*
Rugosidad	2	1.048*	2	1.032*	2	0.982*
Edificios	16	-1.324*	16	-1.775*	16	-1.726*
Autopistas	16	-1.376*	16	-1.315*	16	-0.156
Carreteras	16	-2.004*	16	-1.580*	16	-0.523*
AUC (95% CI)	0.900 (0.896-0.904)		0.908 (0.904-0.911)		0.936 (0.933-0.939)	

Las variables de vegetación tuvieron un efecto positivo (Tabla 1) sobre la disponibilidad del hábitat en la mayoría de los casos, especialmente la variable de recursos alimenticios del conjunto de datos nacional. Junto con los recursos alimenticios, la rugosidad del terreno fue la variable ambiental que más afectó positivamente la disponibilidad del hábitat del oso pardo para todos los modelos. La superficie forestal influyó negativamente en el modelo global, mientras que fue ligeramente positiva en los modelos continental y nacional. En todos los casos, la relación de las variables de presión humana con la disponibilidad del hábitat fue desfavorable.

Todos los modelos mostraron una buena capacidad con altos valores de AUC (Tabla 1). El modelo nacional contaron con el AUC más alto (0.936) mientras que el más bajo fue el del modelo global (0.900). Los resultados del test de DeLong mostraron diferencias significativas entre los tres modelos (p -valor < 0,05). En general, el patrón espacial de las áreas con alta disponibilidad de hábitat fue muy similar entre los modelos global y continental, aunque con diferencias en su nitidez. Dos núcleos de alta disponibilidad se muestran en zonas coincidentes con el rango de distribución del oso pardo en el área de estudio. Ambos núcleos se encuentran separados por zonas de baja disponibilidad donde discurren dos vías principales (AP-66 y N-630; ver Figura 1). Para las predicciones del modelo global y continental, también se puede observar una alta disponibilidad hacia los bordes suroeste y sureste del área de estudio.

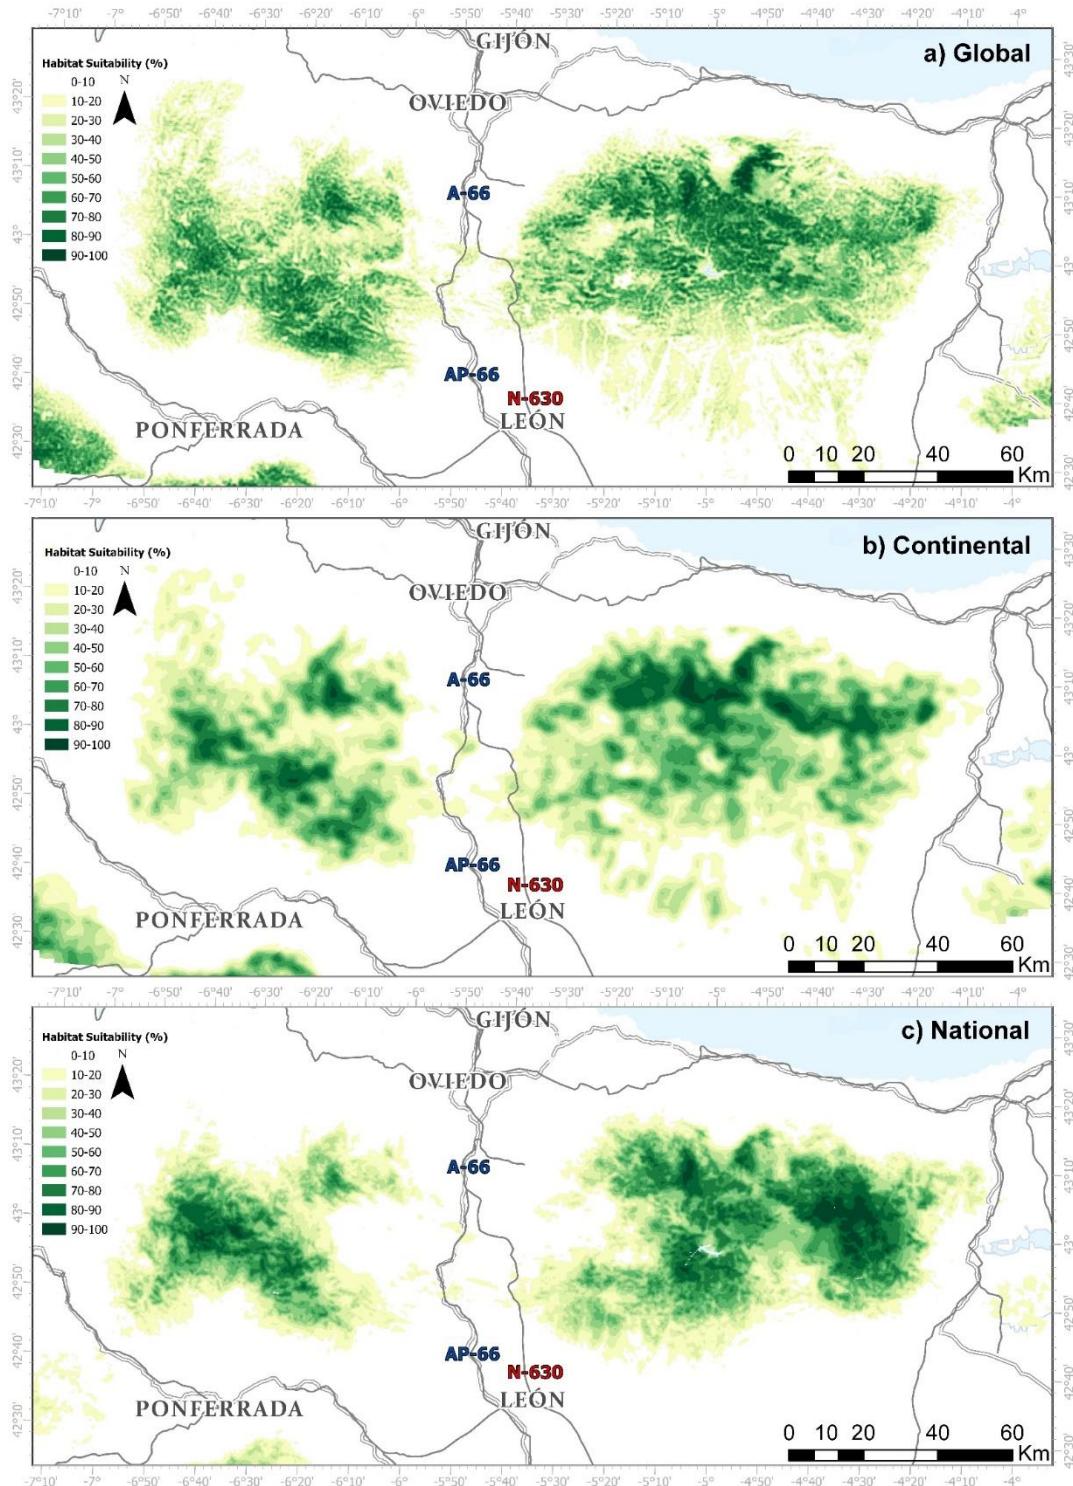


Figura 1. Mapas de disponibilidad del hábitat del oso pardo obtenidos a partir de modelos multivariable para cada conjunto de datos: (a) Conjunto de datos global (de imágenes Sentinel-1 y Sentinel-2), (b) Conjunto de datos continental (del mapa CORINE Land Cover 2018 en combinación con Forest Type Product de CLMS), y (c) Conjunto de datos nacional (MFE en combinación con LiDAR).

4.2. Lince Ibérico.

Todos los modelos de selección de hábitat obtuvieron una alta capacidad predictiva para discriminar entre el hábitat utilizado y el hábitat disponible para los movimientos dispersivos del lince (valores AUC estimados de 0,86 y 0,91 tanto mediante validación cruzada de *10-fold* como espacial). La Tabla 2 muestra los coeficientes de regresión para seleccionar cada clase de uso del suelo. Los matorrales (*shrublands*), los bosques abiertos (*broadleaved* y *coniferous*) y los olivares de montaña (*mountain groves*) fueron las clases preferidas durante el movimiento. Por otro lado, los linces en estado de movimiento exploratorio evitaron en su mayoría las áreas urbanas (*unsuitable*), las tierras de cultivo herbáceo (*extensive crops*) y las carreteras.

Tabla 2. Coeficientes de las variables para los modelos del lince ibérico. Los pastizales (*grasslands*) son la clase de cobertura del suelo de referencia y, por lo tanto, no tiene un coeficiente estimado ni un nivel de significancia. Niveles de significancia: * $<0,05$.

Variable (Nombres en base a CLC18)	Cartografía Base	LCM Agresta (Lidar)	CLC18			
	Cartografía Auxiliar	LiDAR (arbolado & matorral) + DLT	DLT	TCD + DLT	LiDAR (arb. & mat.) + DLT	LiDAR (arbolado) + DLT
Unsuitable		-5.96*	-7.64*	-7.69*	-7.07*	-8.05*
Carreteras de alta densidad		-29.64*	-49.62*	-49.44*	-37.08*	-39.10*
Carreteras de baja densidad		-50.82*	-55.44*	-55.07*	-48.36*	-48.27*
Intensive crops		-3.76*	-5.95*	-5.96*	-5.53*	-6.41*
Lowland Groves (MDT)		1.62*	0.08	0.06	0.77*	-0.03
Mountain Groves (MDT)		2.31*	1.22*	1.19*	2.01*	1.21*
Extensive crops		-2.58*	-2.18*	-2.19*	-1.59*	-2.32*
Crops mix. Natural veg.			-1.16*	-1.08*	-0.35	-1.09*
Agroforestry			0.76*	0.72*	1.55*	0.73*
Grasslands (clase de referencia)						
Shrublands		3.06*	1.23*	1.08*	2.48*	1.25*
Transitional Woodlands			1.09*			
Broadleaved 5-25%fcc		1.97*	0.96*	0.88*	2.16*	1.36*
Broadleaved 25-50%fcc		2.05*		1.29*	1.76*	1.00*
Broadleaved 50-75%fcc		1.89*		0.90*	1.59*	0.78*

Broadleaved 75-100%fcc	0.29*		1.68*	-0.65	-1.49
Coniferous 5-25%fcc	2.75*	0.18	-13.22*	2.67*	1.87*
Coniferous 25-50%fcc	1.69*		1.34*	1.20*	0.29
Coniferous 50-75%fcc	0.69		0.38*	0.39	-0.43
Coniferous 75-100%fcc	0.02		-0.81*	-0.50	-1.31*
AUC 10-fold	89.49%	90.58%	90.40%	88.63%	88.73%
AUC Cross-Val. Espacial	87.50%	86.63%	86.11%	86.08%	86.23%

5. Discusión

La elección de la fuente de datos espaciales es un paso importante para la modelización de la disponibilidad del hábitat, ya que la resolución de los datos es un factor clave para la caracterización del paisaje que influye profundamente en la naturaleza de los resultados (LECHNER & RHODES, 2016; LIANG et al., 2013). En consecuencia, nuestros resultados mostraron resultados similares pero también divergencias significativas a la hora de modelizar la disponibilidad del hábitat utilizando diferentes fuentes de datos.

Nuestros resultados mostraron rendimientos similares tanto para los tres modelos de disponibilidad del hábitat del oso pardo como para los 5 modelos del lince ibérico, lo que sugiere que las imágenes Sentinel-1 y 2 y los productos paneuropeos CLMS son alternativas sólidas para la modelización de la disponibilidad del hábitat. Para el caso del oso pardo, pese a las pequeñas diferencias en las puntuaciones de AUC, los mapas de disponibilidad del hábitat reflejaron patrones espaciales análogos de las zonas de alta disponibilidad de hábitat y los tres modelos predijeron correctamente el rango de distribución del oso en la Cordillera Cantábrica. Para el caso del lince ibérico, todos los modelos obtuvieron valores de AUC muy similares lo que indica una buena capacidad predictiva en todos los casos. Este hecho sugiere igualmente que los mapas de usos del suelo obtenidos en base a imágenes satélites de Sentinel-2 tienen un alto potencial para la modelización del hábitat que es por lo menos equiparable al de otros mapas de usos del suelo populares en Europa como es Corine Land Cover. De la misma manera, las capas de alta resolución espacial de CLMS (*Dominant Leaf Type* y *Tree Cover Density*) también son capaces de proporcionar resultados excelentes en la modelización del hábitat obteniendo rendimientos similares a LiDAR ya que permiten una buena caracterización de las variables de vegetación.

Los datos de alta resolución espacial incluidos en cada modelo (Sentinel-1 y 2, DLT, TCD, FTY y LiDAR) pueden ser la causa principal detrás de los buenos resultados, ya que un menor tamaño de pixel hace que las clases de cobertura vegetal sean más fácilmente diferenciables por el modelo (GOTTSCHALK et al., 2011; ZELLER et al., 2017). La alta resolución espacial propició la selección de escalas operativas pequeñas (0,5–1 km) para la superficie forestal en los tres modelos del oso pardo y permitió la identificación precisa de zonas aisladas y teselas de alta disponibilidad en entornos heterogéneos como son ambas zonas de estudio (GASTÓN et al., 2017). Sin embargo, la delimitación de áreas de alta disponibilidad no tiene un patrón detallado en los mapas de los modelos continentales y nacionales del oso. Esto podría deberse al CLC18 y el FMS, ya que su mayor escala (MMU de 25 y 2,25 ha, respectivamente) puede haber afectado el detalle de los resultados.

Es importante mencionar, que para igualar la resolución de los datos de las presencias de oso pardo, las variables ambientales se remuestrearon a 1 ha, aumentando el tamaño de píxel disponible de algunas capas (por ejemplo, de LiDAR, FTY y SLCM). Las ubicaciones de los osos pardos tuvieron que remuestrearse a 1 ha para evitar la pseudoreplicación, ya que el mismo individuo podría haber causado múltiples rastros. La disponibilidad de datos de seguimiento GPS evita este problema y mejora la precisión de las presencias, permitiendo utilizar las variables ambientales con su mejor resolución espacial, como ocurre en el caso del lince. Sin embargo, en la mayoría de los casos, las preferencias de hábitat del oso pardo están más influenciadas por mayores escalas operativas y no por la escala más detallada disponible de 250 m (Tabla 1). A pesar de las escalas operativas, la alta resolución espacial de las capas influyó en cómo se caracterizó la configuración del paisaje, considerando pequeñas teselas de hábitat y elementos del paisaje que habrían sido ignorados con resoluciones espaciales de menos detalle antes del remuestreo. De la misma manera, la alta resolución espacial de los datos espaciales usados en los modelos del lince ibérico permitió la identificación de elementos del paisaje que operan a una escala reducida, lo que repercutió en la buena calidad predictiva obtenida en los modelos.

La resolución temática puede explicar las diferencias entre la capacidad predictiva de los modelos del oso, ya que se observó un mejor rendimiento cuando sus conjuntos de datos espaciales permitieron clasificar más tipos de vegetación (LIANG et al., 2013; SEOANE et al., 2004). Por ejemplo, la identificación de múltiples tipos de vegetación incluidos en el modelo nacional (debido al MFE) permitió caracterizar importantes fuentes de alimentos para el oso pardo, en comparación con el SLCM que solo clasificó una sola clase de bosque. La mejor resolución temática del conjunto de datos nacionales también puede explicar las diferentes escalas operativas seleccionadas para la variable de recursos alimenticios.

Las imprecisiones presentes en las capas de entrada también podrían producir rendimientos más bajos en los modelos continentales y globales del oso. Tanto el FTY (precisión mínima de 0,90) (LANGANKE et al., 2017) como las capas SLCM (índice kappa de 0,89) (MERCIER et al., 2019) obtuvieron una alta precisión. Sin embargo, también es posible observar algunas clasificaciones erróneas, especialmente en el SLCM. Para este caso concreto, las pendientes pronunciadas afectaron negativamente a los datos de Sentinel-1, produciendo errores de clasificación en áreas montañosas donde abundan recursos naturales que son vitales para el oso pardo. Más clasificaciones erróneas pueden observarse también entre las superficies boscosas y de matorral, ambas importantes para la definición de recursos alimenticios del oso (MERCIER et al., 2019). Estas imprecisiones podrían explicar la influencia negativa de la superficie forestal en el modelo global (Tabla 1), pues en este modelo algunas zonas que son aptas para el oso no se caracterizaron correctamente como bosque. Sentinel-1 permite mapear variables de vegetación independientemente de la cobertura por nubes que limita la calidad de las imágenes ópticas de satélite (CLERICI et al., 2017), pero se deben abordar los posibles problemas derivados de su uso en paisajes montañosos (BAYANUDIN & JATMIKO, 2016).

Los resultados mostrados en este estudio respaldan el potencial de las imágenes satélite para predecir las preferencias de hábitat de las especies en paisajes heterogéneos (NIEDBALLA et al., 2015; VENIER et al., 2004). Sin embargo, esto puede no ser apropiado para todas las circunstancias. Los conjuntos de datos globales y continentales considerados en este estudio podrían ser más adecuados para caso de estudio de especies con requerimientos ecológicos a grandes escalas, ya que es posible que no se alcance un suficiente detalle para identificar una amplia variedad de recursos naturales, lo que puede ser importante para comprender las preferencias de hábitat de las especies a pequeña escala (MATEO-SÁNCHEZ et al., 2016; NIELSEN et al., 2010; RECHSTEINER et al., 2017). Para intentar comprender relaciones específicas entre hábitat y especies, se deben utilizar datos que enriquezcan la resolución temática (MARTIN et al., 2013) y que complementen la alta resolución espacial de las variables de vegetación tal y como se demuestra en los modelos del lince. Para este propósito, las fuentes de datos de sensores remotos gratuitos, como el reciente LiDAR de la

NASA, pueden ser útiles para informar sobre la estructura vertical y horizontal de la vegetación (PETTORELLI et al., 2016).

Igualmente, si hay varias fuentes de datos disponibles, nuestros resultados abogan por la fuente de datos con la resolución espacial y temática más alta. No obstante, la disponibilidad regional de los datos espaciales puede limitar la elección de la fuente de datos, que en la mayoría de los casos estaría restringida a datos provenientes de imágenes satélite, como aquellos provenientes de Sentinel-1 y 2. Sin embargo, la resolución temporal de los datos también puede ser esencial, especialmente para estudios dinámicos de hábitat (BISHOP-TAYLOR et al., 2018). Las variables de vegetación obtenidas a partir de teledetección por satélite ofrecen una gran ventaja, ya que pueden actualizarse regularmente con una alta frecuencia: 5 a 6 días de intervalos de tiempo de revisita promedio para los sensores Sentinel en el ecuador (FILIPPONI, 2019; LI & ROY, 2017). A pesar de derivarse de datos satelitales, los productos de CLMS no ofrecen actualizaciones frecuentes: cada 6 años para Corine Land Cover y cada 3 años para FTY. Este período puede ser incluso mayor para los datos restringidos a nivel nacional; Por ejemplo, los datos del LiDAR español se actualizan aproximadamente cada 7 años, mientras que el MFE aún no se ha actualizado. En consecuencia, la resolución temporal favorecería la elección de imágenes satélite para modelizar procesos ecológicos cuando el factor temporal es importante. Adicionalmente, la combinación de datos satelitales con otras fuentes de datos puede ser recomendable para compensar las limitaciones que pueden tener los datos espaciales (PETTORELLI et al., 2016). No obstante, el procesado de imágenes satélite requiere una gran experiencia y mucho esfuerzo para caracterizar las variables ambientales correctamente. Esta limitación favorece la elección de cartografía ya procesada, tal y como los productos de CLCS, que permiten a los gestores concentrarse casi directamente en el proceso de modelización (BEKER et al., 2019).

6. Conclusiones

Los resultados de este estudio respaldan el uso de las imágenes satélite gratuitas como una fuente global y perfectamente válida para estimar variables de vegetación para la modelización de la disponibilidad del hábitat. Los productos de cobertura terrestre ya procesados (como los de CLMS) también son una alternativa eficaz para los estudios centrados en el continente europeo. Por lo tanto, las fuentes de datos disponibles a nivel global son adecuadas para producir resultados significativos que guíen el correcto diseño de medidas de conservación y planes de gestión de la naturaleza. Sin embargo, es necesario tener en cuenta algunas consideraciones en función de la resolución espacial, temporal y temática requerida. Los datos satelitales disponibles a nivel mundial tienen la ventaja de que se actualizan con frecuencia, pero exigen un alto esfuerzo para su procesado y pueden requerir mucho tiempo y una computación intensiva para su obtención. Los datos satelitales también pueden no ofrecer la información suficiente como para comprender asociaciones entre especies y sus hábitats de manera precisa, lo que requiere una alta resolución temática y espacial. Por esta razón, se debe intentar mejorar la resolución temática de las variables de vegetación provenientes de fuentes de datos espaciales a nivel global. Esto se puede lograr mediante la combinación de sensores y otras fuentes de datos espaciales de acceso gratuito. La comparación presentada por este estudio ofrece información valiosa para comprender mejor las posibles implicaciones, sesgos y limitaciones que tiene la selección de fuentes de datos espaciales sobre los resultados de los modelo de disponibilidad del hábitat, lo que es clave para una correcta definición de las medidas de conservación.

7. Agradecimientos

Agradecemos a Santiago Saura, Carlos Ciudad y Jorge Cuevas, por su trabajo en estudios previos sobre el hábitat y la conectividad del oso pardo que son la base del presente trabajo. También agradecemos al Plan Nacional de Ortofotografía Aérea (PNOA-IGN), a la Fundación Oso Pardo y a las

Administraciones Autonómicas implicadas en la gestión del oso pardo por facilitarnos los datos (Junta de Castilla y León, Gobierno de Cantabria, Principado de Asturias y Xunta de Galicia). Agradecemos las localizaciones de especies facilitadas por el proyecto Life+IBERLINCE. También agradecemos la financiación de la Universidad Politécnica de Madrid, y el proyecto WOODNET.

8. Bibliografía

- AKAIKE, H. (1973). Information theory and an extension of the maximum likelihood principle. In B. Petrov & F. Csáki (Eds.), *Proc. 2nd Int. Symp. Information Theory* (pp. 267–281). Akadémiai Kiadó.
- ÁLVAREZ-MARTÍNEZ, J. M., JIMÉNEZ-ALFARO, B., BARQUÍN, J., ONDIVIELA, B., RECIO, M., SILIÓ-CALZADA, A., & JUANES, J. A. (2018). Modelling the area of occupancy of habitat types with remote sensing. *Methods in Ecology and Evolution*, 9(3), 580–593. <https://doi.org/10.1111/2041-210X.12925>
- BAYANUDIN, A. A., & JATMIKO, R. H. (2016). Orthorectification of Sentinel-1 SAR (Synthetic Aperture Radar) Data in Some Parts Of South- eastern Sulawesi Using Sentinel-1 Toolbox Orthorectification of Sentinel-1 SAR (Synthetic Aperture Radar) Data in Some Parts Of South- eastern Sulawesi Using S. *IOP Conference Series: Earth and Environmental Science*, 47(1), 012007. <https://doi.org/10.1088/1755-1315/47/1/012007>
- BEKER, T., ORLOVIĆ, S., & STOJANOVIĆ, D. B. (2019). Overview of Free Open Source Global Forest Species Data for Biogeographic Modeling. 59–70.
- BELLAMY, C., BOUGHEY, K., HAWKINS, C., REVELEY, S., SPAKE, R., WILLIAMS, C., & ALTRINGHAM, J. (2020). A sequential multi-level framework to improve habitat suitability modelling. *Landscape Ecology*, 0123456789. <https://doi.org/10.1007/s10980-020-00987-w>
- BENNETT, G., & MULONGOY, K. J. (2006). Review of experience with ecological networks, corridors and buffer zones. In *CBD Technical Series* (Vol. 23).
- BISHOP-TAYLOR, R., TULBURE, M. G., & BROICH, M. (2018). Evaluating static and dynamic landscape connectivity modelling using a 25-year remote sensing time series. *Landscape Ecology*, 33(4), 625–640. <https://doi.org/10.1007/s10980-018-0624-1>
- BÜTTNER, G., KOSZTRA, B., SOUKUP, T., SOUSA, A., & LANGANKE, T. (2017). *Final CLC2018 Technical Guidelines*.
- CAMATHIAS, L., BERGAMINI, A., KÜCHLER, M., STOFER, S., & BALTENSWEILER, A. (2013). High-resolution remote sensing data improves models of species richness. *Applied Vegetation Science*, 16(4), 539–551. <https://doi.org/10.1111/avsc.12028>
- CHUST, G., PRETUS, J. L., DUCROT, D., & VENTURA, D. (2004). Scale dependency of insect assemblages in response to landscape pattern. *Landscape Ecology*, 19(1), 41–57. <https://doi.org/10.1023/B:LAND.0000018368.99833.f2>

CIANFRANI, C., LE LAY, G., HIRZEL, A. H., & LOY, A. (2010). Do habitat suitability models reliably predict the recovery areas of threatened species? *Journal of Applied Ecology*, 47(2), 421–430. <https://doi.org/10.1111/j.1365-2664.2010.01781.x>

CLERICI, N., VALBUENA CALDERÓN, C. A., & POSADA, J. M. (2017). Fusion of sentinel-1a and sentinel-2A data for land cover mapping: A case study in the lower Magdalena region, Colombia. *Journal of Maps*, 13(2), 718–726.
<https://doi.org/10.1080/17445647.2017.1372316>

DELONG, E. R., DELONG, D. M., & CLARKE-PEARSON, D. L. (1988). Comparing the Areas under Two or More Correlated Receiver Operating Characteristic Curves : A Nonparametric Approach. Published by: International Biometric Society Stable. *Biometrics*, 44(3), 837–845.

FIELDING, A. H., & BELL, J. F. (1997). A review of methods for the assessment of prediction errors in conservation presence/absence models. *Environmental Conservation*, 24(1), 38–49. <https://doi.org/10.1017/S0376892997000088>

FILIPPONI, F. (2019). Sentinel-1 GRD Preprocessing Workflow. *Proceedings*, 18(1), 11.
<https://doi.org/10.3390/ecrs-3-06201>

GASTÓN, A., CIUDAD, C., MATEO-SÁNCHEZ, M. C., GARCÍA-VIÑAS, J. I., LÓPEZ-LEIVA, C., FERNÁNDEZ-LANDA, A., MARCHAMALO, M., CUEVAS, J., DE LA FUENTE, B., FORTIN, M. J., & SAURA, S. (2017). Species' habitat use inferred from environmental variables at multiple scales: How much we gain from high-resolution vegetation data? *International Journal of Applied Earth Observation and Geoinformation*, 55, 1–8.
<https://doi.org/10.1016/j.jag.2016.10.007>

GASTÓN, A., & GARCÍA-VIÑAS, J. I. (2013). Evaluating the predictive performance of stacked species distribution models applied to plant species selection in ecological restoration. *Ecological Modelling*, 263, 103–108. <https://doi.org/10.1016/j.ecolmodel.2013.04.020>

GATTI, A., & GALOPPO, A. (2018). *Sentinel-2 Products Specification Document*. 1–487.
<https://sentinel.esa.int/documents/247904/685211/Sentinel-2-Products-Specification-Document>

GOTTSCHALK, T. K., AUE, B., HOTES, S., & EKSCHMITT, K. (2011). Influence of grain size on species-habitat models. *Ecological Modelling*, 222(18), 3403–3412.
<https://doi.org/10.1016/j.ecolmodel.2011.07.008>

GRAND, J., BUONACCORSI, J., CUSHMAN, S. A., GRIFFIN, C. R., & NEEL, M. C. (2004). A Multiscale Landscape Approach to Predicting Bird and Moth Rarity Hotspots in a Threatened Pitch Pine-Scrub Oak Community. *Conservation Biology*, 18(4), 1063–1077.
<https://onlinelibrary.wiley.com/doi/abs/10.1111/j.1523-1739.2004.00555.x>

GUISAN, A., TINGLEY, R., BAUMGARTNER, J. B., NAUJOKAITIS-LEWIS, I., SUTCLIFFE, P. R., TULLOCH, A. I. T., REGAN, T. J., BROTONS, L., MCDONALD-MADDEN, E., MANTYKA-PRINGLE, C., MARTIN, T. G., RHODES, J. R., MAGGINI, R., SETTERFIELD, S. A., ELITH, J., SCHWARTZ, M. W., WINTLE, B. A., BROENNIMANN, O., AUSTIN, M., ... BUCKLEY, Y. M. (2013). Predicting

species distributions for conservation decisions. *Ecology Letters*, 16(12), 1424–1435.
<https://doi.org/10.1111/ele.12189>

GURRUTXAGA, M., & SAURA, S. (2014). Prioritizing highway defragmentation locations for restoring landscape connectivity. *Environmental Conservation*, 41(2), 157–164.
<https://doi.org/10.1017/S0376892913000325>

HARRELL, F. E. (2019). Regression Modeling Strategies. In *Springer*.
<https://link.springer.com/content/pdf/10.1007/978-3-319-19425-7.pdf>

LALIBERTÉ, J., & ST-LAURENT, M. H. (2020). Validation of functional connectivity modeling: The Achilles' heel of landscape connectivity mapping. *Landscape and Urban Planning*, 202(May 2019), 103878. <https://doi.org/10.1016/j.landurbplan.2020.103878>

LANGANKE, T., MORAN, A., DULLECK, B., & SCHLEICHER, C. (2017). *Copernicus Land Monitoring Service–High Resolution Layer Water and Wetness Product Specifications Document*. Copernicus Land Monitoring Service –%OAHig Resolution Layer Forest Product Specifications%OAland.copernicus.eu

LECHNER, A. M., & RHODES, J. R. (2016). Recent Progress on Spatial and Thematic Resolution in Landscape Ecology. *Current Landscape Ecology Reports*, 1(2), 98–105.
<https://doi.org/10.1007/s40823-016-0011-z>

LI, J., & ROY, D. P. (2017). A global analysis of Sentinel-2a, Sentinel-2b and Landsat-8 data revisit intervals and implications for terrestrial monitoring. *Remote Sensing*, 9(9).
<https://doi.org/10.3390/rs9090902>

LIANG, Y., HE, H. S., FRASER, J. S., & WU, Z. W. (2013). Thematic and Spatial Resolutions Affect Model-Based Predictions of Tree Species Distribution. *PLoS ONE*, 8(7), 1–10.
<https://doi.org/10.1371/journal.pone.0067889>

MARQUÍNEZ, J., GARCÍA, P., NORES, C., LASTRA, J., VARELA, M., & MARTÍNEZ, R. (2002). *Delimitación de áreas críticas para el oso pardo y cartografía de la calidad de hábitat*.

MARTIN, Y., VAN DYCK, H., DENDONCKER, N., & TITEUX, N. (2013). Testing instead of assuming the importance of land use change scenarios to model species distributions under climate change. *Global Ecology and Biogeography*, 22((11)), 1204–1216.

MATEO-SÁNCHEZ, M. C., CUSHMAN, S. A., & SAURA, S. (2014). Connecting endangered brown bear subpopulations in the Cantabrian Range (north-western Spain). *Animal Conservation*, 17(5), 430–440. <https://doi.org/10.1111/acv.12109>

MATEO-SÁNCHEZ, M. C., GASTÓN, A., CIUDAD, C., GARCÍA-VIÑAS, J. I., CUEVAS, J., LÓPEZ-LEIVA, C., FERNÁNDEZ-LANDA, A., ALGEET-ABARQUERO, N., MARCHAMALO, M., FORTIN, M. J., & SAURA, S. (2016). Seasonal and temporal changes in species use of the landscape: how do they impact the inferences from multi-scale habitat modeling? *Landscape Ecology*, 31(6), 1261–1276. <https://doi.org/10.1007/s10980-015-0324-z>

MATEO SÁNCHEZ, M. C., CUSHMAN, S. A., & SAURA, S. (2014). Scale dependence in habitat selection: the case of the endangered brown bear (*Ursus arctos*) in the Cantabrian Range (NW Spain). *International Journal of Geographical Information Science*, 28(8), 1531–1546. <https://doi.org/10.1080/13658816.2013.776684>

MERCIER, A., BETBEDER, J., RUMIANO, F., BAUDRY, J., GOND, V., BLANC, L., BOURGOIN, C., CORNU, G., CIUDAD, C., MARCHAMALO, M., POCCARD-CHAPUIS, R., & HUBERT-MOY, L. (2019). Evaluation of Sentinel-1 and 2 time series for land cover classification of forest-agriculture mosaics in temperate and tropical landscapes. *Remote Sensing*, 11(8), 979. <https://www.mdpi.com/2072-4292/11/8/979>

MITECO. (2006). *Mapa Forestal De España 1:50.000 (MFE50)*. <https://www.miteco.gob.es/es/biodiversidad/servicios/banco-datos-naturaleza/informacion-disponible/mfe50.aspx>
MITMA. (2015). *Centro Nacional de Descargas*. <http://centrodedescargas.cnig.es/>

NIEDBALLA, J., SOLLMANN, R., MOHAMED, A. BIN, BENDER, J., & WILTING, A. (2015). Defining habitat covariates in camera-trap based occupancy studies. *Scientific Reports*, 5, 1–10. <https://doi.org/10.1038/srep17041>

NIELSEN, S. E., MCDERMID, G., STENHOUSE, G. B., & BOYCE, M. S. (2010). Dynamic wildlife habitat models: Seasonal foods and mortality risk predict occupancy-abundance and habitat selection in grizzly bears. *Biological Conservation*, 143(7), 1623–1634. <https://doi.org/10.1016/j.biocon.2010.04.007>

O'CONNOR, B., SECADES, C., PENNER, J., SONNENSCHEIN, R., SKIDMORE, A., BURGESS, N. D., & HUTTON, J. M. (2015). Earth observation as a tool for tracking progress towards the Aichi Biodiversity Targets. *Remote Sensing in Ecology and Conservation*, 1(1), 19–28. <https://doi.org/10.1002/rse2.4>
OpenStreetMap. (2015). www.openstreetmap.org

PEARCE, J., & FERRIER, S. (2000). Evaluating the predictive performance of habitat models developed using logistic regression. *Ecological Modelling*, 133(3), 225–245. [https://doi.org/10.1016/S0304-3800\(00\)00322-7](https://doi.org/10.1016/S0304-3800(00)00322-7)

PETTORELLI, N., SCHULTE TO BÜHNE, H., TULLOCH, A., DUBOIS, G., MACINNIS-NG, C., QUEIRÓS, A. M., KEITH, D. A., WEGMANN, M., SCHRODT, F., STELLMES, M., SONNENSCHEIN, R., GELLER, G. N., ROY, S., SOMERS, B., MURRAY, N., BLAND, L., GEIJZENDORFFER, I., KERR, J. T., BROSZEIT, S., ... NICHOLSON, E. (2018). Satellite remote sensing of ecosystem functions: opportunities, challenges and way forward. *Remote Sensing in Ecology and Conservation*, 4(2), 71–93. <https://doi.org/10.1002/rse2.59>

PETTORELLI, N., WEGMANN, M., SKIDMORE, A., MÜCHER, S., DAWSON, T. P., FERNANDEZ, M., LUCAS, R., SCHAEPMAN, M. E., WANG, T., O'CONNOR, B., JONGMAN, R. H. G., KEMPENEERS, P., SONNENSCHEIN, R., LEIDNER, A. K., BÖHM, M., HE, K. S., NAGENDRA, H., DUBOIS, G., FATOYINBO, T., ... GELLER, G. N. (2016). Framing the concept of satellite remote sensing essential biodiversity variables: challenges and future directions. *Remote Sensing in Ecology and Conservation*, 2(3), 122–131. <https://doi.org/10.1002/rse2.15>

PLUMMER, S. E. (2000). Perspectives on combining ecological process models and remotely sensed data. *Ecological Modelling*, 129(2–3), 169–186. [https://doi.org/10.1016/S0304-3800\(00\)00233-7](https://doi.org/10.1016/S0304-3800(00)00233-7)

PULLINGER, M. G., & JOHNSON, C. J. (2010). Maintaining or restoring connectivity of modified landscapes: Evaluating the least-cost path model with multiple sources of ecological information. *Landscape Ecology*, 25(10), 1547–1560. <https://doi.org/10.1007/s10980-010-9526-6>

RECHSTEINER, C., ZELLWEGER, F., GERBER, A., BREINER, F. T., & BOLLMANN, K. (2017). Remotely sensed forest habitat structures improve regional species conservation. *Remote Sensing in Ecology and Conservation*, 3(4), 247–258. <https://doi.org/10.1002/rse2.46>

RILEY, S. J., DE GLORIA, S. D., & ELLIOT, R. (1999). A Terrain Ruggedness that Quantifies Topographic Heterogeneity. *Intermountain Journal of Sciences*, 5(1–4), 23–27.

ROBERTS, D. R., BAHN, V., CIUTI, S., BOYCE, M. S., ELITH, J., GUILLERA-ARROITA, G., HAUENSTEIN, S., LAHOZ-MONFORT, J. J., SCHRÖDER, B., THUILLER, W., WARTON, D. I., WINTLE, B. A., HARTIG, F., & DORMANN, C. F. (2017). Cross-validation strategies for data with temporal, spatial, hierarchical, or phylogenetic structure. *Ecography*, 40(8), 913–929. <https://doi.org/10.1111/ecog.02881>

ROSE, R. A., BYLER, D., EASTMAN, J. R., FLEISHMAN, E., GELLER, G., GOETZ, S., GUILD, L., HAMILTON, H., HANSEN, M., HEADLEY, R., HEWSON, J., HORNING, N., KAPLIN, B. A., LAPORTE, N., LEIDNER, A., LEIMGRUBER, P., MORISSETTE, J., MUSINSKY, J., PINTEA, L., ... WILSON, C. (2015). Ten ways remote sensing can contribute to conservation. *Conservation Biology*, 29(2), 350–359. <https://doi.org/10.1111/cobi.12397>

SCHWARTZ, M. W. (2012). Using niche models with climate projections to inform conservation management decisions. In *Biological Conservation* (Vol. 155, pp. 149–156). Elsevier. <https://doi.org/10.1016/j.biocon.2012.06.011>

SEOANE, J., BUSTAMANTE, J., & DÍAZ-DELGADO, R. (2004). Are existing vegetation maps adequate to predict bird distributions? *Ecological Modelling*, 175(2), 137–149. <https://doi.org/10.1016/j.ecolmodel.2003.10.011>

SHEEHAN, J. (2017). *The Utility of Fine-Scale Remote Sensing Data for Modeling Habitat Characteristics and Breeding Bird Species Distributions in an Appalachian Mature Deciduous*. <http://search.proquest.com/openview/f89e444ec61ff71092f73748fc9bf0a1/1?pq-origsite=gscholar&cbl=18750&diss=y>

SKIDMORE, A., PETTORELLI, N., COOPS, N. C., GELLER, G. N., HANSEN, M., LUCAS, R., MÜCHER, C. A., O'CONNOR, B., PAGANINI, M., PEREIRA, H. M., SCHAEPMAN, M. E., TURNER, W., WANG, T., & WEGMANN, M. (2015). Agree on biodiversity metrics to track from space. *Nature*, 523(7561), 403–406.

TATTONI, C., RIZZOLLI, F., & PEDRINI, P. (2012). Can LiDAR data improve bird habitat suitability models? *Ecological Modelling*, 245, 103–110.

<https://doi.org/10.1016/j.ecolmodel.2012.03.020>

TURNER, M. G., ARTHAUD, G. J., ENGSTROM, R. T., HEJL, S. J., LIU, J., LOEB, S., & MCKELVEY, K. (1995). Usefulness of spatially explicit population models in land management. *Ecological Applications*, 5(1), 12–16. <https://doi.org/10.2307/1942046>

VENIER, L. A., PEARCE, J., MCKEE, J. E., MCKENNEY, D. W., & NIEMI, G. J. (2004). Climate and satellite-derived land cover for predicting breeding bird distribution in the Great Lakes Basin. *Journal of Biogeography*, 31(2), 315–331. <https://doi.org/10.1046/j.0305-0270.2003.01014.x>

ZELLER, K. A., MCGARIGAL, K., CUSHMAN, S. A., BEIER, P., VICKERS, T. W., & BOYCE, W. M. (2016). Using step and path selection functions for estimating resistance to movement: pumas as a case study. *Landscape Ecology*, 31(6), 1319–1335.
<https://doi.org/10.1007/s10980-015-0301-6>

ZELLER, K. A., MCGARIGAL, K., CUSHMAN, S. A., BEIER, P., VICKERS, T. W., & BOYCE, W. M. (2017). Sensitivity of resource selection and connectivity models to landscape definition. *Landscape Ecology*, 32(4), 835–855. <https://doi.org/10.1007/s10980-017-0489-8>