



**MEMORIA DE ACTUACIÓN.
DESCRIPCIÓN DE LAS
ACTIVIDADES REALIZADAS
DENTRO DEL PROYECTO:**

**“Búsqueda de Indicadores
Óptimos para la Defensa y
Evaluación de la Biodiversidad
Forestal ante el Cambio
Climático (BIODEF-CC)”**

ÍNDICE

Abstract

1. Introducción
 - 1.1. Antecedentes
 - 1.2. Objetivos del proyecto
2. Metodología
 - 2.1. Metodología FIC
 - 2.2. Procedimiento de cálculo de bioindicadores
3. Resultados
 - 3.1. Análisis de la meteorología y climatología de la zona de estudio
 - 3.2. Indicadores más apropiados para evaluar el estado de la biodiversidad forestal, incluyendo la biomasa, salud y diversidad.
 - 3.3. Proyecciones de escenarios de clima futuro
 - 3.4. Análisis de la vulnerabilidad y probabilidad de plagas y enfermedades de los bosques bajo diferentes condiciones climáticas de acuerdo con los índices seleccionados.
4. Conclusiones
5. Bibliografía

ABSTRACT

Este estudio analiza las amenazas a las que se enfrenta la biodiversidad de las cuencas de los ríos Júcar y Segura debido al cambio climático. Concretamente, el estudio se centra en una especie invasora potencialmente dañina para la vegetación autóctona: el *Arundo Donax* (caña común).

Mediante la utilización de un modelo de distribución de especies, se obtiene una simulación actual de la distribución del *Arundo Donax*. Actualmente, su presencia es más destacable en la franja costera de la Comunidad Valenciana. Utilizando el mismo modelo de distribución, combinado con proyecciones climáticas de temperatura y precipitación hasta finales del siglo XXI, se obtiene como resultado principal que esta especie invasora tenderá a extenderse en las próximas décadas desde su ubicación actual hacia el curso alto de los ríos de la vertiente mediterránea.

Agradecimientos: Este proyecto ha sido apoyado por el Ministerio para la Transición Ecológica, en la convocatoria de 2018 sobre "Concesión de subvenciones a entidades del tercer sector u organizaciones no gubernamentales que desarrollen actividades de interés general consideradas de interés social en materia de investigación científica y técnica de carácter medioambiental"

1. Introducción

1.1 Antecedentes

El calentamiento global afecta en gran medida a los ecosistemas forestales, lo que requiere de planes de prevención y gestión destinados a aumentar la capacidad y resiliencia de los bosques para garantizar su pervivencia (FAO, 2006). En el actual contexto de calentamiento global se deben considerar la variación de factores ambientales como pueda ser el aumento de la temperatura media, el aumento de la intensidad y duración de las olas de calor, el aumento del riesgo de incendio, la variación de precipitación o el aumento del estrés hídrico que entre otros muchos han generado un aumento de la mortalidad forestal así como el desplazamiento latitudinal de numerosas especies (Allen et al., 2010). También es necesario contemplar los factores bióticos (patógenos, plagas, especies invasoras, etc.) y su respuesta ante la variabilidad ambiental y cómo pueden afectar a futuro. En Europa tenemos ejemplos de numerosas especies de patógenos que han mermado especies locales en las últimas décadas, en su mayor parte procedentes de América y Asia.

Para esta labor habitualmente se utilizan modelos de distribución de especies (SMDs), constituidos como una herramienta útil para evaluar la exposición de los elementos bióticos y abióticos. Esta evaluación parte de la asociación entre variables ambientales y los registros de especies conocidas permitiendo de esta manera la evaluación de la idoneidad del hábitat para una especie determinada bajo diferentes escenarios climáticos.

Garantizar la permanencia del beneficio que poseen los bosques sobre el medioambiente y la sociedad es uno de los compromisos adquiridos por España en múltiples acuerdos internacionales (ej.: Objetivos de Desarrollo del Milenio; Decisión Ministerial de Oslo: Bosques Europeos 2020). Además de los beneficios medioambientales no debemos olvidarnos de las repercusiones socioeconómicas a través de numerosas actividades relacionadas con el turismo de naturaleza y paisajístico y otras no menos relacionadas como la silvicultura y la ganadería. En concreto, la Ley 42/2007 del Patrimonio Natural y de la Biodiversidad, constituye el Catálogo Español de Especies Exóticas Invasoras reconociendo que suponen una amenaza grave para las especies autóctonas, los hábitats o los ecosistemas españoles.

Para su correcta elaboración, el presente proyecto tiene en cuenta los factores abióticos, su reciente evolución, sus proyecciones futuras y su clasificación a partir de un método de predicción estadística basado en estratificación analógica. De igual manera, los factores bióticos se clasifican por tipologías condicionados por los diferentes tipos de respuesta que posean ante los agentes abióticos y entre sí mismos, tanto para tipologías forestales como para

los agentes patógenos y las plagas. Esto permite evaluar de forma más robusta las amenazas potenciales que posea el ámbito forestal en estas regiones peninsulares.

La Fundación para la Investigación del Clima (FIC) posee un largo historial en la evaluación del impacto del cambio climático sobre el ámbito forestal a partir de proyectos nacionales e internacionales. En lo referente a la generación de escenarios locales de cambio climático el equipo de la FIC tiene una holgada experiencia de más de 20 años. Cabe destacar que la FIC ha generado una parte significativa de los escenarios oficiales utilizados en el Plan Nacional de Adaptación al Cambio Climático de España (Brunet et al., 2008).

Entre numerosos proyectos podemos destacar la evaluación del impacto del cambio climático sobre las masas forestales, en el proyecto denominado “Estudio del impacto del cambio climático sobre la diversidad y la composición de las cubiertas forestales en los Parques Nacionales españoles (2010)” y financiado por el Ministerio de Medio ambiente y Medio Rural y Marino.

Otro proyecto relativo a las simulaciones de cambio climático es el que evalúa sus impactos sobre el hábitat del oso pardo y financiado por el Ministerio de Medio Ambiente y Medio Rural y Marino: “Estudio del impacto del cambio climático sobre la diversidad y la composición de las cubiertas forestales en las zonas de interés para la protección del oso pardo en España (2010)”, donde se analizó el impacto del cambio climático sobre el hábitat actual de esta especie en España, y sobre otras zonas que, no estando actualmente habitadas por el oso pardo (una especie emblemática de nuestro país y en grave peligro de extinción), pudieran ser zonas de interés en el futuro.

Otro de los proyectos realizados por la FIC es “Investigación científica para la adaptación de las masas forestales de *Pinus pinaster* Ait. y *Pinus halepensis* Mill. al cambio climático, mediante la simulación de la evolución futura de las poblaciones marginales y el análisis de su diversidad genética (2014)”. En este proyecto se logró evaluar el impacto del cambio climático – mediante la definición de impacto en la genética de dos especies arbóreas determinadas – en el sector forestal. Algunos resultados de este estudio se han publicado en revistas internacionales, como es el caso de Serra-Varela et al. (2017).

En lo relativo a proyectos internacionales se ha realizado la evaluación del cambio climático sobre ecosistemas forestales para el caso de cordilleras en Iberoamérica: “Impactos potenciales del cambio climático en ecosistemas forestales en cordilleras iberoamericanas y herramientas para la adaptación de la gestión (CLIMIFORAD – Climate Change, Iberoamerican Mountain Forests and Adaptation)”, financiado por el Banco Interamericano de Desarrollo (BID).

Por otro lado, el Grupo de Investigación Historia y Dinámica del Paisaje Vegetal, la Universidad Politécnica de Madrid, lleva colaborando con el CIFOR-

INIA desde al año 2008 (por ejemplo en el proyecto MIA 2008-2011: Proyecto cooperativo sobre mitigación y adaptación al cambio climático en la gestión forestal sostenible en Iberoamérica), y con la FIC desde 2011 (por ejemplo en el proyecto CLIMIFORAD 2011-2015: Proyecto: Impactos potenciales del cambio climático en ecosistemas forestales en cordilleras iberoamericanas y herramientas para la adaptación).

Además, lleva profundizando en el empleo de modelos de distribución de especies, enfocado a la aplicación de los efectos climáticos en coordinación con estas dos entidades desde el 2008 hasta el presente (Moreno Amat, 2017).

1.2. Objetivos del proyecto

En el proyecto “Búsqueda de Indicadores Óptimos para la Defensa y Evaluación de la Biodiversidad Forestal ante el Cambio Climático (BIODEF-CC)” se ha estudiado la amenaza de especies invasoras en las cuencas hidrográficas del Júcar y Segura bajo diferentes proyecciones climáticas a escala local generadas mediante una técnica de downscaling estadístico (FICLIMA) a partir de un conjunto de modelos climáticos pertenecientes al Coupled Model Intercomparison Project 5 (CMIP5).

El **objetivo principal** de la presente investigación es la **prevención y anticipación de riesgos y amenazas** que el **cambio climático** pueda causar sobre la **superficie forestal** y su **biodiversidad** en las **cuencas hidrográficas** seleccionadas. Las líneas de trabajo son las siguientes:

- Recopilación de datos meteorológicos y bibliográficos sobre biodiversidad forestal
- Evaluación de las variables de riesgo forzadas bajo diferentes escenarios meteorológicos
- Proyección de los diferentes escenarios climáticos de biodiversidad forestal
- proyección de la distribución de las especies con mayor amenaza para los ecosistemas de las cuencas seleccionadas.

Los **objetivos específicos** se pueden resumir en:

- Definición de una técnica para determinar la relación entre **escenarios de riesgo** para la **biodiversidad forestal** a **escala climática** respecto a las variables que supongan una amenaza con una significancia estadística suficientemente robusta y estudiar su evolución a futuro.
- **Identificación** de **especies bioindicadoras** para la Defensa y Evaluación de la Biodiversidad Forestal ante el Cambio Climático.
- **Análisis** de la **distribución** y de los **factores climáticos** implicados en la presencia de las especies con mayor grado de **amenaza**.

- **Proyección** de la **distribución de especies** con mayor grado de **amenaza** bajo **diferentes escenarios** y desarrollo de una **estrategia comunicativa**.

Para alcanzar los objetivos expuestos anteriormente, el estudio se distribuyó en las siguientes actividades:

		Descripción de la actividad
Actividad 1	Recogida de datos de las variables meteorológicas: Temperatura, precipitación, humedad y viento	Se recopilan datos meteorológicos de superficie a partir de las redes meteorológicas disponibles. Se verifican unos estándares de calidad de datos a partir de diversos filtros de cantidad y calidad entre los que se incluye un filtro de inhomogeneidades con técnica propia (Monjo et al. 2013).
Actividad 2	Recogida de datos de las variables ambientales: topografía, usos del suelo y vegetación	Posteriormente se recopilan datos bibliográficos y se seleccionan los indicadores más apropiados para realizar una estimación del estado actual de los factores bióticos, especialmente a partir de datos tomados en el Inventario Forestal Nacional.
Actividad 3	Análisis de vulnerabilidad al clima de las defensas naturales de las cuencas hidrográficas del estudio	Tras un proceso de estratificación analógica se determinan los escenarios climáticos de mayor vulnerabilidad para la biodiversidad forestal.
Actividad 4	Proyección de escenarios climáticos para las próximas décadas de temperatura, precipitación, humedad y viento	Posteriormente se generan los múltiples escenarios climáticos basándose en las diferentes proyecciones RCP del AR5. Hay que tener en cuenta que se han generado diferentes proyecciones de clima futuro y por ello se generan diferentes proyecciones de vulnerabilidad en función de la masa forestal y el resto de agentes, por lo que el análisis de impacto se realiza sobre el conjunto de esas proyecciones, teniendo las conclusiones finales un carácter probabilístico

Tabla 1. Actividades realizadas en el marco del proyecto BIODEF-CC.

2. Metodologías utilizadas

Para simular las proyecciones climáticas futuras se ha utilizado una metodología de *downscaling* estadístico (FICLIMA) desarrollada por la FIC, que permite simular series diarias de temperatura y precipitación a lo largo del siglo XXI y cuyas proyecciones se han utilizado para calcular los indicadores identificados dentro del proyecto.

2.1. Metodología de regionalización estadística FICLIMA

A día de hoy, la herramienta más potente en la simulación del clima futuro son los Modelos Climáticos Globales y concretamente los *Earth System Models* (ESMs). Estos modelos muestran una capacidad notable para reproducir las principales características de la circulación atmosférica general. El problema surge cuando se evalúan los resultados a una escala más pequeña (es decir, se seleccionan unos pocos puntos de la rejilla de trabajo) donde las variables, especialmente en superficie, no se aproximan a los valores observados en la realidad.

Estas limitaciones se pueden explicar por varias razones, en general relacionadas con la insuficiente resolución espacial de los modelos que a día de hoy es de unos 2°-3° de latitud/longitud:

- La topografía (cordilleras, líneas de costa, etc.) es descrita con poco detalle lo que hace que algunos forzamientos relacionados con la misma y de extraordinaria importancia a nivel local sean omitidos y por lo tanto no tenidos en cuenta por el modelo.
- Algunos de los procesos atmosféricos que se presentan a una escala inferior a la de la rejilla de trabajo de los modelos (y que por lo tanto tienden a no ser reflejados por éstos) se recogen mediante parametrizaciones directas, es decir, son representados por un ajuste directo de los parámetros en el modelo. Esas parametrizaciones son ajustadas de manera estadística en todo el planeta pudiendo ser ineficientes en regiones concretas.
- La parametrización del flujo de energía desde las escalas sinópticas (106 km²) hasta las de una escala inferior a la rejilla de trabajo afecta a la fiabilidad de las menores escalas resueltas.

Dado que en la mayor parte de los estudios de evaluación de impactos es necesaria la presencia de escenarios climáticos con resolución local de variables cercanas a la superficie terrestre (temperatura a 2m., precipitación, etc.), surge la necesidad de adaptar la información proporcionada por los ESMs (de baja resolución espacial) a la información requerida por los modelos de impacto (de mayor resolución espacial-local en superficie). Este proceso de regionalización es conocido como *downscaling*.

Existen dos maneras principales de afrontar el problema de la regionalización:

- A. **Aproximaciones estadísticas** (*downscaling estadístico*). Se obtienen relaciones empíricas entre variables a gran escala procedentes de los Modelos Climáticos Globales y variables de alta resolución (en superficie).
- B. **Aproximaciones por modelización dinámica** (*downscaling dinámico*). Estos modelos incrementan su resolución sobre la región de interés. Puede realizarse de dos maneras, o bien con una técnica de “zoom” de la propia rejilla del modelo o bien mediante el anidamiento de un Modelo de Área Limitada (LAM) en las condiciones de contorno suministradas por el Modelo Climático. Son los denominados Modelos Regionales del Clima (RCM, del inglés Regional Climate Model).

Las aproximaciones estadísticas tienen mucho menor coste computacional (lo que permite aplicarlas a multitud de Modelos Climáticos y escenarios de emisiones), pero sufren de una incertidumbre implícita consecuencia de aceptar la hipótesis de que los campos de efectos en superficie de alta resolución son función exclusiva de las condiciones dinámicas y termodinámicas a gran escala en la atmósfera, considerando las características de la topografía fijas. Es dudoso que en un marco de cambio climático no varíe ningún forzamiento mesoescalar (albedo, humedad del suelo, campos atmosféricos a baja resolución...). Adicionalmente, las relaciones estadísticas entre campos atmosféricos de baja resolución y las variables en superficie a escala local son siempre imperfectas pudiendo resultar no-estacionarias, lo que significa que, aunque estas relaciones se verifiquen en el clima actual, no tienen por qué hacerlo en un clima futuro (un problema conocido como problema de la estacionariedad).

Las aproximaciones dinámicas cuentan con una base física más fuerte (aunque también utilizan relaciones estadísticas en las parametrizaciones). Actualmente, la resolución de los RCMs es de unos 25 Km, lo que resulta insuficiente para simular correctamente variables en superficie a escala local, especialmente en zonas de topografía compleja. Por otro lado, tienen el inconveniente de un coste computacional elevadísimo que pocas instituciones pueden permitirse.

	A FAVOR	EN CONTRA	APLICACIONES
Downscaling dinámico	<ul style="list-style-type: none"> • Simula mecanismos climáticos. • No realiza asunciones <i>a priori</i> sobre cómo están relacionados el clima presente y el futuro. • Herramientas científicas permanentemente actualizadas. • Los continuos avances en ordenadores hacen que cada vez se generen más 	<ul style="list-style-type: none"> • Muy costoso, tanto en términos de necesidades informáticas como de formación del personal. • Los resultados son sensibles a las parametrizaciones iniciales. • El posible sesgo existente en los MCG se puede propagar a la escala local. • El formato de salida de 	<ul style="list-style-type: none"> • Áreas geográficas con pocos datos iniciales de partida. • Estudios asociados con extremos climáticos y variabilidad no-lineal, como los sanitarios. • Relaciona los resultados con procesos climáticos. • Permite incluir impactos sobre el uso del suelo sobre

	<p>rápidamente y sean más baratos de ejecutar.</p> <ul style="list-style-type: none"> • Estimula la colaboración entre científicos del clima y de otras disciplinas de estudio. 	<p>los modelos puede no ser útil a otras disciplinas de análisis científico, y es necesario un tratamiento de datos posterior.</p>	<p>los resultados.</p>
<p>Downscaling estadístico</p>	<ul style="list-style-type: none"> • Muy barato (funciona con mucha velocidad en ordenadores personales con software libre). • Aprovecha la experiencia estadística entre investigadores. • Puede corregir los sesgos propios de los MCG. • Permite evaluar los resultados climáticos sobre un grupo de MCGs y sobre diversos escenarios. 	<ul style="list-style-type: none"> • Asume que las relaciones entre el clima local y el de gran escala permanecen constantes. • No incorpora mecanismos climáticos. • No está ajustado para capturar varianzas o eventos extremos. 	<ul style="list-style-type: none"> • Medias climáticas, y ciertos rangos de variabilidad. • Regiones ricas en datos meteorológicos, como las latitudes medias del hemisferio norte. • Permite comparar el clima presente y el futuro de forma consistente. • Puede realizar tests sobre diversos predictores. • Permite medir las escalas de variables hasta lugares concretos.

Tabla 2. Diferencias ente *downscaling* estadístico y dinámico. (Fuente: Patz, et al., 2005)

La necesidad de regionalizar

La metodología FICLIMA de regionalización es una metodología de *downscaling* estadístico. Necesita por lo tanto de una selección previa de campos a utilizar como predictores y una, vez seleccionados éstos, realiza un tratamiento basado en la metodología de análogos. En lo que sigue pasaremos a describir con un cierto grado de detalle los fundamentos de la metodología FICLIMA; si lo que se desea es un mayor detalle, puede acudir a Ribalaygua et al. (2013).

En términos generales, la metodología sigue el siguiente esquema: se selecciona un día problema “X”, cuyos campos atmosféricos (geopotenciales, temperaturas a distintos niveles de presión...) de baja resolución son conocidos (mediante las salidas de los Modelos Climáticos Globales para el día “X”). A partir de esos campos conocidos, se pretende estimar el valor de las variables meteorológicas en superficie (temperaturas máxima y mínima, precipitación...) para el día “X” en un punto concreto del territorio (observatorio).

El método trabaja en dos pasos sucesivos:

1. El primer paso, denominado estratificación analógica, consiste en seleccionar de un banco de datos aquellos n días con configuraciones atmosféricas más similares a las del día problema “X”. La medida de similitud utilizada compara el parecido entre las variables empleadas para

caracterizar las situaciones sinópticas atmosféricas; esas variables determinan el forzamiento sinóptico causante de los descensos y ascensos de aire, generadores de nubosidad y precipitación. Se busca, además, aportar información sobre la dirección del viento en superficie, lo que permite estudiar los efectos que la topografía ejerce en la distribución espacial de la nubosidad y de la precipitación.

2. El segundo paso aplica métodos diferentes en función de la variable que se quiera calcular:

- Para estimar las temperaturas mínimas y máximas diarias, se realiza, por cada variable, una regresión lineal múltiple con selección automática de predictores. La población de trabajo va a estar compuesta por los n días seleccionados en el paso previo. Como predictores se tienen, por un lado, los valores de las variables atmosféricas en la vertical del punto para el que se quiere estimar la temperatura en superficie y por otro, predictores potenciales. Dichos predictores potenciales son un indicador de la duración de la noche en el día en cuestión (proporciona información sobre el potencial de calentamiento / enfriamiento radiativo) y un promedio ponderado de las temperaturas de los días anteriores (se considera el efecto de la inercia térmica del suelo). Una vez establecida la relación lineal existente entre los predictores seleccionados y el predictando (temperatura mínima, máxima o precipitación), se aplica dicha relación a los valores de los predictores del día "X" para estimar el valor del predictando en dicho día.

La influencia fuertemente no-lineal que la nubosidad y la precipitación ejercen sobre la temperatura en superficie ha sido corregida en la estratificación analógica. Al seleccionar los días con configuraciones atmosféricas más similares, se garantiza que las condiciones de precipitación y nubosidad también lo sean y por tanto, también, su influencia sobre el predictando. Obtenemos, de esta manera, relaciones lineales más robustas. Un ejemplo de esto es la relación entre el espesor de la baja troposfera y la temperatura a 2 m, que es de carácter no-lineal. Cuando se trata de días con cielos cubiertos, la temperatura máxima va a depender fuertemente del espesor, entre ambas variables se tendrá una relación bastante lineal. Sin embargo, en días con cielos despejados, la dependencia de la temperatura máxima con el espesor es menor, dependiendo, principalmente, de la insolación y esta a su vez de la época del año.

- Para el caso de la precipitación se han probado varias aproximaciones. La más simple de todas ellas contempla la estima por simple promediado de los k días análogos más parecidos a "X". Además de estimar la cantidad de lluvia, este método permite obtener la probabilidad de lluvia o tiempo seco. En el estudio de las series obtenidas se detectó que, aunque el comportamiento de la predicción de precipitación media en un periodo era aceptable, el número de días de lluvia se sobreestimaba claramente. Ello se debe a que se estaba asociando lluvia a todos los días con probabilidad no nula, aunque ésta fuese muy baja. Para corregir este error, se introdujo una corrección

estadística que permite obtener el número de días de lluvia en un mes a partir de las probabilidades de lluvia de cada uno de los días del mes. Conocido el número de días de lluvia y la cantidad de lluvia, se distribuye ésta entre los días con mayor probabilidad y cantidad esperada de precipitación. De esta forma se obtienen mejoras no sólo para el número de días de lluvia, sino también para lluvias extremas y periodos de sequía.

Aunque algunas de las debilidades intrínsecas del método de *downscaling* estadístico son insalvables debido a la propia naturaleza de tal método (dependencia de un conjunto de observatorios meteorológicos con datos fiables y que cubran un periodo temporal extenso; necesidad de sucesivas pruebas de adaptación de la metodología hasta determinar los campos que mejor recogen la variabilidad climática en la zona de estudio), la metodología FICLIMA presenta algunas ventajas con respecto a otras metodologías estadísticas:

	<p>El problema de la estacionariedad va a ser minimizado gracias al criterio de selección de predictores, basado en consideraciones teóricas que reflejen las relaciones físicas entre predictores y predictandos, relaciones físicas que no deben cambiar a lo largo del tiempo.</p>
	<p>Cuando se utiliza el método de selección de análogos, y dado que la simulación final estará basada en los días más análogos, el valor asignado a la variable meteorológica estudiada estará limitado por el valor observado que tenga en esos días análogos, es decir, su margen de variabilidad vendrá dado por la propia variabilidad del pasado (nunca calcularíamos valores superiores o inferiores). Sin embargo, el segundo paso introducido en la metodología FICLIMA nos permite superar esa limitación: las relaciones lineales diarias establecidas para temperatura y la redistribución de la precipitación en base a la función de distribución permiten simular valores que pueden exceder la limitación de los valores observados iniciales.</p>

Tabla 3. Ventajas de la metodología FICLIMA frente a otras metodologías de *downscaling* estadístico

Con el fin de asegurar que las proyecciones climáticas han sido generadas de la forma más rigurosa posible, se proceden a realizar un proceso de verificación de la metodología y otro de la validación de los modelos climáticos.

Verificación de la metodología de *downscaling*

El proceso de verificación consiste en la comparación de los datos observados (de las diferentes estaciones meteorológicas) con los datos simulados obtenidos mediante la aplicación de la metodología de *downscaling* sobre el

reanálisis (en nuestro estudio, ERA40). Comparando los dos conjuntos de datos, observados y simulados, se puede evaluar si la metodología es capaz de simular correctamente el clima actual (y del pasado reciente). La información resultante es muy importante y tiene que ser tomada en cuenta cuando se trabaje con escenarios climáticos futuros.

La metodología se ha aplicado al reanálisis Europeo ERA40 del ECMWF (*European Centre for Medium-Range Weather Forecasts*) para el periodo 1958-2000. El reanálisis ERA40 proporciona "observaciones" de los predictores, y cubre con una rejilla de $1.125^{\circ} \times 1.125^{\circ}$ toda la superficie terrestre, con resolución seis-horaria (4 datos al día). No obstante, esa información de relativa alta resolución (espacial y temporal), debe relajarse a la de los Modelos Climáticos que se vayan a utilizar posteriormente (rejillas de 2 a 3° de resolución, y en general con un único dato al día), ya que en esta verificación se pretende evaluar el error de la metodología de *downscaling* aplicada en las mismas condiciones que se vayan a aplicar luego a los GCMs. Esto es importante, ya que algunas metodologías de *downscaling*, y la de la FIC entre ellas, mejoran su capacidad de regionalización cuanto mayor resolución espacial y temporal tenga la información de entrada (los predictores). Por ello, si no se relajase la resolución espacial y temporal del ERA40 a la de los GCMs que se va a regionalizar, obtendríamos errores de verificación menores de lo que en realidad se debería considerar (y corregir).

Lo primero que se debe hacer es obtener los valores de los predictores a partir de la información proporcionada por el ERA40. El siguiente paso es el de obtener las situaciones sinópticamente análogas a las que se presentaron durante el periodo común entre observaciones y reanálisis, en nuestro caso 1958-2000. Esta parte del proceso tiene un elevado coste computacional, ya que para cada día del periodo de verificación (1958-2000) se determinan las situaciones más similares del periodo de referencia (1958-2000), exceptuando los 5 días anteriores, los 5 posteriores y el mismo día problema para evitar el fenómeno denominado *overfitting* o sobreajuste.

Una vez determinadas las situaciones análogas a cierto día problema x , se obtiene el valor simulado de la variable meteorológica a estudiar para ese día x . Realizando este proceso para cada uno de los días del periodo de verificación se obtiene una serie simulada por regionalización de ERA40 para cada uno de los observatorios.

Es importante resaltar que no es necesario que existan observaciones de los predictandos de todos los días del periodo de verificación (cosa que muy raramente sucede), ya que en la serie simulada por regionalización del ERA40 cada día se corresponde con una fecha real. Por tanto, las comparaciones entre las observaciones y la serie simulada por regionalización del ERA40 se realizan día a día (con los días de los que haya observación). Este aspecto es esencial, ya que, si una metodología de regionalización es capaz de reproducir las observaciones día a día, eso sugiere que se están captando las relaciones físicas entre predictores y predictandos, y por tanto el problema de la estacionariedad, la principal desventaja de las metodologías estadísticas, se reduce.

Validación de los modelos climáticos

En general, los modelos climáticos tienden a simular un clima presente más cálido/frío o húmedo/seco de lo que éste es en realidad y la magnitud con la que se alejan de la realidad varía en función de la región concreta en la que se esté trabajando dado que la simulación de los modelos se realiza a escala global. Dado que cada modelo trabaja de forma diferente en la simulación del clima surge la necesidad de evaluar el comportamiento de cada modelo en la zona de estudio que permita determinar cómo de bueno es dicho modelo simulando el clima presente de la región y si su uso es adecuado o por el contrario no se debería trabajar con él. El proceso mediante el cual se evalúa el comportamiento de un modelo climático es lo que se conoce como validación. Este proceso consiste en comparar las series simuladas obtenidas mediante regionalización del reanálisis (ERA40, en nuestro caso) con las series simuladas obtenidas mediante regionalización del escenario *Historical* de cada modelo (su simulación de control) para un periodo común del pasado, en este caso 1958-2000. *Historical* corresponde a la ejecución de un experimento concreto relativo a datos del pasado y no es por lo tanto un escenario futuro de cambio climático. Su misión es la de permitir disponer de un experimento que nos muestre si el modelo climático a emplear es capaz de reflejar la variabilidad climática natural y por eso abarca un periodo del pasado, el periodo 1951 – 2005 (aunque algunos modelos hacen comenzar tal periodo más atrás).

Debe hacerse notar que la disponibilidad de los datos de los modelos climáticos debe agradecerse al WCRP (*World Climate Research Programme*), un programa de la Organización Meteorológica Mundial (*World Meteorological Organization – WMO*) que es el responsable de la iniciativa *Coupled Model Intercomparison Project 5* (CMIP5), y el desarrollo de la infraestructura necesaria para su almacenamiento y descarga (tanto de hardware como de software) al Departamento de Energía de los Estados Unidos de América. A cada uno de los grupos de trabajo de los modelos empleados debe agradecerse también el trabajo realizado en su modelización y en su ejecución.

Los escenarios de clima futuro

Los Escenarios de Clima Futuro suelen asociarse en los estudios de Cambio Climático a escenarios de emisiones en tanto que descripciones plausibles de cómo serán los cambios futuros en un amplio rango de variables: socioeconómicas, tecnológicas, energéticas, uso del suelo, emisiones de gases de efecto invernadero (GEIs), y contaminantes del aire. Para cumplir esta función, se desarrollaron conjuntos de escenarios de emisiones como los IS92 o los SRES (los asociados al cuarto informe del IPCC). Pero en la comunidad científica surgió la necesidad de escenarios provistos de una información más detallada. Atendiendo a esta necesidad, el IPCC propone la definición de nuevos escenarios. En este caso, la propuesta consiste en que sea la comunidad científica quien defina dichos escenarios mediante la colaboración conjunta de los responsables de los distintos centros que generan Modelos Climáticos y de los responsables de los centros de Modelos de Evaluación Integrada. La idea de aunarlos reside en que estos últimos proporcionan una

información adicional sobre aspectos socioeconómicos que completan la información generada por los modelos.

Los nuevos escenarios futuros a usar, los asociados al quinto informe del IPCC, han recibido el nombre de *Representative Concentration Pathways* (RCPs) y su definición se basa en los siguientes criterios:

- 1) Los RCPs se deben basar en escenarios de emisiones ya existentes elaborados por distintos centros y recogidos en la literatura. Al mismo tiempo cada RCP debe, por sí mismo, ser una descripción plausible e internamente coherente con el futuro,
- 2) deben proporcionar información de todos los forzamientos radiativos necesarios para la modelización climática (uso del suelo, emisiones de GEIs y contaminantes del aire),
- 3) deben estar armonizados, es decir, la transición continua entre el periodo histórico (el experimento *Historical*) y los periodos futuros debe garantizarse y,
- 4) deben ofrecer información hasta el 2100 y estar disponibles para simular aún más allá.

El nombre de los RCPs refleja dos de sus principales características:

1. **Representative**: hace referencia a la idea de que un RCP representa a un conjunto de escenarios de emisiones ya existentes. Es decir, el RCP debe ser compatible tanto con los escenarios extremos como con los medios.
2. **Concentration Pathway**: este término hace hincapié en que los RCPs no son productos finales, sino que son la herramienta (el input) hacia la generación de escenarios de emisiones, de ahí el uso de concentraciones en vez de emisiones. Los RCP se entienden como un conjunto suficientemente consistente de las componentes de forzamiento radiativo pero no son un conjunto completo de proyecciones climáticas, socioeconómicas y de emisión.

La comunidad científica (formada por más de 20 grupos de trabajo de todo el mundo) determinó en septiembre de 2008 en París que los nuevos escenarios serían los RCP2.6, RCP4.5, RCP6.0 y RCP8.5 (el nombre hace referencia al forzamiento radiativo alcanzado en 2100); la figura 1 representa el comportamiento de tales escenarios a lo largo del tiempo, expresado como forzamiento radiativo. La figura4 muestra las características de la definición de cada escenario o RCP.

CMIP5 New scenarios: Representative Concentration Pathways

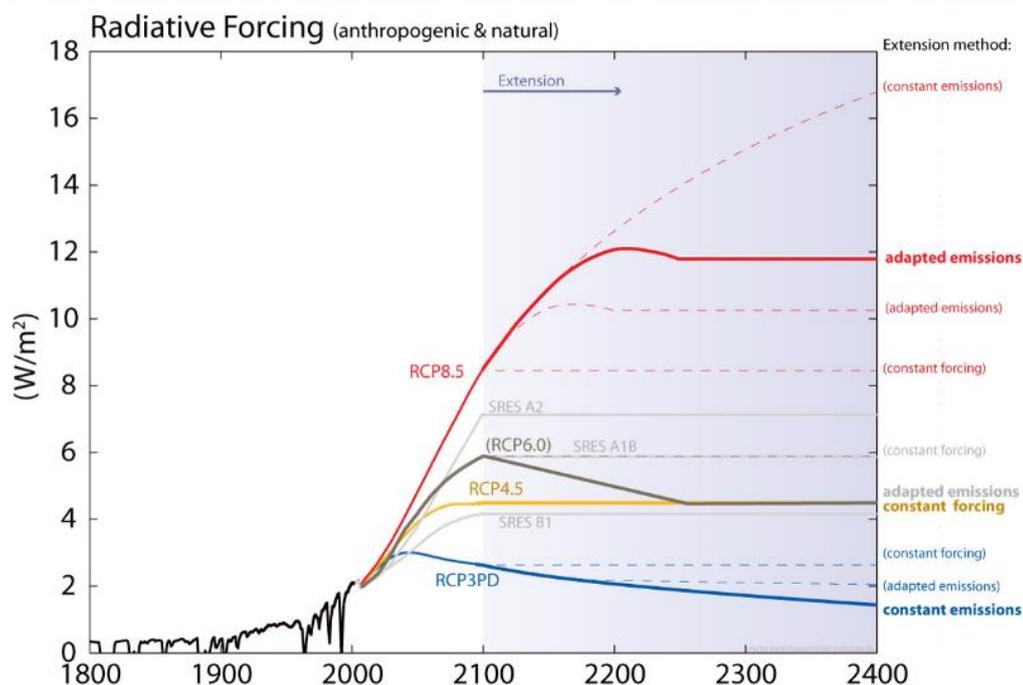


Figura 1. Forzamiento radiativo a lo largo del siglo XXI asociado a los diferentes RCPs y su relación con los escenarios del 4º informe del IPCC (SRES). El escenario RCP2.6 aparece con su nombre originario, RCP3PD. Fuente: Meinshausen, Smith, et al. (2011).

RCP	Características
2.6	Se alcanza un pico de 3 W/m ² antes de 2100 para luego descender hasta los 2.6 W/m ²
4.5	Se estabiliza sin sobrepasar el nivel de 4.5 W/m ² (equivalente a unos 650 ppm) en el 2100
6.0	Se estabiliza sin sobrepasar el nivel de 6.0 W/m ² (equivalente a unos 850 ppm) en el 2100
8.5	Alcanza 8.5 W/m ² (equivalente a unos 1370 ppm de CO ₂ eq.) en 2100 y no se estabilizan los niveles hasta el 2050

Tabla 4. Características principales de los diferentes RCPs.

Junto con los nuevos RCPs se formó el CMIP5 (*Climate Model Intercomparison Project 5*) con el objetivo de crear una base de trabajo donde poner a disposición de la comunidad científica toda la información climática a emplear en los trabajos relacionados con el 5º informe del IPCC.

Debido a la enorme información generada por los diferentes centros de investigación, el CMIP5 ha dividido la información en diferentes niveles con el objetivo de que todos los centros de investigación aporten un mínimo de información común que permita la comparación entre ellos. Así, el primer nivel, denominado “Core” y que debe ser proporcionado por todos los miembros, lo forman los RCPs 4.5 y 8.5. En un segundo nivel y denominado “Tier 1” se encuentran los RCPs 2.6 y 6.0 y experimentos más detallados, y en el último nivel, denominado “Tier 2” se encuentran experimentos más complejos, como, por ejemplo, los *Extended Concentration Pathways*, extensiones de los RCPs hasta el año 2300.

La elección del modelo climático empleado en este estudio no ha sido determinada por ningún criterio científico específico ya que, dado lo reciente de los modelos asociados al CMIP5, todavía no existe la suficiente literatura científica relativa al comportamiento de todos los modelos existentes, con lo que por ahora es completamente imposible establecer una clasificación (mejores modelos / peores modelos) de los modelos existentes. Para la selección del modelo elegido de entre los existentes se impuso que

1. Mostrará un buen comportamiento en el pasado informe del IPCC o al menos fueran generados por los mismos organismos científicos, buscando un cierto grado de confianza en la capacidad de los equipos involucrados a la hora de generar un modelo y,
2. Dando preferencia a modelos que fueran del tipo Modelos de Sistema Terrestre (ESM por las siglas en inglés de *Earth System Model*), los modelos climáticos más avanzados. Estos modelos son un conjunto de ecuaciones que describen los procesos que tienen lugar dentro y entre la atmósfera, el océano, la criosfera y la biosfera marina y terrestre. Estas ecuaciones recogen los mecanismos físicos, químicos y biológicos que gobiernan a los elementos del sistema terrestre y también incluyen erupciones volcánicas y variaciones de la radiación solar entrante. Su principal avance frente a los Modelos de Circulación General tradicionales es que permiten la interacción del sistema con el ciclo del carbono y tienen en cuenta la bioquímica y la biogeología marina.

La corrección del error sistemático

Tal y como hemos comentado anteriormente, si necesitamos que los datos regionalizados en un punto de un cierto modelo climático se puedan interpretar en sus valores absolutos y no sólo en términos de incrementos relativos entonces debemos corregir los posibles errores que han conducido a introducir sesgos en la regionalización para así poder obtener valores que podamos estudiar en su magnitud absoluta. Esta corrección es lo que denominamos Corrección del Error Sistemático. Por lo tanto, antes de estudiar las

simulaciones obtenidas al regionalizar las proyecciones futuras de los 9 modelos considerados debemos llevar a cabo la corrección de tal error.

Sea cual sea el método de corrección empleado, buscaremos no corregir todos los datos de la misma forma (no sumarles o multiplicarles la misma cantidad), sino de forma proporcional, de manera que a los valores que tengan mayor error se les apliquen mayores correcciones, y los valores que tengan menor error se les apliquen menores correcciones. Para determinar qué valores tienen mayor o menor error estudiaremos la función de distribución de esos valores, comparando la función de distribución de los valores observados frente a los de ERA40 regionalizados, y la de los valores de ERA40 regionalizados frente a la de los modelos regionalizados. En concreto usaremos la función de distribución acumulada empírica o ECDF (*Empirical Cumulative Distribution Function*) que nos permite, al comparar dos entre sí, comparar la diferencia entre las mismas magnitudes (en rigor, entre los mismos cuantiles, ya que estamos trabajando con funciones de distribución) y establecer relaciones de proporcionalidad entre las magnitudes que dependerán de las propias magnitudes en sí. Este método nos proporciona una forma no-lineal (como buscábamos) de establecer las diferencias entre dos grupos de datos diferentes; la medida de esas diferencias será lo que nos permita corregir el error entre ambos grupos de datos.

La forma de aplicar este método se ejemplifica en la figura 2. Aunque en rigor el método está basado en el uso de la ECDF, aquí hemos representado el periodo de retorno de cada cantidad de precipitación (que gráficamente es más ilustrativa que la temperatura), entendido como la inversa de su probabilidad, dado que visualmente es mucho más ilustrativo (y también es una manera de representar su función de distribución). Lo que vamos a ver es un ejemplo de la forma en que funciona la corrección, donde los círculos negros representan valores observados; los azules, valores simulados del periodo de control (se correspondería con el experimento *Historical* de un modelo climático); y los verdes, los valores simulados de un escenario futuro. Veamos, usando un ejemplo, en qué consistiría el método:

1. Partiendo de los propios datos calculamos la distribución teórica de cada uno de los grupos de datos; tales distribuciones teóricas se corresponden con las líneas continuas representadas (cada una con el color del grupo al que se corresponde).
2. Una precipitación diaria de 33 mm en el grupo de control se corresponde con una de 51 en los observados – y esto es así porque el orden impuesto basado en periodos de retorno (en probabilidad, recordemos; o en ECDF) asocia que el mismo periodo de retorno de la de 33 mm se corresponde con la 51 en el grupo de los observados.

3. La corrección del escenario futuro debe pasar obligatoriamente por la comparación previa con su propio grupo de control, ya que sólo el grupo de control puede compararse con el grupo de valores observados. Así que supongamos una precipitación de 41 mm en el grupo del escenario futuro; esa misma precipitación tiene un periodo de retorno (una probabilidad) diferente en el grupo de control, y es ésta la que debo tomar, y al tomarla y llevarla hacia el grupo de observación le asigno el valor de 79 mm.

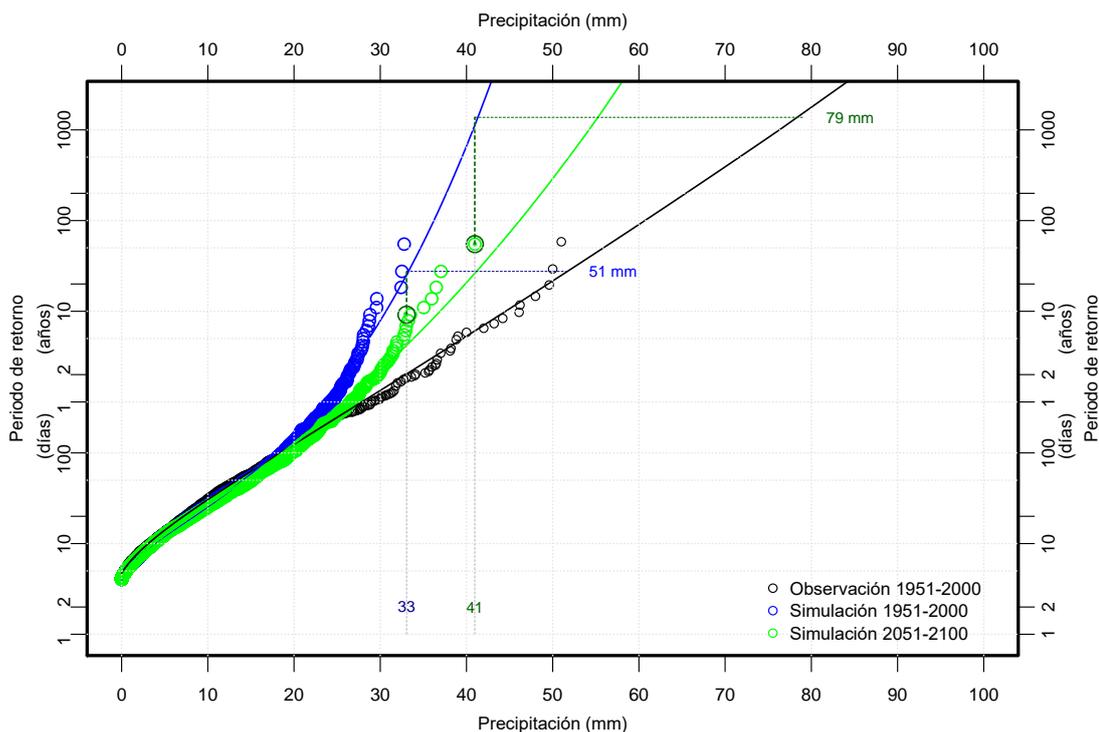


Figura 2. Visualización, con ejemplos, de la corrección del error sistemático. Los puntos negros se corresponden con valores observados, los azules con simulados para un periodo de control, y los verdes con simulaciones de periodos futuros. Las líneas continuas son las distribuciones teóricas de cada grupo. El uso del periodo de retorno (como inversa de la probabilidad) muestra las relaciones entre los grupos, ejemplificadas en los casos de 33 y 41 mm.

En resumen, el proceso de generación de escenarios de clima futuro a escala local a partir de la metodología FICLIMA comprende: 1) un proceso de caracterización climática de la zona a través de la cual se determinan los predictores potenciales a emplear; 2) verificación de la metodología, es decir, el funcionamiento de la misma en la zona de estudio; 3) validación de los modelos climáticos a emplear, es decir, determinar la manera en la que cada modelo climático simula el clima actual; 4) generar las proyecciones climáticas a partir de varios modelos climáticos bajo diferentes escenarios de clima futuro y 5) corregir el error sistemático asociado al proceso completo de regionalización. Llegados a este punto se disponen de proyecciones climáticas robustas que se utilizan en el cálculo de bioindicadores.

2.2. Procedimiento de cálculo de bioindicadores

En este proyecto la modelización se ha llevado a cabo por el método de **máxima entropía** o **Maxent** para obtener mapas de idoneidad climática en el presente y en el futuro para *Arundodonax (L.)*. Maxent es un tipo de algoritmo para desarrollar modelos de distribución de especies que no necesita la introducción de datos de ausencia (Phillips et al., 2006). En lugar de ello, Maxent toma los datos climáticos del área de estudio para construir un *background* de pseudoausencias y caracterizar climáticamente el área donde la especie se desarrolla. Se basa en el principio de que la distribución estimada de las especies debe coincidir con la distribución conocida a partir de las condiciones ambientales de donde ha sido observada. El algoritmo trata de encontrar la distribución de probabilidad de entropía máxima, que es la más cercana posible a la uniforme, teniendo en cuenta las restricciones impuestas por las presencias observadas reales y las condiciones climáticas del área de muestreo (Phillips et al., 2006). El software es gratuito y puede descargarse y utilizarse libremente siempre que se use con fines educativos o de investigación. (http://biodiversityinformatics.amnh.org/open_source/maxent/)

El proceso de modelización comienza con la descarga y tratamiento de los **datos de presencia** (y ausencia, en su caso) de la especie. Es imprescindible analizar y preparar los datos para eliminar posibles errores existentes en los registros, aún más cuando son obtenidos de bases de datos globales y fuentes ajenas. El número de presencias a emplear influirá de forma determinante en el modelo ya que muy pocas presencias pueden conducir a la elaboración de modelos poco representativos, mientras que el exceso conduce al sobreajuste de las predicciones (Aulló-Maestro & Moreno-Amat, 2011). Suele recomendarse un mínimo de 10 registros de presencia por cada variable a predecir, incluso 20 o 40 presencias si hay afección de multicolinealidad y correlación (Miller, 2010).

La **información ambiental** del territorio constituye las variables independientes o variables predictoras de los MDE. Estas variables pueden ser continuas (como la precipitación y la temperatura) o categóricas (por ejemplo: el tipo de suelo). El set de variables ambientales con las que se construirán los modelos debe ser correctamente seleccionado, ya que en el conjunto de información ambiental pueden darse problemas debidos a la correlación y combinación lineal de las diversas variables. Esto genera información redundante que afecta a la precisión de las predicciones de los algoritmos (Aulló-Maestro & Moreno-Amat, 2011).

El marco ambiental de fondo que compondrá el set definitivo de variables se conoce como **background del modelo**. Esta información debe ser adecuada a las presencias, ya que, como se ha citado previamente, éstas no deben ser excesivas en número ni demasiado restringidas.

Tras la preparación de los datos de presencia-ausencia, y la selección de las variables ambientales, se procederá a la **construcción de los modelos**. En este apartado seleccionaremos la complejidad matemática de ajuste de las predicciones mediante los factores '*Beta*' y las funciones '*Features*'. Con la construcción del modelo en Maxent se obtendrán estimaciones de la distribución potencial de la especie bajo condiciones climáticas actuales y futuras. Posteriormente, la capacidad predictora del mismo se evaluará mediante la curva ROC y el estadístico AUC.

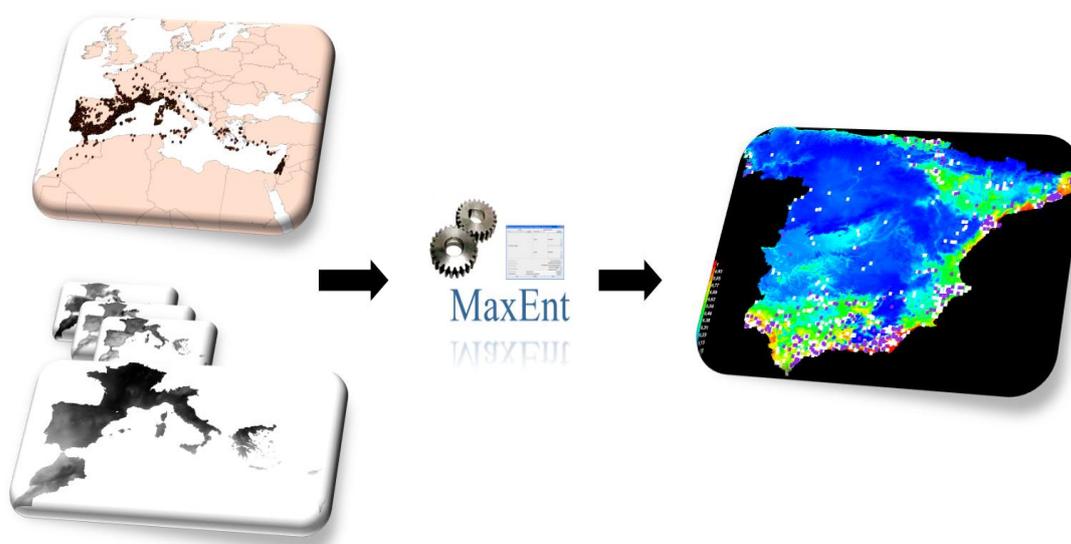


Figura 3. Esquema representativo del proceso de modelización con Maxent.

Datos de presencias

El conjunto de presencias empleado para la realización de los modelos proviene de diferentes muestreos de presencias reales, que han sido recopilados en la base de datos de GBIF (<http://www.gbif.org/>). Se ha procedido a la descarga de los registros, los cuales han sido posteriormente filtrados para ajustar las condiciones de partida al *background* necesario para la generación de modelos de distribución natural de la especie.

En la modelización con Maxent la variable dependiente, es decir, las ocurrencias, deben representar la distribución natural de la especie. En este caso se ha seleccionado el área correspondiente a la región del Mediterráneo para la descarga de los datos de entrada, atendiendo a los resultados de recientes estudios que defienden una homogeneidad genética de la especie en el Mediterráneo, que habría sido introducida desde Asia en torno al 1500 AC.

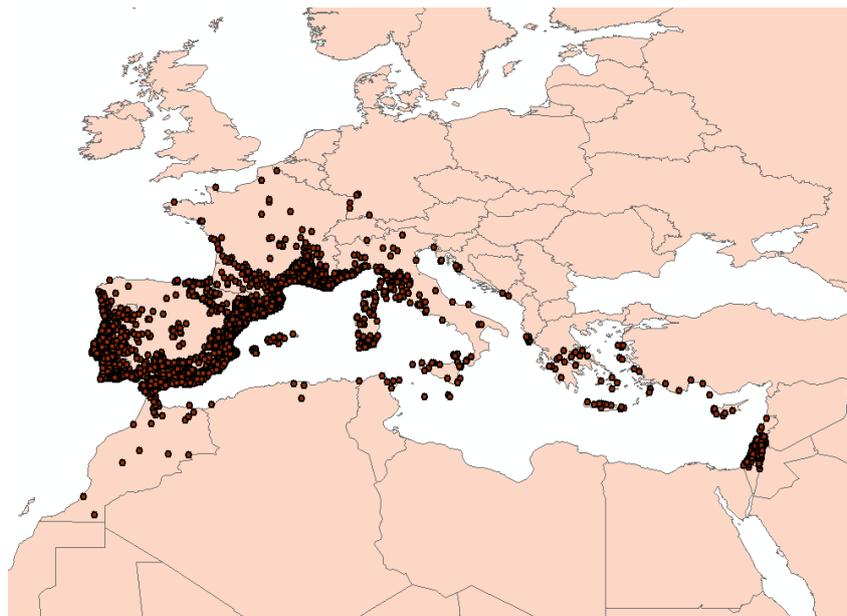


Figura 4. Mapa de presencias descargado del GBIF.

Estos datos (un total de 30.060, figura 4) recién descargados del GBIF serán debidamente procesados, de manera que las presencias que formen parte de la construcción del modelo compongan una distribución homogénea y en equilibrio con el área climática representada.

➤ Limpieza de presencias

La descarga de datos de fuentes externas no está exenta de errores, por lo que necesitaremos limpiar estos registros para mejorar la representatividad de nuestro futuro modelo. Sirviéndonos de Excel podremos filtrar los registros de ocurrencias y preparar la variable dependiente del modelo.

Entre los errores fácilmente detectables, encontramos puntos cuyas coordenadas poseen el valor 'Null' o (0,0), así como puntos situados sobre el océano. Si no eliminásemos estos registros, el modelo tomaría información climática de estos puntos para calcular las estimaciones. Por otra parte, debemos asegurarnos de no contar con registros duplicados, un error muy común en los sets de datos que descargamos de fuentes externas.

Un factor fundamental de cara a la limpieza de variables es la selección de la escala. Puesto que los datos climáticos se descargarán con la mayor precisión disponible (30 seg, aproximadamente 1 km²), es necesario escoger como presencias válidas aquellas recogidas con una precisión de coordenadas no inferior a 1 km².

Finalmente, el mapa de presencias seleccionadas es el siguiente (ver Figura 5), constituido por un total de 8561 datos. Se han eliminado los países mal representados así como el archipiélago canario, donde la especie está categorizada como exótica invasora.

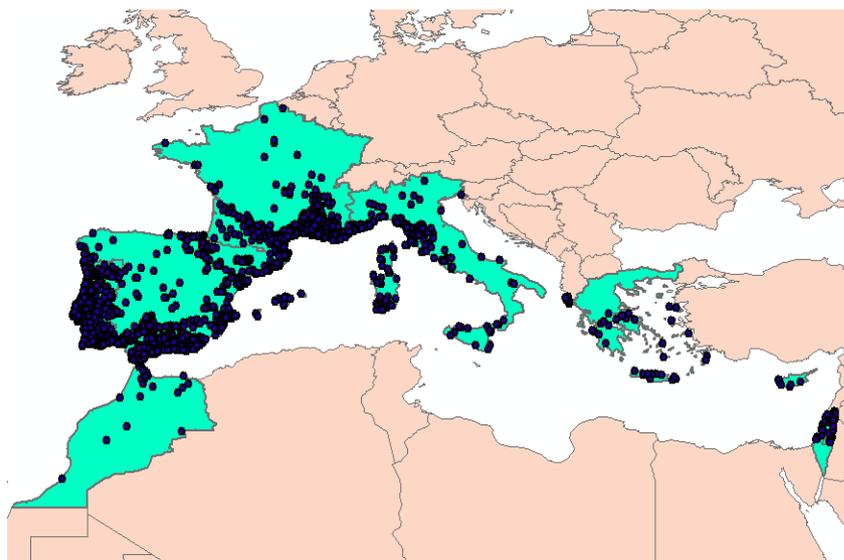


Figura 5. Mapa de presencias seleccionadas.

Datos climáticos

En la modelización por máxima entropía deberán conocerse los datos ambientales en las zonas de presencias empleadas para llevar a cabo las predicciones. Las variables climáticas presentes y futuras necesarias para el proyecto fueron descargadas desde WorldClim.org (Hijmans et al., 2005). Esta base de datos cuenta con capas rasterizadas de condiciones climáticas para su uso cartográfico para creación de modelos espaciales de todo el mundo. Por tanto, los datos son a escala mundial y han sido referenciados en el sistema WGS84.

WorldClim.org dispone de las series de datos en diferentes precisiones: 10 min (aproximadamente 340 km²), 5 y 2.5 minutos y 30 segundos (aproximadamente 1 km²). En este proyecto se ha trabajado con los datos de mayor precisión (30 seg). La información climática disponible queda caracterizada por las siguientes 19 variables bioclimáticas, recogidas en la Tabla 5.

Bio_1	Temperatura media anual
Bio_2	Rango diario de temperaturas (max-min)
Bio_3	Isotermalidad (Bio_2/Bio_7 *100)
Bio_4	Estacionalidad de la temperatura

Búsqueda de Indicadores Óptimos para la Defensa y Evaluación de la Biodiversidad Forestal ante el Cambio Climático (BIODEF-CC)

Bio_5	Temperatura máxima del mes más cálido
Bio_6	Temperatura mínima del mes más frío
Bio_7	Rango anual de temperaturas (Bio_5-Bio_6)
Bio_8	Temperatura media del trimestre más húmedo
Bio_9	Temperatura media del trimestre más seco
Bio_10	Temperatura media del trimestre más cálido
Bio_11	Temperatura media del trimestre más frío
Bio_12	Precipitación anual
Bio_13	Precipitación del mes más húmedo
Bio_14	Precipitación del mes más seco
Bio_15	Estacionalidad de la precipitación
Bio_16	Precipitación del trimestre más húmedo
Bio_17	Precipitación del trimestre más seco
Bio_18	Precipitación del trimestre más cálido
Bio_19	Precipitación del trimestre más frío

Tabla 5. Variables bioclimáticas disponibles. Fuente: WorldClim.org

➤ Establecimiento del *background*

En primer lugar, la caracterización climática debe tener un área acorde con la representación de la ocurrencia de la especie, ya que el modelo formará los datos de pseudoausencia a partir de la información del clima. Por este motivo hemos limpiado las presencias en los pasos anteriores, obteniendo un área suficientemente bien representada.

Esta área de trabajo compondrá nuestro *background* cuando ajustemos las capas climáticas descargadas a dicha extensión. Empleando la herramienta 'ExtractbyMask' de ArcGis obtendremos la información climática de nuestro área de estudio a partir de los datos globales descargados (véase Figura 6).



Figura 6. Establecimiento del *Background*.

Este proceso se ha realizado para las 19 variables descargadas. A continuación, debemos seleccionar el set definitivo de variables bioclimáticas a emplear, ya que el conjunto total de las 19 variables presenta problemas de correlación y colinealidad. En primer lugar, la información de cada variable será transferida a los puntos de presencia para obtener una tabla del siguiente tipo:

Latitud	Longitud	Bio 1	Bio 2	...	Bio 19
---------	----------	-------	-------	-----	--------

Tabla 6: Modelo de tabla generada para dar paso a la limpieza del set de variables.

➤ Filtros estadísticos

La precisión de los modelos dependerá en gran medida de la relación entre las variables empleadas. De este modo, la información que aporta cada variable es adoptada por Maxent dependiendo de la que ya albergan otras variables. Es necesario por tanto llevar a cabo un análisis estadístico del conjunto de variables que componen los datos climáticos para minimizar la información redundante, ya que este es uno de los factores que más alteran capacidad predictiva de los modelos.

Las variables bioclimáticas deben pasar unos filtros estadísticos (Moreno-Amat, 2017), de modo que la selección final del set de variables definitivo genere una cantidad mínima de información redundante. Los distintos análisis llevados a cabo se recogen en la Tabla 7.

Análisis	Evalúa	Software
'R' de Pearson	Correlación de las variables 2 a 2.	RStudio
VIF	Multicolinealidad en el set de variables climáticas.	RStudio

Tabla 7: Filtros estadísticos empleados para establecer el set definitivo de variables bioclimáticas.

i. R de Pearson

Para eliminar la repetición de variables climáticas de entrada que pudieran producir ruido en el modelo, este análisis pone en relación la información aportada por las variables comparadas entre sí dos a dos. Los números que sobrepasan un índice de Pearson de 0,75 serán tomados como valores de correlación inasumible.

	biomed1	biomed2	biomed3	biomed4	biomed5	biomed6	biomed7	biomed8	biomed9	biomed10	biomed11	biomed12	biomed13	biomed14	biomed15	biomed16	biomed17	biomed18	biomed19
biomed1	1,000	0,055	0,480	-0,397	0,475	0,752	-0,291	0,204	0,497	0,614	0,879	-0,497	-0,225	-0,769	0,814	-0,126	-0,805	-0,771	0,095
biomed2	0,055	1,000	0,064	0,553	0,682	-0,535	0,774	0,064	0,308	0,529	-0,255	-0,192	-0,202	0,091	-0,067	-0,241	0,060	0,011	-0,253
biomed3	0,480	0,064	1,000	-0,790	-0,248	0,596	-0,578	-0,159	-0,110	-0,221	0,718	-0,013	0,045	-0,554	0,623	0,279	-0,617	-0,606	0,520
biomed4	-0,397	0,553	-0,790	1,000	0,596	-0,844	0,954	0,176	0,258	0,476	-0,781	-0,087	-0,147	0,545	-0,576	-0,370	0,579	0,535	-0,590
biomed5	0,475	0,682	-0,248	0,596	1,000	-0,178	0,687	0,322	0,665	0,970	0,020	-0,521	-0,360	-0,165	0,142	-0,471	-0,166	-0,176	-0,469
biomed6	0,752	-0,535	0,596	-0,844	-0,178	1,000	-0,837	0,027	0,099	-0,001	0,949	-0,215	-0,030	-0,739	0,740	0,139	-0,755	-0,691	0,376
biomed7	-0,291	0,774	-0,578	0,954	0,687	-0,837	1,000	0,159	0,296	0,540	-0,689	-0,131	-0,178	0,454	-0,467	-0,364	0,465	0,412	-0,538
biomed8	0,204	0,064	-0,159	0,176	0,322	0,027	0,159	1,000	0,127	0,342	0,041	-0,317	-0,225	0,114	-0,092	-0,340	0,092	0,153	-0,495
biomed9	0,497	0,308	-0,110	0,258	0,665	0,099	0,296	0,127	1,000	0,701	0,210	-0,342	-0,152	-0,298	0,258	-0,234	-0,253	-0,303	-0,191
biomed10	0,614	0,529	-0,221	0,476	0,970	-0,001	0,540	0,342	0,701	1,000	0,176	-0,557	-0,351	-0,282	0,275	-0,445	-0,286	-0,287	-0,418
biomed11	0,879	-0,255	0,718	-0,781	0,020	0,949	-0,689	0,041	0,210	0,176	1,000	-0,303	-0,095	-0,816	0,834	0,090	-0,852	-0,799	0,359
biomed12	-0,497	-0,192	-0,013	-0,087	-0,521	-0,215	-0,131	-0,317	-0,342	-0,557	-0,303	1,000	0,896	0,514	-0,229	0,888	0,552	0,554	0,711
biomed13	-0,225	-0,202	0,045	-0,147	-0,360	-0,030	-0,178	-0,225	-0,152	-0,351	-0,095	0,896	1,000	-0,291	0,091	0,942	0,318	0,315	0,770
biomed14	-0,769	0,091	-0,554	0,545	-0,165	-0,739	0,454	0,114	-0,298	-0,282	-0,816	0,514	0,291	1,000	-0,768	0,132	0,971	0,936	-0,176
biomed15	0,814	-0,067	0,623	-0,576	0,142	0,740	-0,467	-0,092	0,258	0,275	0,834	-0,229	0,091	-0,768	1,000	0,225	-0,830	-0,815	0,426
biomed16	-0,126	-0,241	0,279	-0,370	-0,471	0,139	-0,364	-0,340	-0,234	-0,445	0,090	0,888	0,942	0,132	0,225	1,000	0,146	0,160	0,914
biomed17	-0,805	0,060	-0,617	0,579	-0,166	-0,755	0,465	0,092	-0,253	-0,286	-0,852	0,552	0,318	0,971	-0,830	0,146	1,000	0,973	-0,167
biomed18	-0,771	0,011	-0,606	0,535	-0,176	-0,691	0,412	0,153	-0,303	-0,287	-0,799	0,554	0,315	0,936	-0,815	0,160	0,973	1,000	-0,158
biomed19	0,095	-0,253	0,520	-0,590	-0,469	0,376	-0,538	-0,495	-0,191	-0,418	0,359	0,711	0,770	-0,176	0,426	0,914	-0,167	-0,158	1,000

Tabla 8. Resultado del análisis de correlación 2 a 2 mediante el factor 'r' de Pearson

Este primer análisis de correlación sugiere la aplicación de variables muy poco correlacionadas, tal y como la 3 (isotermalidad), 8 (temperatura media del trimestre más húmedo) y la 9 (temperatura media del trimestre más seco).

ii. VIF

El cálculo del Factor de Inflación de Varianza o VIF (*Variance Inflation Factor*) constituye un análisis matemático de cada variable predictora del modelo, utilizado para solventar los problemas de multicolinealidad entre las variables. La multicolinealidad representa la dependencia lineal entre las variables predictoras de un modelo, que causa imprecisión en la cuantificación del efecto que cada variable predictora (climática) ejerce sobre la variable dependiente (presencias) (Vega & Guzmán, 2011). En el presente proyecto se ha llevado a cabo el análisis del factor de inflación de varianza para describir los problemas de multicolinealidad en el análisis de regresión a fin de minimizar los efectos de inestabilidad en el modelo y la imposibilidad de interpretación. Las directrices utilizadas para llevar a cabo el análisis de los Factores de Inflación de Varianza son las recogidas en la Tabla 9.

VIF	Estado de los predictores
$FIV = 1$	No correlacionados
$1 < FIV < 5$	Moderadamente correlacionados
$FIV > 5$ a 10	Altamente correlacionados

Tabla 9: Directrices empleadas para eliminar variables según VIF. Fuente: R.org

El análisis de multicolinealidad por VIF se ha realizado mediante Rstudio. Este estudio se tomará como un criterio fiable para eliminar variables bioclimáticas, con el fin de establecer el set definitivo de variables. La eliminación de las diferentes variables se debe llevar a cabo una a una, eliminando en cada fase la variable más correlacionada. Esto significa que se eliminará la variable con peor estadística y se repetirá el análisis. Cuando todas las variables presenten un VIF inferior a 5 el set de variables podrá ser, a priori, considerado como válido.

Tras llevar a cabo el análisis del VIF se ha establecido un set definitivo compuesto por las siguientes variables:

Bio_2	Rango diario de temperaturas (max-min)
Bio_3	Isotermalidad (Bio_2/Bio_7 *100)
Bio_8	Temperatura media del trimestre más húmedo
Bio_9	Temperatura media del trimestre más seco
Bio_14	Precipitación del mes más seco
Bio_15	Estacionalidad de la precipitación
Bio_19	Precipitación del trimestre más frío

Tabla 10: Set definitivo de variables bioclimáticas

Vemos que este set cuenta con las variables de menor correlación analizada en el paso anterior (3, 8 y 9), por lo que los resultados confirman que estas variables han de ser empleadas en el modelo.

3. Resultados

3.1. Análisis de la meteorología y climatología de la zona de estudio

El estudio se ha desarrollado en las cuencas hidrográficas del Júcar y el Segura. Debido a la intrincada orografía de las cuencas hidrográficas del Júcar y el Segura la climatología de la zona es muy variada. Por lo que, para entender el comportamiento climático de la zona de estudio, y poder desarrollar mejor su estudio meteorológico, se ha partido de la clasificación climática de Koeppen-Geiger para extraer los climogramas típicos dentro de la zona de estudio (Figura 7).

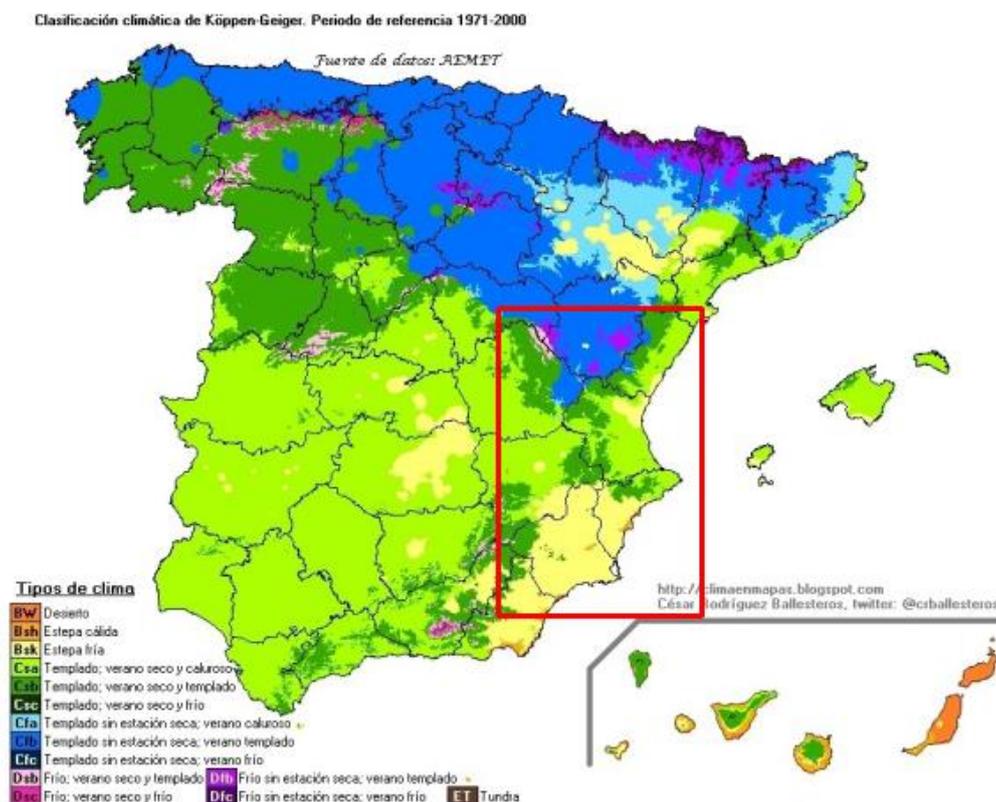


Figura 7. Clasificación climática de Köppen-Geiger para el periodo de referencia 1971-2000. Fuente de datos Aemet, fuente representación: @crballesteros

Así pues, la cuenca hidrográfica del Segura se puede asimilar al clima predominante: bsk, estepa fría, que coincide también bastante bien con la provincia de Murcia y la zona de Almería que pertenece a dicha Cuenca (Figura 8).

La Cuenca del Júcar es mucho más variada y compleja para poder extraer un climograma tipo, así que para discriminar diferentes comportamientos climáticos acordes con su orografía se ha asimilado que la zona montañosa del norte de la demarcación hidrográfica del Júcar (Cuenca y Teruel), se corresponde con una zona homogénea de temperaturas más bajas y lluvias más repartidas a lo largo del año, el clima medio que ha resultado según la clasificación de Köppen-Geiger ha sido el Csb, incumpliendo el criterio de precipitación mínima para la estación seca, no el de regularidad de lluvia, para no ser un Cfb (Figura 8).

Entre ambas ubicaciones, en la Cuenca del Júcar, tenemos una zona de transición; con unas temperaturas ligeramente más bajas que las del clima de la cuenca del Segura. Pero que a diferencia de esta e incluso del clima de la zona norte destaca por estar muy bien expuesta a los vientos mediterráneos húmedos, con lo que las acumulaciones de precipitación media anual son los mayores de las tres áreas en la provincia de Valencia, que se ha escogido como representativa de este tipo de clima: Csa. (Figura 10).

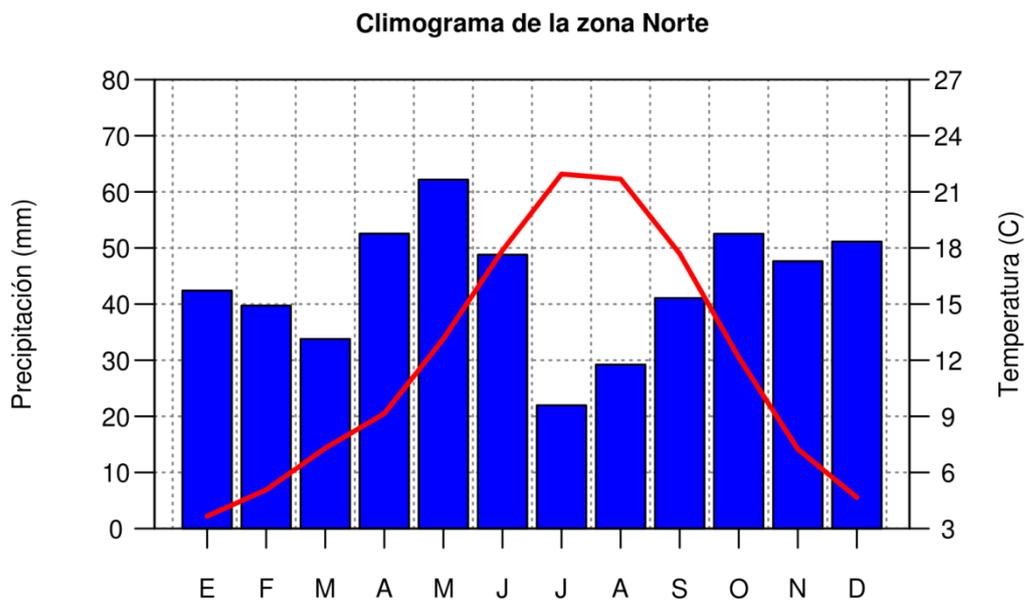


Figura 8. Climograma promedio para el periodo 1971-2000 del área norte de la zona de estudio. Clima (Csb), zona muy influenciada por el sistema Ibérico

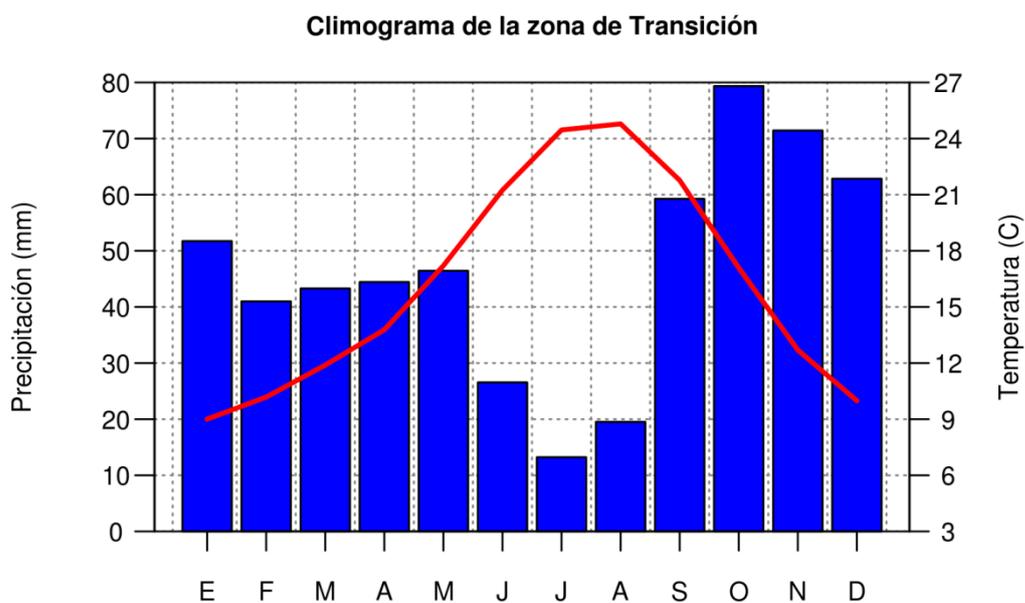


Figura 9. Climograma promedio para el periodo 1971-2000 del área de transición de la zona de estudio. Clima (Csa), zona muy influenciada por su apertura a los vientos mediterráneos

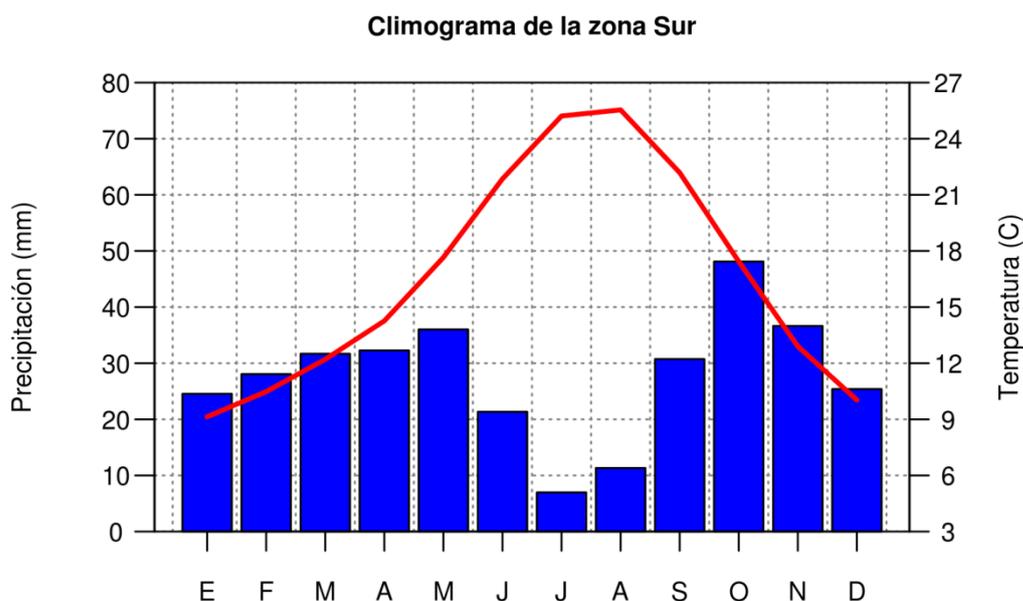


Figura 10. Climograma promedio para el periodo 1971-2000 del área sur de la zona de estudio. Clima (BSh), zona muy influenciada por la orografía al quedar a sotavento de la mayor parte de los vientos húmedos.

Una vez aproximados a los tipos de clima en los que estamos inmersos en cada zona se pueden estudiar las condiciones meteorológicas que favorecen la estratificación estable de la baja atmósfera y la mala ventilación por debajo de la capa límite que se suele dar con la presencia de inversiones térmicas. Existe gran cantidad de literatura sobre este fenómeno, como por ejemplo (Watson et al., 2015) o (Conesa et al., 2014), siendo este último a microescala en la zona del medio Segura.

Todos los datos meteorológicos a emplear (temperaturas máxima y mínima diarias del aire y precipitación diaria) se han obtenido de estaciones meteorológicas de la Agencia Estatal de Meteorología (AEMet). Dado que para el cálculo de los bioindicadores es necesario poseer datos tanto de precipitación como de temperatura, sólo se han considerado observatorios meteorológicos que tuvieran datos diarios de ambas variables. Además, y puesto que más adelante necesitaremos regionalizar los datos de los modelos climáticos sobre tales observatorios, necesitaremos imponer un número mínimo de datos observados en cada observatorio (para así caracterizar bien su clima), al menos 4.000 datos diarios en nuestro caso, lo que ha impuesto una nueva condición sobre los observatorios.

Antes de emplear tales datos se hace necesario un trabajo previo de control de calidad de los datos y de la homogeneización de éstos.

- El control de calidad de los datos consiste en desarrollar un conjunto de pruebas sobre tal serie que garantice que los datos son coherentes

dentro de la propia serie de estudio. Los dos controles automáticos principales a emplear en un control de calidad son:

- Coherencia básica. Rechazo directo de valores manifiestamente erróneos, como por ejemplo las precipitaciones negativas.
 - Puntos atípicos u *outliers*. Valores desacomodadamente atípicos dentro de un conjunto dado de datos, es decir, valores que parecen provenir de fuentes de datos diferentes o haber sido generados de una forma distinta al resto de los datos. En este caso, la dificultad teórica de su detección provendrá de la definición que hagamos de “atípicos”. En la práctica, la detección se refiere generalmente a valores de magnitud absoluta desacomodadamente alta.
- La homogeneización de los datos de una serie temporal hace referencia al control de calidad de los datos en tanto que elementos de una serie temporal, es decir, estudia la posible coherencia de los datos exactamente en el orden en el que son presentados. Nótese que los controles anteriores podrían realizarse sobre las mismas series pero desordenadas, pero no nos informan sobre la posible variabilidad temporal de los datos, algo que casi siempre viene ligado cuanto menos a ciclos anuales.

Debe hacerse notar que el proceso de homogeneización de una serie puede presentarse también como parte del proceso general del control de la calidad de los datos de una serie; si se presenta aquí como un punto separado es para subrayar la importancia de tal proceso y de sus resultados.

En la figura 11 podemos ver los datos reales de temperatura máxima diaria de un observatorio meteorológico real (que, aunque real, no se ha utilizado en este proyecto; sólo lo usamos aquí como un ejemplo del tipo de problema a ser detectado por las pruebas de homogeneidad).

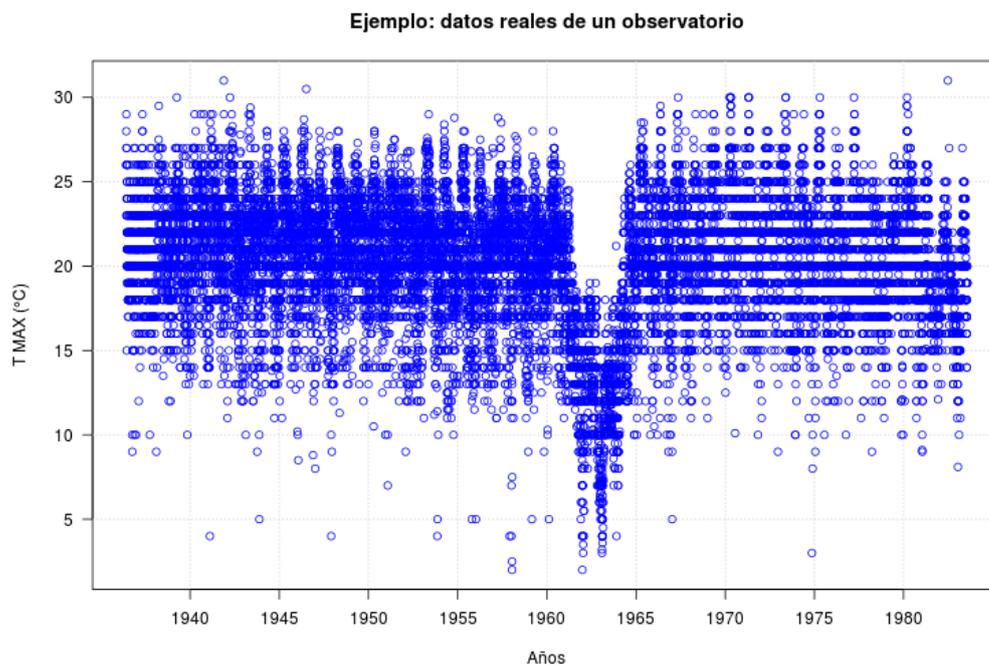


Figura 11. Serie observada diaria de temperatura máxima correspondiente a un observatorio real utilizado como ejemplo.

Podemos ver claramente que entre los años 1961 y 1964 este observatorio presenta un comportamiento irregular – irregular si es que lo comparamos con su comportamiento anterior y posterior en el tiempo, pero no por sí mismo ya que los valores que presenta no parecen por sí mismos irracionales. Es por eso por lo que este ejemplo real es ilustrativo de lo que los tests de detección de inhomogeneidades buscan encontrar: fragmentos temporales de la serie que parecen no encajar con el resto de la serie – y de hecho la serie suministrada como ejemplo ha sido encontrada precisamente gracias a estos tests. La dificultad de implementación formal de un test de inhomogeneidad vendrá dada por la definición que hagamos del parecido entre un tramo de nuestra serie y el resto de ésta.

Para realizar la búsqueda de inhomogeneidades, empleamos un test de comparación de distribuciones de Kolmogorov-Smirnov, un test estadístico no-paramétrico (que no presupone distribuciones de la variable a estudiar, por tanto) que nos proporciona un p-valor que podemos emplear como medida del parecido entre dos años. Si un cierto año ha sido marcado como posible indicador de inhomogeneidad entonces se le somete a una prueba más genérica, averiguando el p-valor de cada uno de los años de toda la serie con respecto a esos dos años. Si se presenta un salto o una ruptura entre todos esos p-valores en los años que estamos considerando entonces sí que se considera que tenemos una inhomogeneidad verdadera para toda la serie.

Tras el proceso de control de calidad y homogeneización de las series meteorológicas proporcionadas por los distintos modelos y considerando que deben disponer de datos tanto de temperatura como de precipitación se han seleccionado para el estudio 265 observatorios (figura 12).

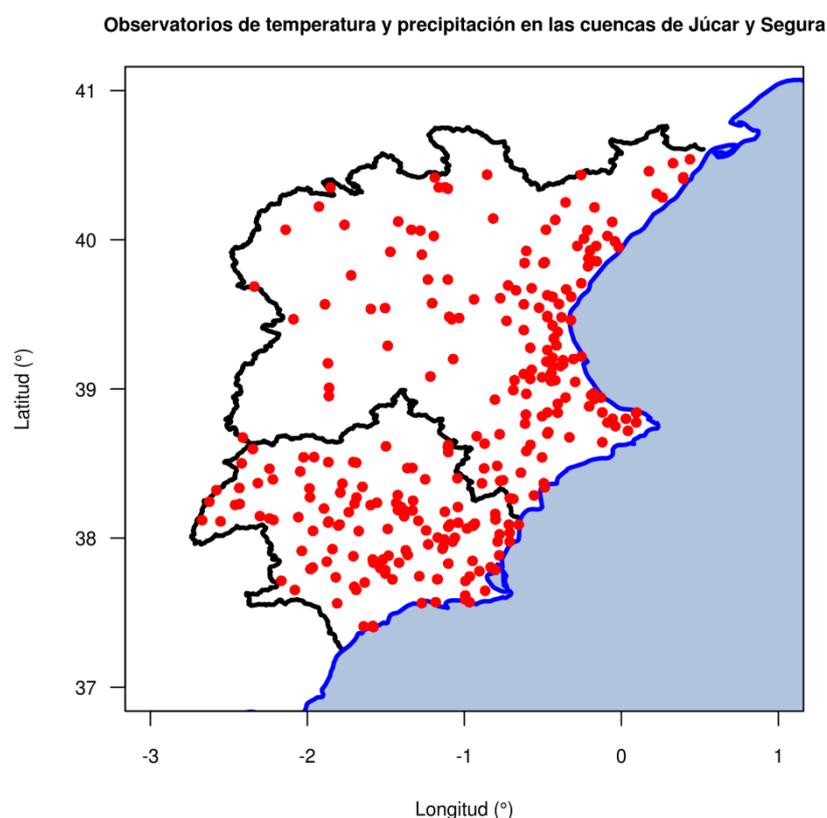


Figura 12. Observatorios con datos diarios suficientes tanto para temperatura como para precipitación seleccionados finalmente para el estudio.

3.2. Indicadores más apropiados para evaluar el estado de la biodiversidad forestal, incluyendo la biomasa, salud y diversidad

Selección de especies bioindicadoras para la Defensa y Evaluación de la Biodiversidad Forestal ante el Cambio Climático

Para la identificación de las especies bioindicadoras objeto de este estudio, teniendo en cuenta la sugerencia de I. García-Amorena (UPM) y Eduardo Lafuente Sacristán (Jefe del Servicio de Estudios Medioambientales de la Confederación Hidrográfica del Segura), se decide centrar el estudio en la **caña común** (*Arundodonax* L.). Actualmente esta especie se encuentra en zonas próximas a la costa, pero existe una preocupación en relación con la posibilidad de que el cambio climático afecte a las cabeceras de las cuencas mejor conservadas.

Como información inicial disponemos de las presencias aportadas por el Global BiodiversityInformationFacility (Figura 13). En esta figura se observa cómo en la región de Murcia la caña se encuentra representada de forma poco abundante, al igual que las zonas de Castilla la Mancha. Esto, en opinión de Eduardo Lafuente no responde a la realidad. Por lo que se propone la búsqueda de otras fuentes de datos adicionales (Junta de Castilla la Mancha, Universidad de Murcia, Confederación del Segura, Vaersa, Tragsa... etc.)

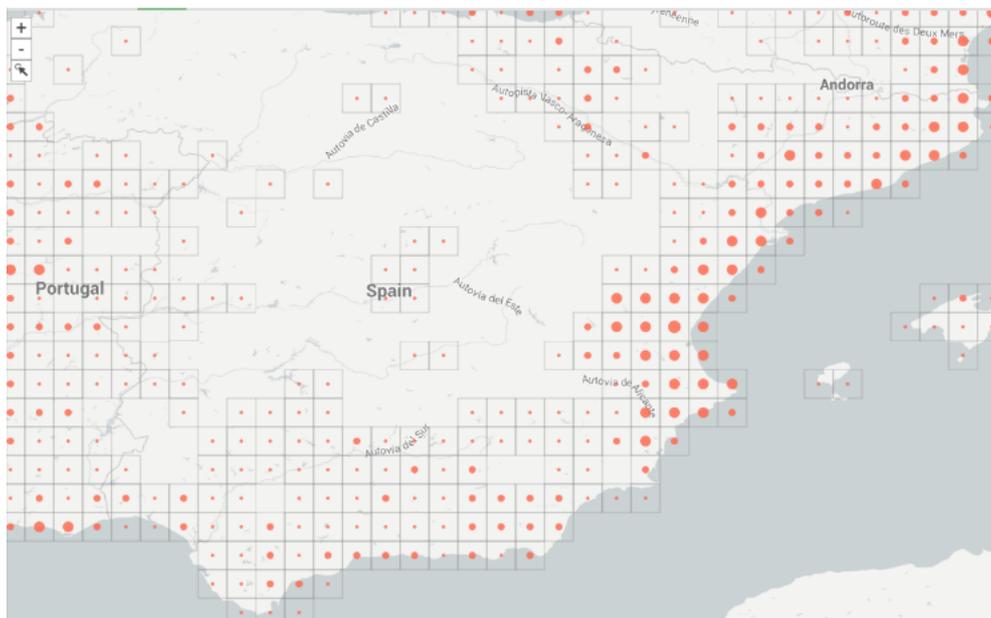


Figura 13: Mapa de presencias de A. donax en el cuadrante SE peninsular (Fuente: www.gbif.org – 07/11/2018)

Dada la problemática ambiental y de seguridad y salud que genera esta especie, se propone profundizar en las condiciones ambientales que limitan su crecimiento.

Distribución potencial actual en la España peninsular

El mapa obtenido representa la distribución potencial en condiciones climáticas actuales. Como se ha citado, esta modelización construye una predicción de la idoneidad climática de la especie. De hecho, este es uno de las desventajas del modelo, ya que no se tiene en cuenta la presencia de cauces fluviales, muy condicionante para la presencia de la especie.

Sin embargo, estos modelos nos permiten visualizar rápidamente las zonas de mayor probabilidad de expansión de la especie y se trata de una buena herramienta para establecer prioridades en la gestión y potenciar el proceso de toma de decisiones.

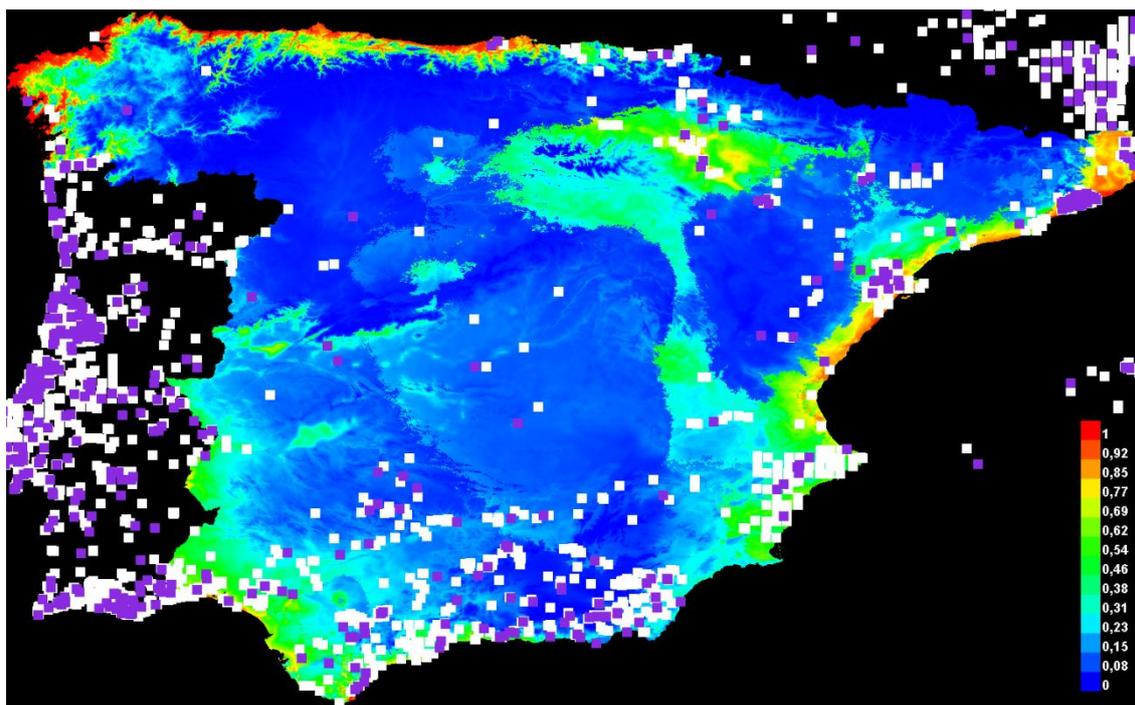


Figura 14. Este resultado muestra la proyección en España peninsular generada por el mejor modelo, es decir, aquel que muestra mayor estadístico AUC.

Los modelos son meras simplificaciones de la realidad, y debemos cuantificar de algún modo la calidad de sus predicciones. La bondad de los modelos se fundamenta en la evaluación del error cometido, medido como la proporción de casos clasificados erróneamente por el modelo (Mateo et al., 2011). Maxent permite evaluar este error mediante el estadístico AUC (*Area Under ROC Curve*). La curva ROC (*Receiving Operating Characteristics*) describe el error cometido por omisión de presencias o inclusión de falsas presencias mediante la representación de sensibilidad (ordenadas) y especificidad (abscisas) (véase Figura 15).

El área bajo la curva ROC, el estadístico AUC, caracteriza la probabilidad de que al escoger aleatoriamente un dato de presencia y otro de pseudoausencia, el modelo asigne a la presencia un mayor valor de idoneidad, repitiendo el proceso para todos los pares de datos posibles en la muestra (Mateo et al., 2011).

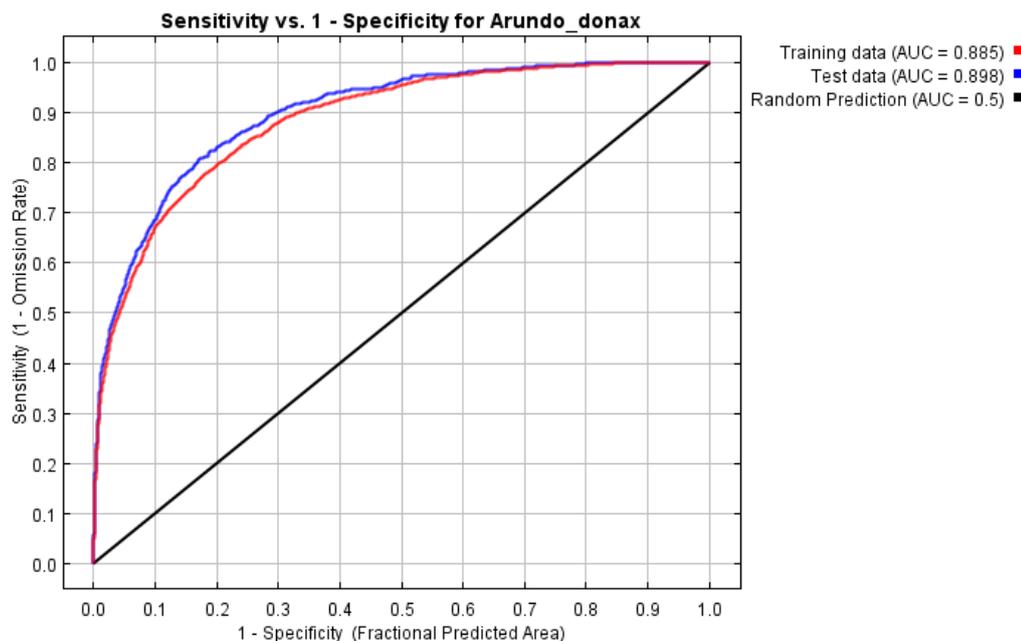


Figura 15. Area Under the ROC Curve (AUC)

Este estadístico AUC toma un valor entre 0 y 1; un valor AUC igual a 1 significa la plena capacidad del modelo para asignar la correcta idoneidad y 0,5 implicaría la nula capacidad para diferenciar los datos escogidos aleatoriamente.

Efecto de las variables del set empleado en la modelización

A continuación, se presentan las distintas curvas de respuesta obtenidas con Maxent, que muestran el efecto de cada una de las variables en la probabilidad de presencia. En estas curvas de respuesta se representan los valores que va tomando cada variable (eje de abscisas) frente a la probabilidad de presencia predicha por el modelo (eje de ordenadas).

Esta información es de gran utilidad ya que nos permite conocer mejor la respuesta que da la especie frente a las distintas características climáticas del entorno por separado. En particular, los datos de temperatura aparecen representados en $^{\circ}\text{C} \cdot 10$.

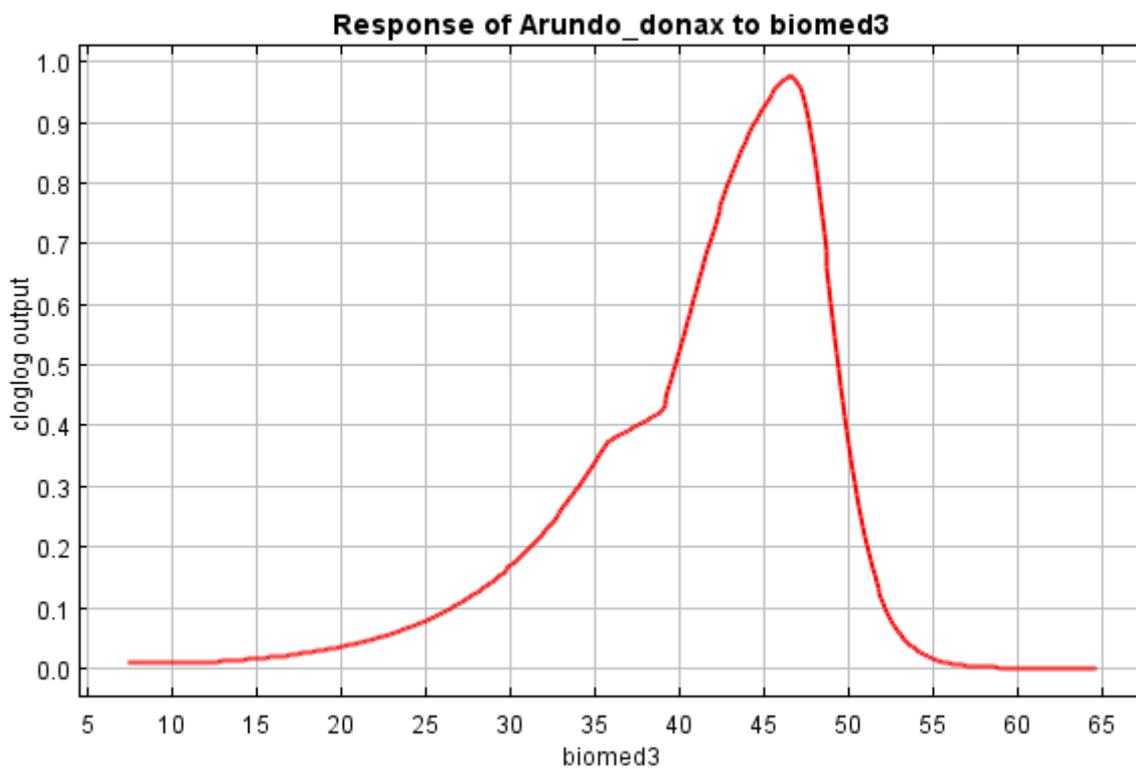


Figura 16: Curva de respuesta para la variable 3 (Isotermalidad)

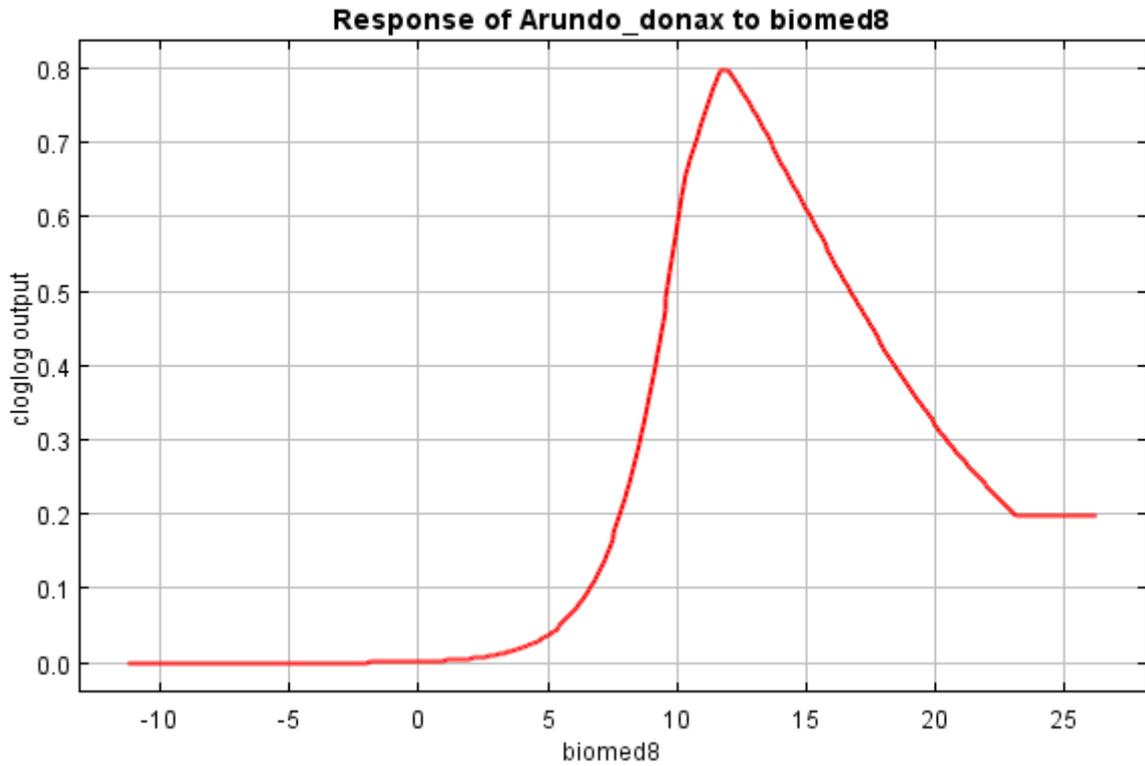


Figura 17: Curva de respuesta para la variable 8 (Temperatura media del trimestre más húmedo)

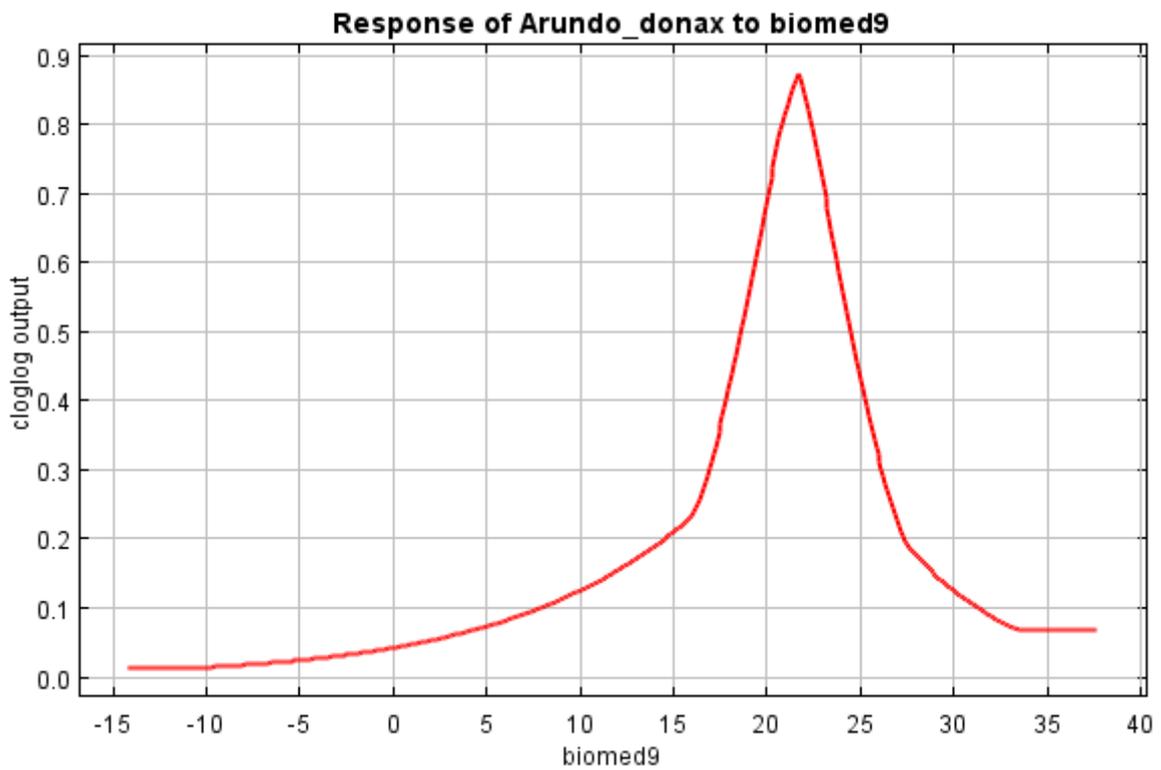


Figura 18: Curva de respuesta para la variable 9 (Temperatura media del trimestre más seco)

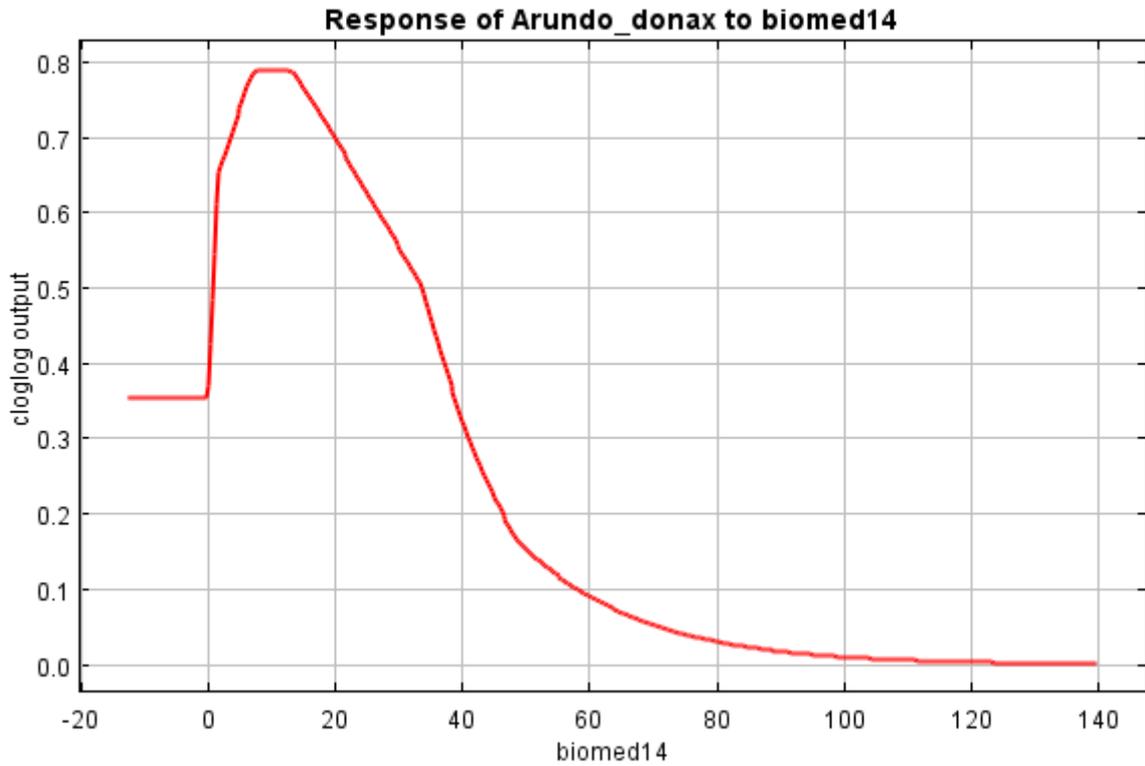


Figura19: Curva de respuesta para la variable 14 (Precipitación del mes más seco)

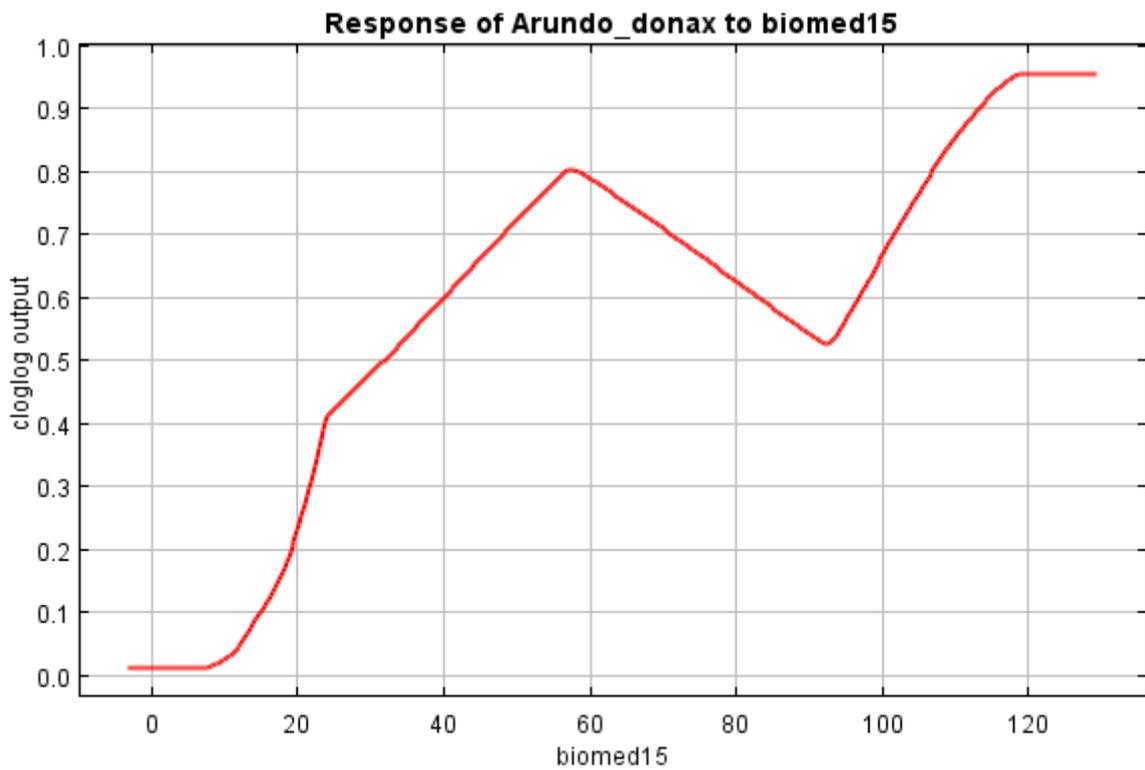


Figura 20: Curva de respuesta para la variable 15 (Estacionalidad de la precipitación)

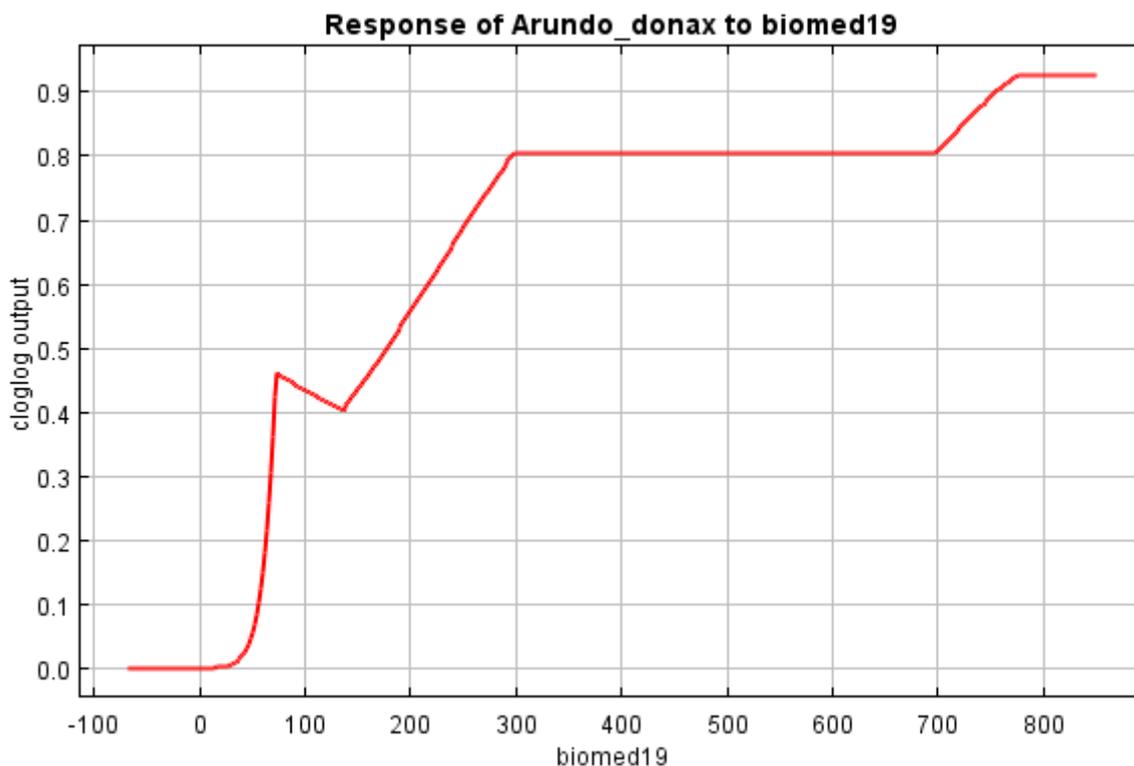


Figura 21: Curva de respuesta para la variable 19 (Precipitación del trimestre más frío)

Selección de bioindicadores óptimos para la defensa de la biodiversidad forestal en las cuencas del Júcar y Segura

En base a los análisis presentados, se han seleccionado como **indicadores óptimos**, aquellas variables dentro del set que ofrecen un patrón claro de la probabilidad de presencia: *Bio2 (Continentalidad diurna)*, *Bio8 (Temperatura media del trimestre más húmedo)*, *Bio14 (Precipitación del mes más seco)* y *Bio19 (Precipitación del trimestre más húmedo)*

Búsqueda de Indicadores Óptimos para la Defensa y Evaluación de la Biodiversidad Forestal ante el Cambio Climático (BIODEF-CC)

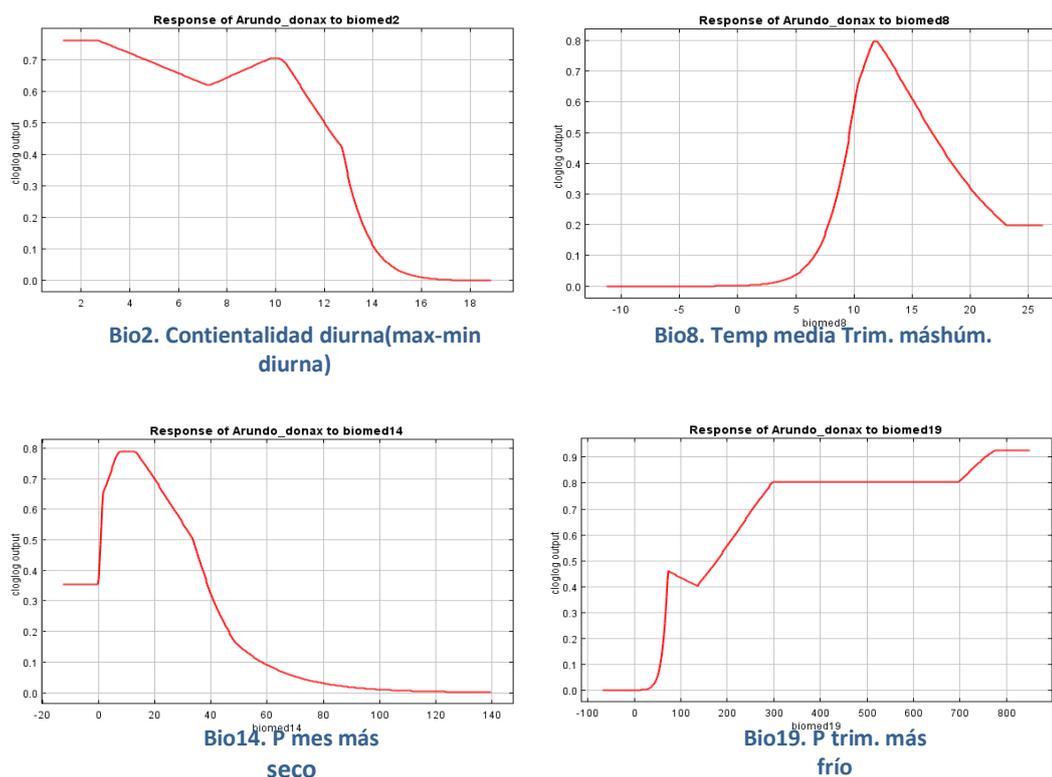


Figura 22. Indicadores óptimos

Para dichos indicadores, se proponen como umbrales para la detección de un aumento alarmante de probabilidad de la presencia de *Arundodonax* frente al cambios climáticos, aquellos valores correspondientes al umbral “*Maximum test sensitivity plus specificity*” generado por el modelo (0.29). Es decir, se propone prestar atención a los valores de cada variable que hagan subir la probabilidad de presencia por encima de 0.29.

En el caso de la *continentalidad diurna* se observa que la probabilidad descende de 0.3 en torno a los 13°C de diferencia entre máxima y mínima diaria. Del mismo modo, la *temperatura media del trimestre más húmedo* favorece la presencia de especie mientras se encuentre entre 10 y 20°C.

Cuando analizamos los patrones relacionados con el régimen pluviométrico podemos observar que la probabilidad se mantiene por encima de 0.3 con bajas precipitaciones en el mes más seco (entre 0 y 40 mm) y altas precipitaciones en el mes más frío (por encima de 100mm, con probabilidad cercana a la máxima a partir de los 300mm). Esto denota el carácter de la especie, que parece presentar afinidad por el régimen hídrico estacional.

3.3. Proyecciones de escenarios de clima futuro

Como se ha comentado en el apartado de metodología, antes de generar los escenarios de clima futuro han de llevarse a cabo los procesos de verificación y

validación que nos permiten corregir el error sistemático a las series “puras” para obtener los escenarios futuros finales.

En los cálculos de bioindicadores para las próximas décadas las variables meteorológicas usadas han sido:

Campo	Fuente
Temperatura	Obtenida mediante <i>downscaling</i> de cada uno de los modelos climáticos y para los RCPs 4.5 y 8.5.
Precipitación	Obtenida mediante <i>downscaling</i> de cada uno de los modelos climáticos y para los RCPs 4.5 y 8.5.

Tabla 11. Relación de variables meteorológicas necesarias en la simulación de bioindicadores.

Los modelos climáticos que se han utilizado en el estudio y sus características se resumen en la tabla 12.

Climatic Model	Spatial /temporal Resolution	Research Center	References
GFDL-ESM2M	2 ^o x2,5 ^o daily	National Oceanic and Atmospheric Administration (NOAA), E.E.U.U.	Dunne et al. (2012)
CanESM2	2,8 ^o x2,8 ^o daily	Canadian Centre for Climate Modeling and Analysis (CC-CMA), Canadá.	Chylek et al. (2011)
CNRM-CM5	1,4 ^o x1,4 ^o daily	CNRM (Centre National de Recherches Meteorologiques), Meteo-France, Francia.	Voltaire et al. (2013)
BCC-CSM1-1	1,4 ^o x1,4 ^o daily	Beijing Climate Center (BCC), China Meteorological Administration, China.	Xiao-Ge et al. (2013)
HADGEM2-CC	1,87 ^o x1,25 ^o daily	Met Office Hadley Center, United Kingdom.	Collins et al. (2008)
MIROC-ESM-CHEM	2,8 ^o x2,8 ^o daily	Japan Agency for marine-Earth Science and Technology (JAMSTEC), Atmosphere and Ocean Research Institute (AORI), and National Institute for Environmental Studies (NIES), Japan.	Watanabe et al. (2011)
MPI-ESM-MR	1,8 ^o x1,8 ^o daily	Max-Planck Institute for Meteorology (MPI-M), Germany.	Raddatz et al. (2007); Marsland et al. (2003)
MRI-CGCM3	1,2 ^o x1,2 ^o daily	Meteorological Research Institute (MRI), Japan.	Yukimoto et al. (2011)
NorESM1-M	2,5 ^o x1,9 ^o daily	Norwegian Climate Centre (NCC), Norway.	Bentsen et al. (2012); Iversen et al. (2012)

Tabla 12. Relación de modelos climáticos usados en el estudio.

Verificación de la metodología

La verificación es un proceso en el cual se analiza la capacidad de la metodología aplicada para simular el clima pasado; en este caso se comparan las series de observaciones simuladas mediante la regionalización del reanálisis ERA40 (tanto de precipitación como de temperatura) con las observaciones reales del periodo común (1958-2000) de la zona de estudio.

En cuanto a la variable de Temperatura, los resultados de la verificación son bueno, con unos valores de MAE notablemente por debajo de aquellos que se obtendrían mediante el mero uso de la climatología como predictor, cometiendo un error medio inferior a 2°C en la predicción diaria. El Bias se comporta de la manera esperada, con un valor aproximado de 0 (Figura 23).

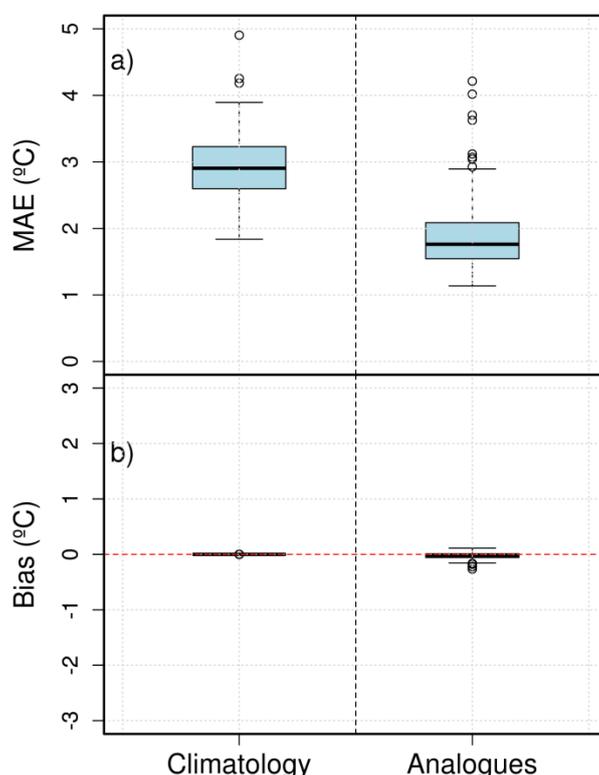


Figura 23. Resultados del proceso de verificación de la Temperatura donde se han comparado los resultados de regionalizar el ERA40 frente a datos observados para las estaciones de las cuencas hidrográficas del Segura y del Júcar (derecha). Con el fin dar calidad a los resultados, se representa a la izquierda los resultados de tomar de referencia la climatología de cada estación. Los estadísticos empleados son el MAE (a) y el Bias (b).

Respecto a la Precipitación, los resultados de los estadísticos son muy satisfactorios. El valor del MAE se encuentra bajo el de la climatología, con un error medio de menos de 2mm. El Bias se sitúa en torno a 0, mientras que en el test KS la mediana de las estaciones se haya por encima del valor umbral de

la significancia, lo que mostraría que la distribución de datos obtenida del downscaling presenta un comportamiento igual a la serie observada original (Figura 24).

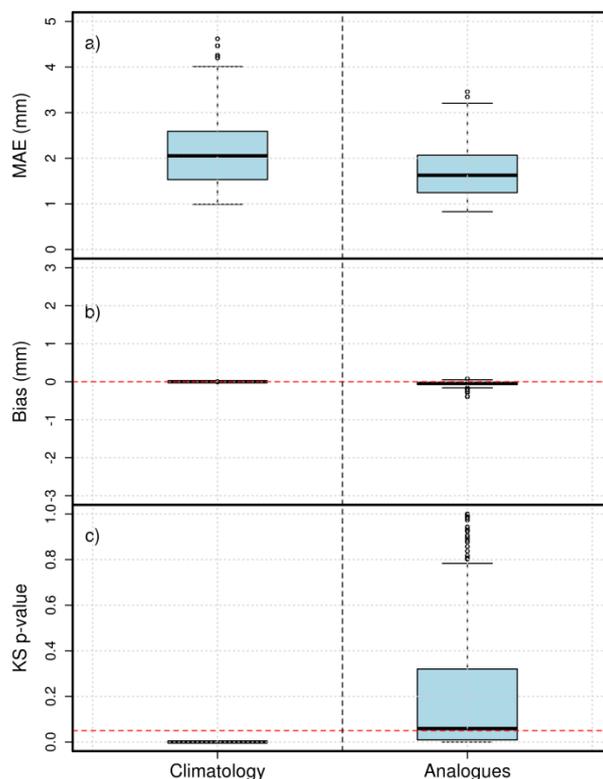


Figura 24. Resultados del proceso de verificación de la Precipitación donde se han comparado los resultados de regionalizar el ERA40 frente a datos observados para las estaciones de las cuencas hidrográficas del Segura y del Júcar (derecha). Con el fin dar calidad a los resultados, se representa a la izquierda los resultados de tomar de referencia la climatología de cada estación. Los estadísticos empleados son el MAE (a), el Bias (b) y el test Kolmogorov-Smirnov (c).

Validación de la metodología

Mediante la validación, se estudia el error introducido por el Modelo de Circulación General (MCG) utilizado. Para ello se comparan las series obtenidas al regionalizar las salidas de control del modelo con las series obtenidas mediante la aplicación de la metodología FICLIMA verificada con anterioridad sobre las proyecciones de los MCG para un periodo común (1958-2000). Los modelos climáticos utilizados en el estudio se resumen en la tabla 7.

Los resultados obtenidos de la validación de la variable Temperatura son buenos. El estadístico Bias muestra una tendencia general de los modelos a sobreestimar el valor de la temperatura alrededor de 0,5 o C, siendo en CNRM-CM5 el modelo con el menor sesgo. La relación de SD es buena para prácticamente todos los modelos, con una SD semejante a la observada, con la excepción del GFDL-ESM2M, cuyo cociente es elevado. El test KS es ampliamente aprobado por todos los modelos (Figura 25).

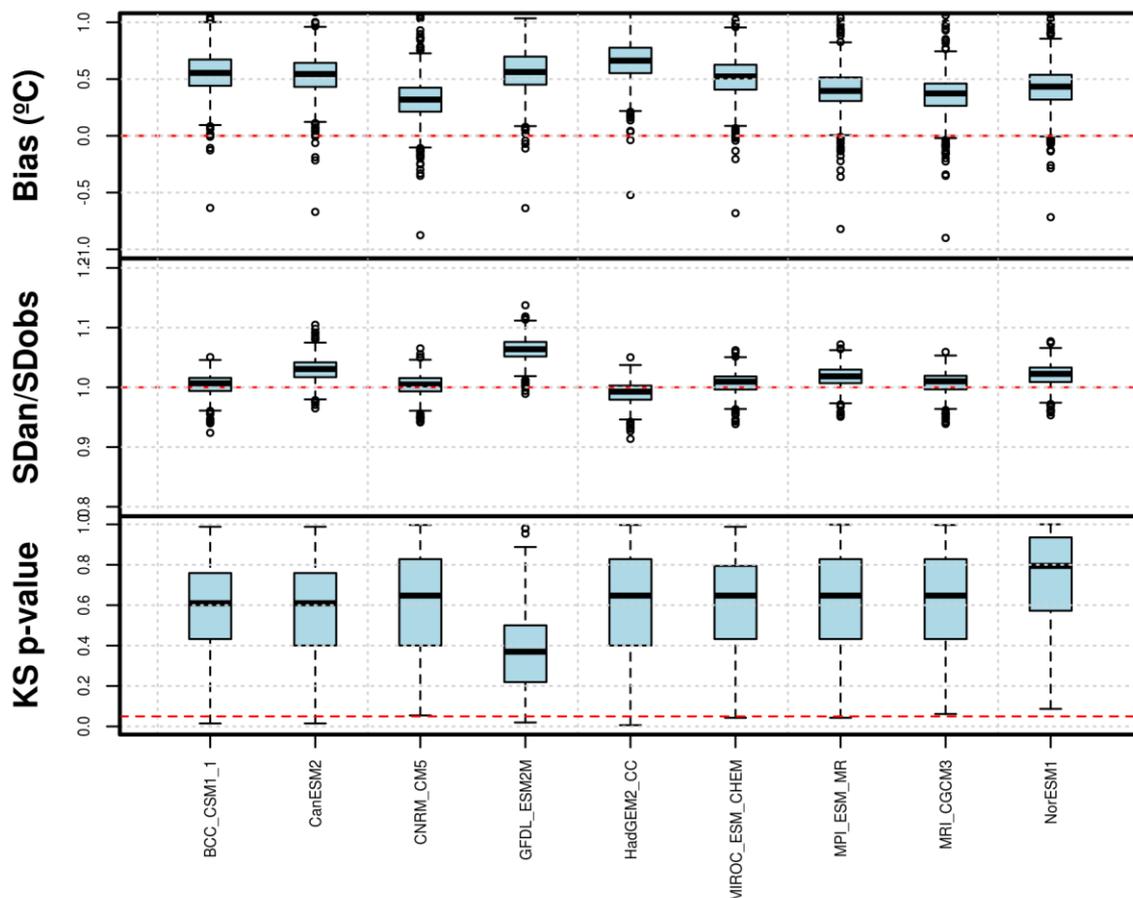


Figura 25. Resultados del proceso de validación de la Temperatura para los MCG regionalizados a las estaciones de las cuencas hidrográficas del Segura y del Júcar. Los estadísticos empleados son el Bias (superior), el cociente entre sendas SD (medio) y el test Kolmogorov-Smirnov (inferior).

Respecto a la Precipitación los resultados son igualmente muy buenos. Se observa que, en este caso, los modelos tienden a subestimar ligeramente el total de precipitación, entre 0 y -0.15mm/día en el peor de los casos. La relación de SD es buena con la salvedad del modelo MIROC-ESM-CHEM, cuyo valor es algo bajo comparado al resto. En cuanto al test KS entre la salida de control de los MCG y la obtenida mediante el método FICLIMA, todos los modelos lo superan con creces, lo que muestra la buena similitud entre ambas distribuciones (Figura 26).

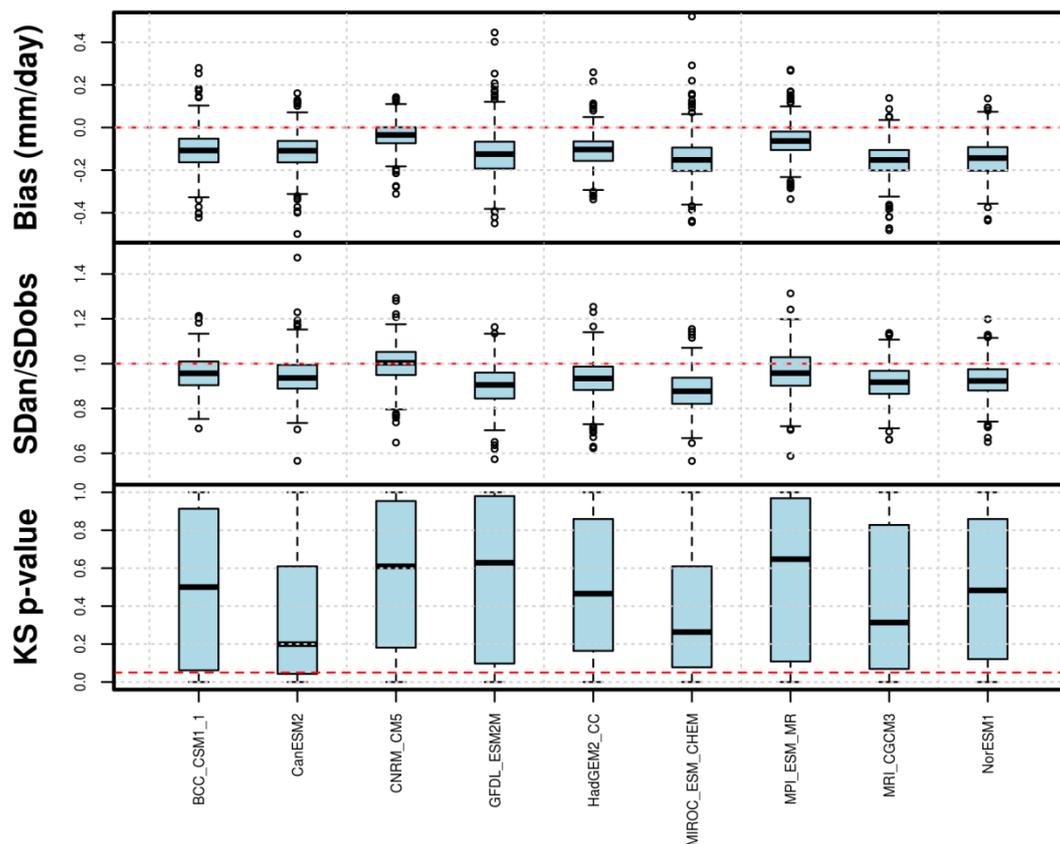


Figura 26. Resultados del proceso de validación de la Precipitación para los MCG regionalizados a las estaciones de las cuencas hidrográficas del Segura y del Júcar. Los estadísticos empleados son el Bias (superior), el cociente entre sendas SD (medio) y el test Kolmogorov-Smirnov (inferior).

Escenarios climáticos futuros de Temperatura

La media anual de temperaturas máximas sufrirá un incremento paulatino hasta el año 2050. Este incremento se situará entre los 1.7°C y los 2.2°C hacia mitad de siglo respecto al período de referencia. Este aumento de temperatura tenderá a ser mayor en verano y otoño, con subidas de hasta 3° (figura 27).

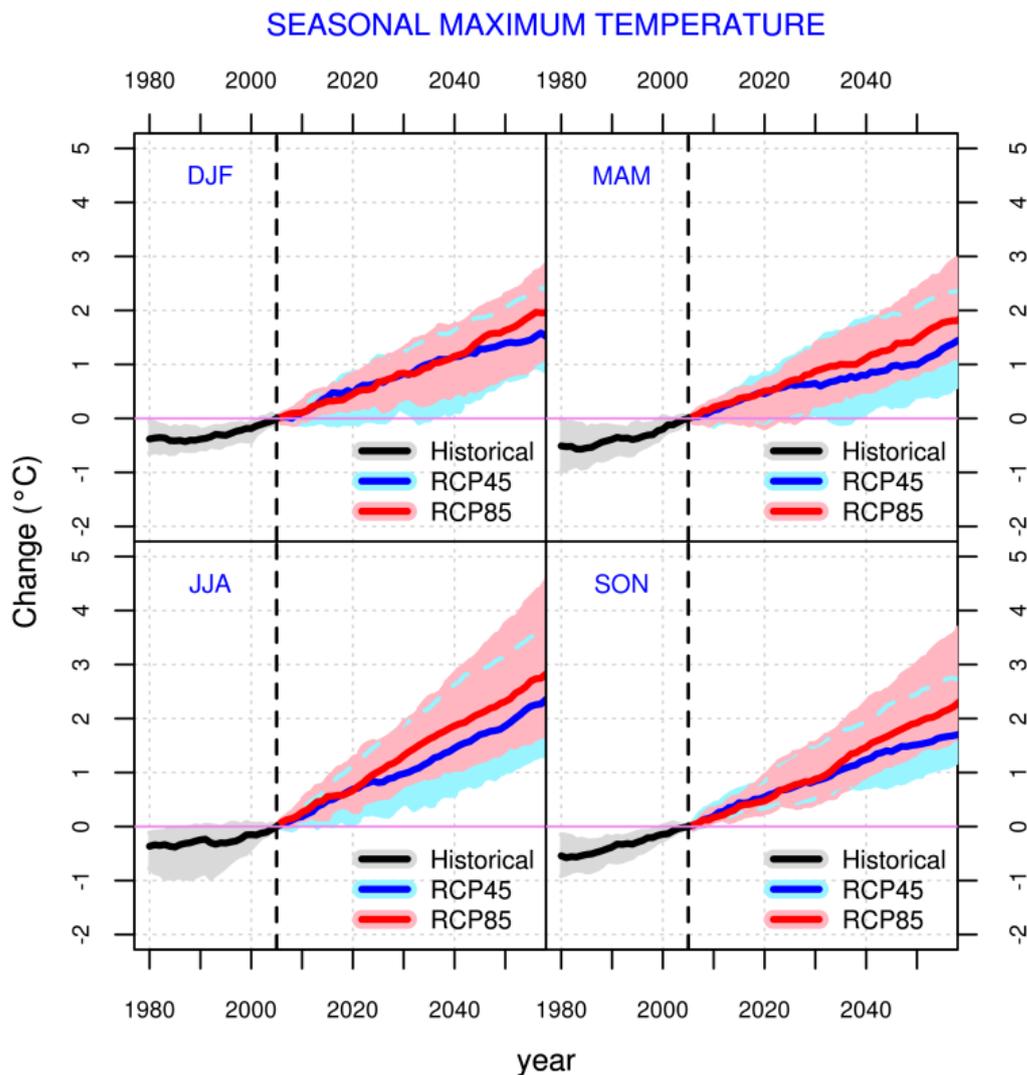


Figura 27. Incrementos estacionales relativos esperados de la Temperatura Máxima para el siglo XXI, representados como medias móviles de 30 años, según los RCPs representados (4.5, y 8.5) con respecto al promedio del periodo 1971 – 2000 (tomado como referencia). La línea discontinua marca el fin del experimento *Historical* y el comienzo de los RCPs. Simulaciones de todos los modelos sobre todos los observatorios. Las líneas muestran la mediana de todos los valores; las sombras cubren desde el percentil 10 hasta el 90

En el caso de las temperaturas mínimas, se observa una tendencia similar pero más atenuada. Los incrementos de temperatura se situarán entre 1.5°C y 2.0°C, pudiendo alcanzar en los meses de verano subidas de hasta 2.5°C (figura 28).

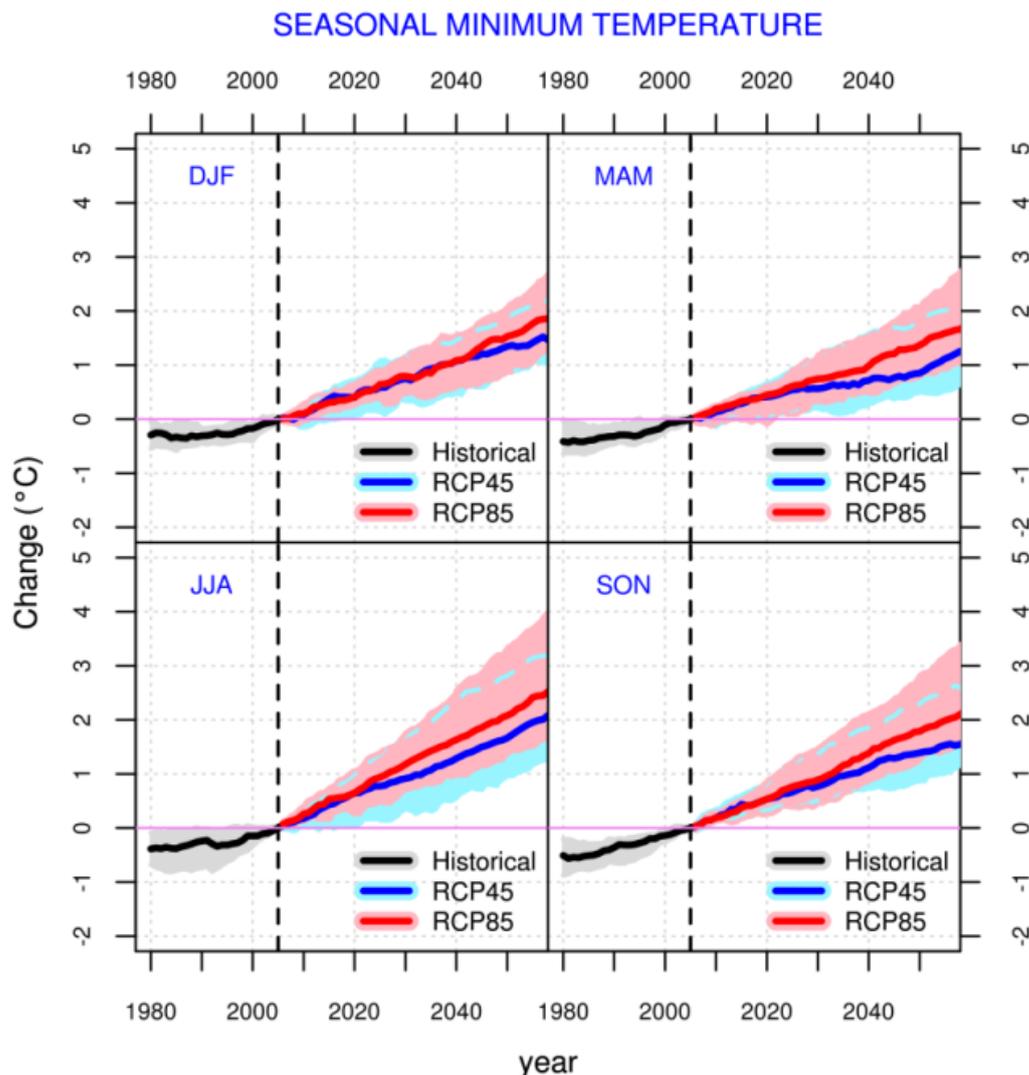


Figura 28. Incrementos estacionales relativos esperados de la Temperatura Mínima para el siglo XXI, representados como medias móviles de 30 años, según los RCPs representados (4.5, y 8.5) con respecto al promedio del periodo 1971 – 2000 (tomado como referencia). La línea discontinua marca el fin del experimento *Historical* y el comienzo de los RCPs. Simulaciones de todos los modelos sobre todos los observatorios. Las líneas muestran la mediana de todos los valores; las sombras cubren desde el percentil 10 hasta el 90

Escenarios climáticos futuros de Precipitación

La precipitación presenta distintas tendencias dependiendo de la estación del año que se analice. Exceptuando los meses de primavera, la precipitación tiende a disminuir ligeramente, alcanzando en el año 2050 un descenso medio de entre un 4% y un 6%. Esta tendencia descendente será más marcada en los meses de otoño, con disminuciones de hasta un 10%. En cambio, en primavera las proyecciones más probables sugieren un ligero aumento de la precipitación, que podría ser de hasta un 8% (figura 29). Hay que resaltar que todas estas tendencias presentan un nivel muy alto de incertidumbre, habiendo un abanico de proyecciones que sugieren desde descensos en la precipitación de un 20% hasta aumentos de un 20%.

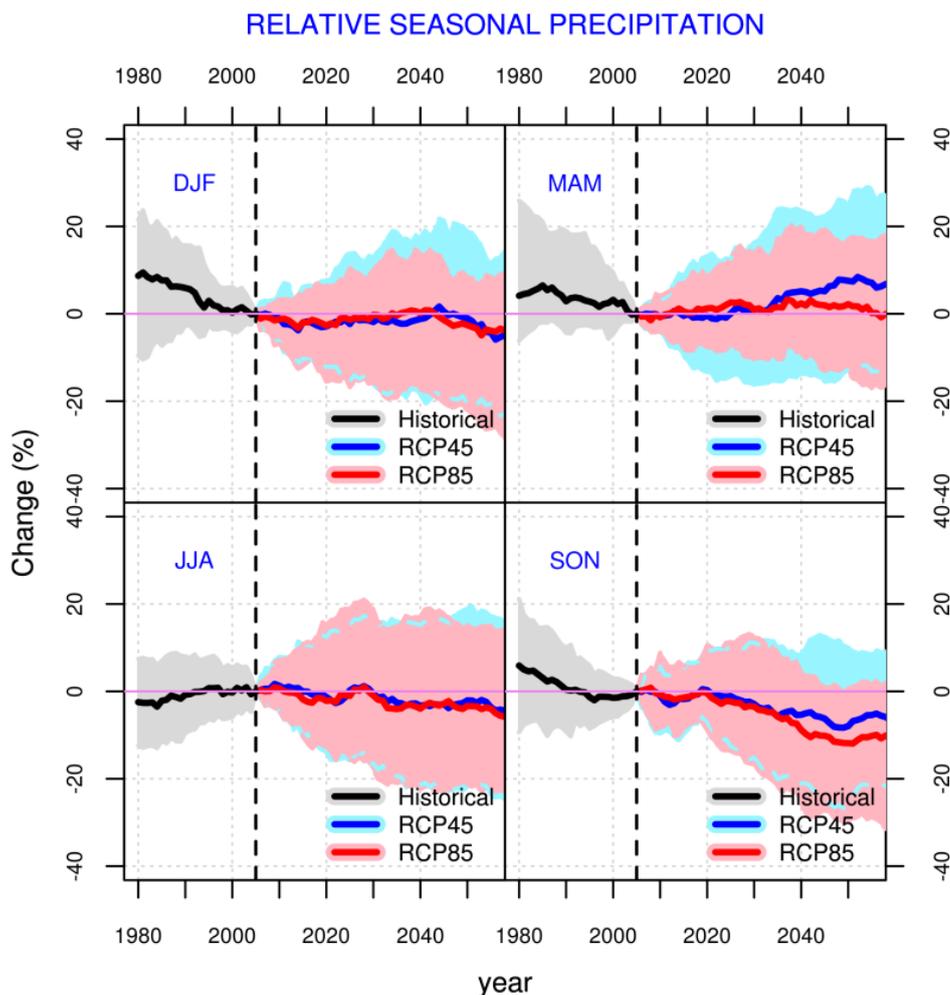


Figura 29. Incrementos estacionales relativos esperados de la Precipitación para el siglo XXI, representados como medias móviles de 30 años, según los RCPs representados (4.5, y 8.5) con respecto al promedio del periodo 1971 – 2000 (tomado como referencia). La línea discontinua marca el fin del experimento *Historical* y el comienzo de los RCPs. Simulaciones de todos los modelos sobre todos los observatorios. Las líneas muestran la mediana de todos los valores; las sombras cubren desde el percentil 10 hasta el 90

A continuación, se resumen los cambios esperados en función de la variable considerada.

	DEF	MAM	JJA	SON	ANUAL
Tmax	+1.6/+2.0	+1.5/+1.9	+2.4/+2.9	+1.8/+2.3	+1.7/+2.2
Tmin	+1.5/+1.9	+1.2/+1.8	+2.0/+2.5	+1.6/+2.1	+1.6/+2.0
Precipitación (mm/día)	-0.05/-0.10	0.0/+0.1	0.00	-0.10/-0.15	-0.05/-0.10
Precipitación (%)	-4.0/-6.0	0.0/+8.0	-4.0/-5.0	-5.0/-10.0	-3.0/-6.0

Tabla 13. Resumen de los resultados obtenidos como valor promedio de todos los modelos climáticos y todos los observatorios utilizados en el estudio representando la variación de cada variable en el periodo 2020-2050 con respecto al periodo de control 1976-2050. En azul valores correspondientes al RCP4.5 y en negro los correspondientes al RCP8.5.

3.4. Análisis de la vulnerabilidad y probabilidad de plagas y enfermedades de los bosques bajo diferentes condiciones climáticas de acuerdo con los índices seleccionados

Mediante modelización por máxima entropía se está modelizando la idoneidad climática de la especie para unas condiciones ambientales actuales o futuras, a partir de la distribución natural actual.

Distribución potencial futura

Se ha empleado la modelización con Maxent para obtener mapas de idoneidad climática bajo distintos escenarios de cambio climático. Se han planteado dos escenarios (4.5 W/m^2 y 8.5 W/m^2) ambas para el año 2070. Los MCG que se han utilizado quedan recogidos en la Tabla 14.

CGM	Institución	País
MPI-ESM-MR	Max Planck Institute for Meteorology	Alemania
HadGEM2	Met Office Hadley Centre ESM	UK

Tabla 14: MCG empleado en las predicciones bajo escenarios de cambio climático.

En todos los escenarios se una clara tendencia de la idoneidad climática de la especie, la cual se prevé que aumente considerablemente en el tercio norte peninsular. Presumiblemente, esto se deberá a la pérdida de influencia atlántica en el clima predominante del norte.

Habiendo analizado la respuesta de cada una de las variables, se observa una clara afinidad por regímenes climáticos estacionales, con altas precipitaciones en invierno (variable 19) pero bajas o muy bajas precipitaciones en verano (variable 14). Este carácter puede explicar la alta afinidad climática que presentaría a finales de siglo el norte de la península, en especial en los escenarios más pesimistas.

i. **MPI-ESM-MR: Escenario 4.5 W/m²**

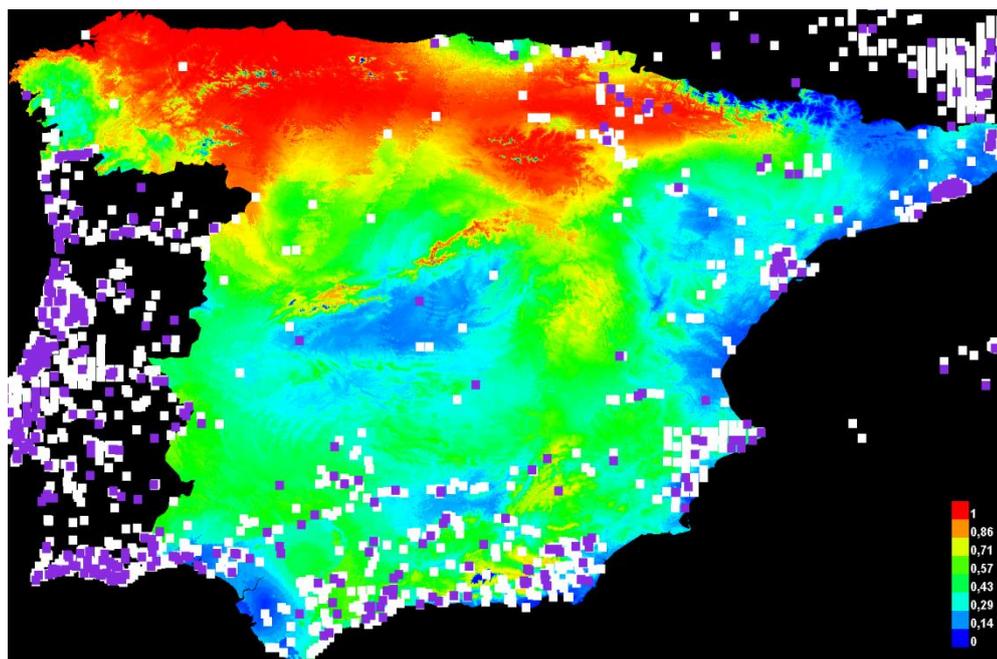


Figura 30: Modelo de idoneidad climática generado a partir **MCG MPI-ESMR-MR** bajo el escenario de **4.5 W/m²** para el año 2070. Queda representada la probabilidad de presencia de la especie entre 0 (azules) y 1 (rojos). El modelo presentó un **AUC** de 0.889 en el entrenamiento y 0.886 en el test.

ii. **MPI-ESM-MR: Escenario 8.5 W/m²**

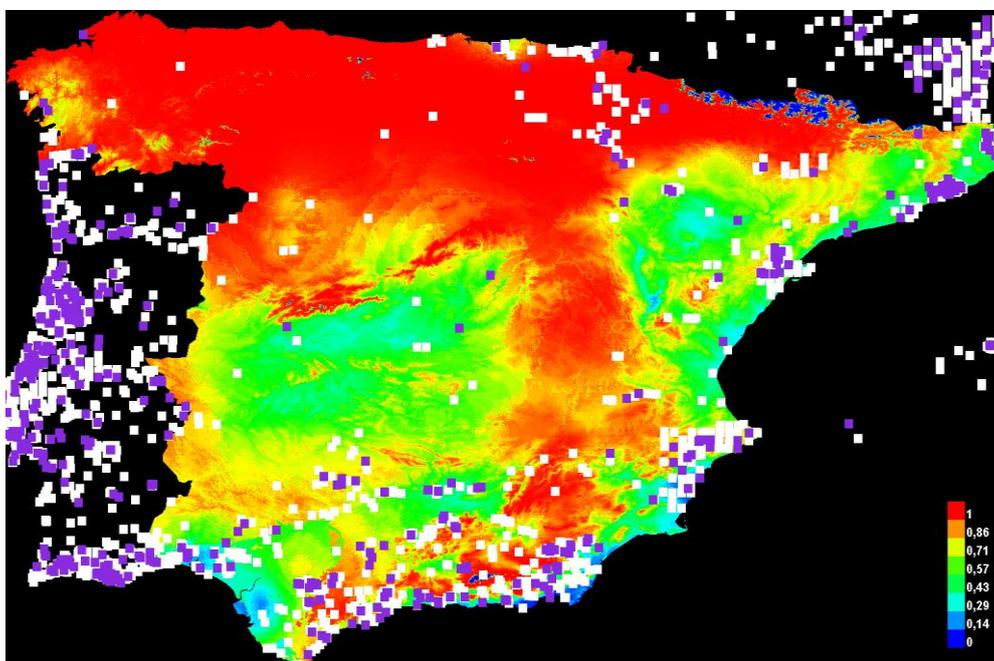


Figura 31: Modelo de idoneidad climática generado a partir del **MPI-ESMR-MR** bajo el escenario de **8.5 W/m²** para el año 2070. Queda representada la probabilidad de presencia de la especie entre 0 (azules) y 1 (rojos). El modelo presentó un **AUC** de 0.889 en el entrenamiento y 0.888 en el test.

iii. HADGEM2: Escenario 4.5 W/m²

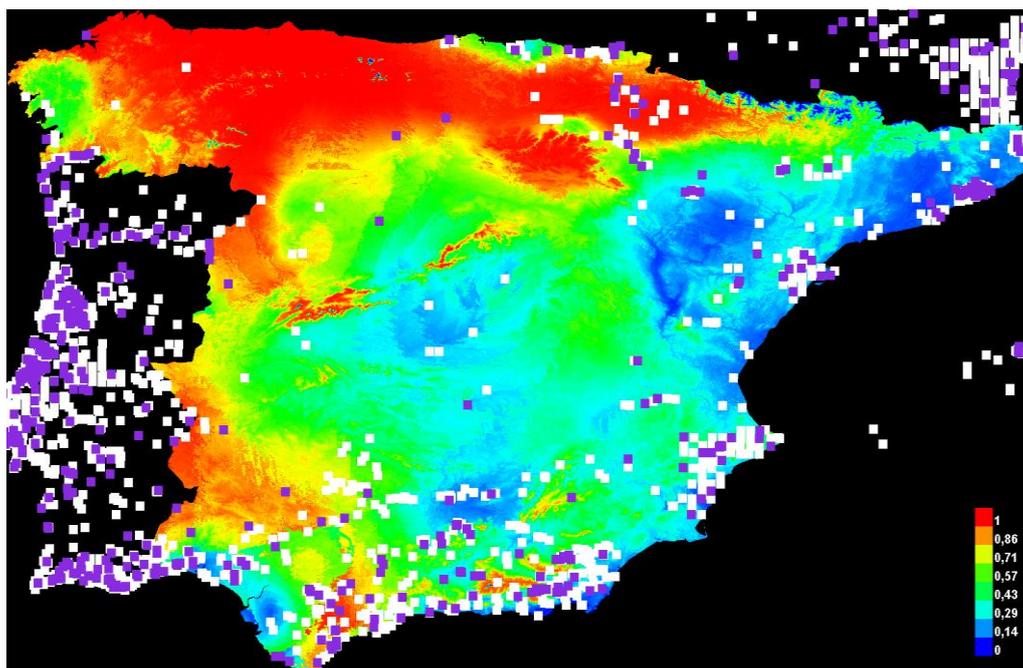


Figura 32: Modelo de idoneidad climática generado a partir del **HadGEM2** bajo el escenario de **4.5 W/m²** para el año 2070. Queda representada la probabilidad de presencia de la especie entre 0 (azules) y 1 (rojos). El modelo presentó un **AUC** de 0.895 en el entrenamiento y 0.889 en el test.

iv. HADGEM2: Escenario 8.5 W/m²

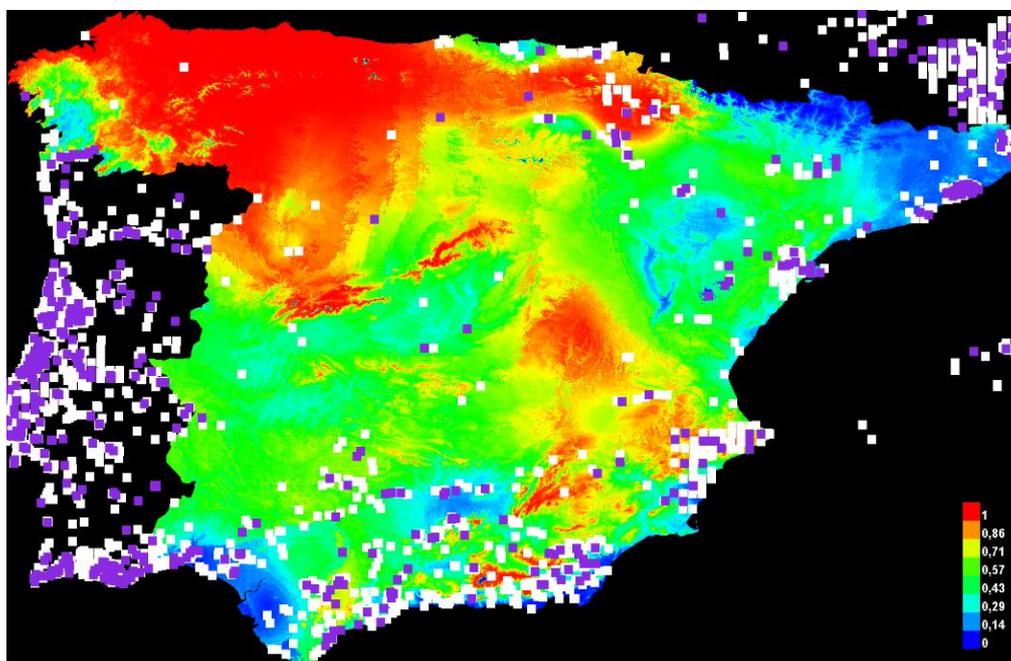


Figura 33: Modelo de idoneidad climática generado a partir del **HadGEM2** bajo el escenario de **8.5 W/m²** para el año 2070. Queda representada la probabilidad de presencia de la especie entre 0 (azules) y 1 (rojos). El modelo presentó un **AUC** de 0.896 en el entrenamiento y 0.897 en el test.

Proyección de distribución de la especie bajo escenarios de Cambio Climático en las demarcaciones de los ríos Júcar y Segura

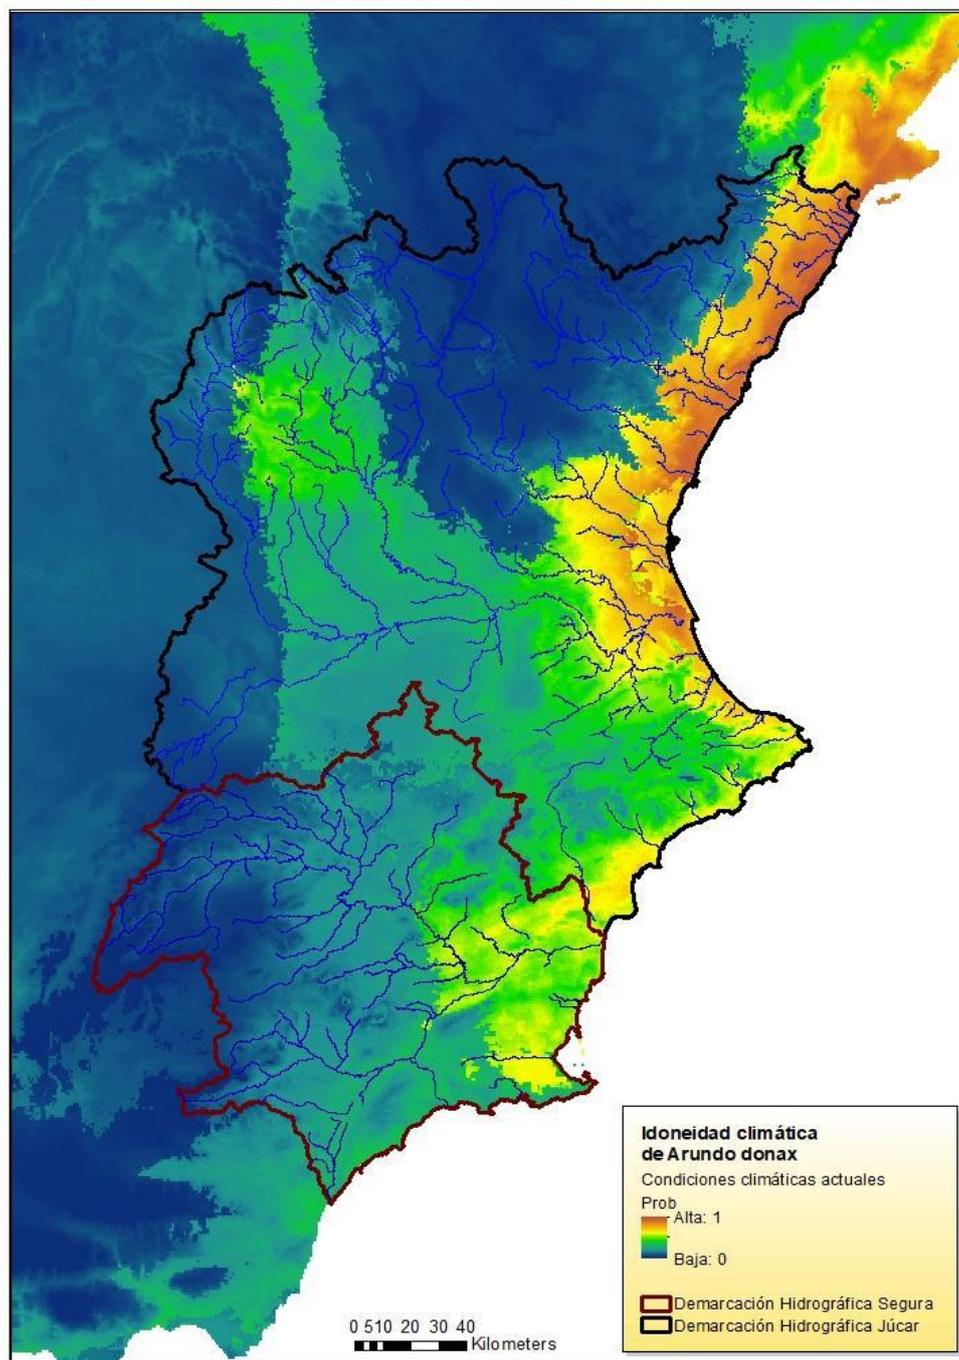


Figura 34: Mapa de distribución potencial en el ámbito de las Demarcaciones Hidrográficas del Júcar y Segura atendiendo a las condiciones climáticas del presente.

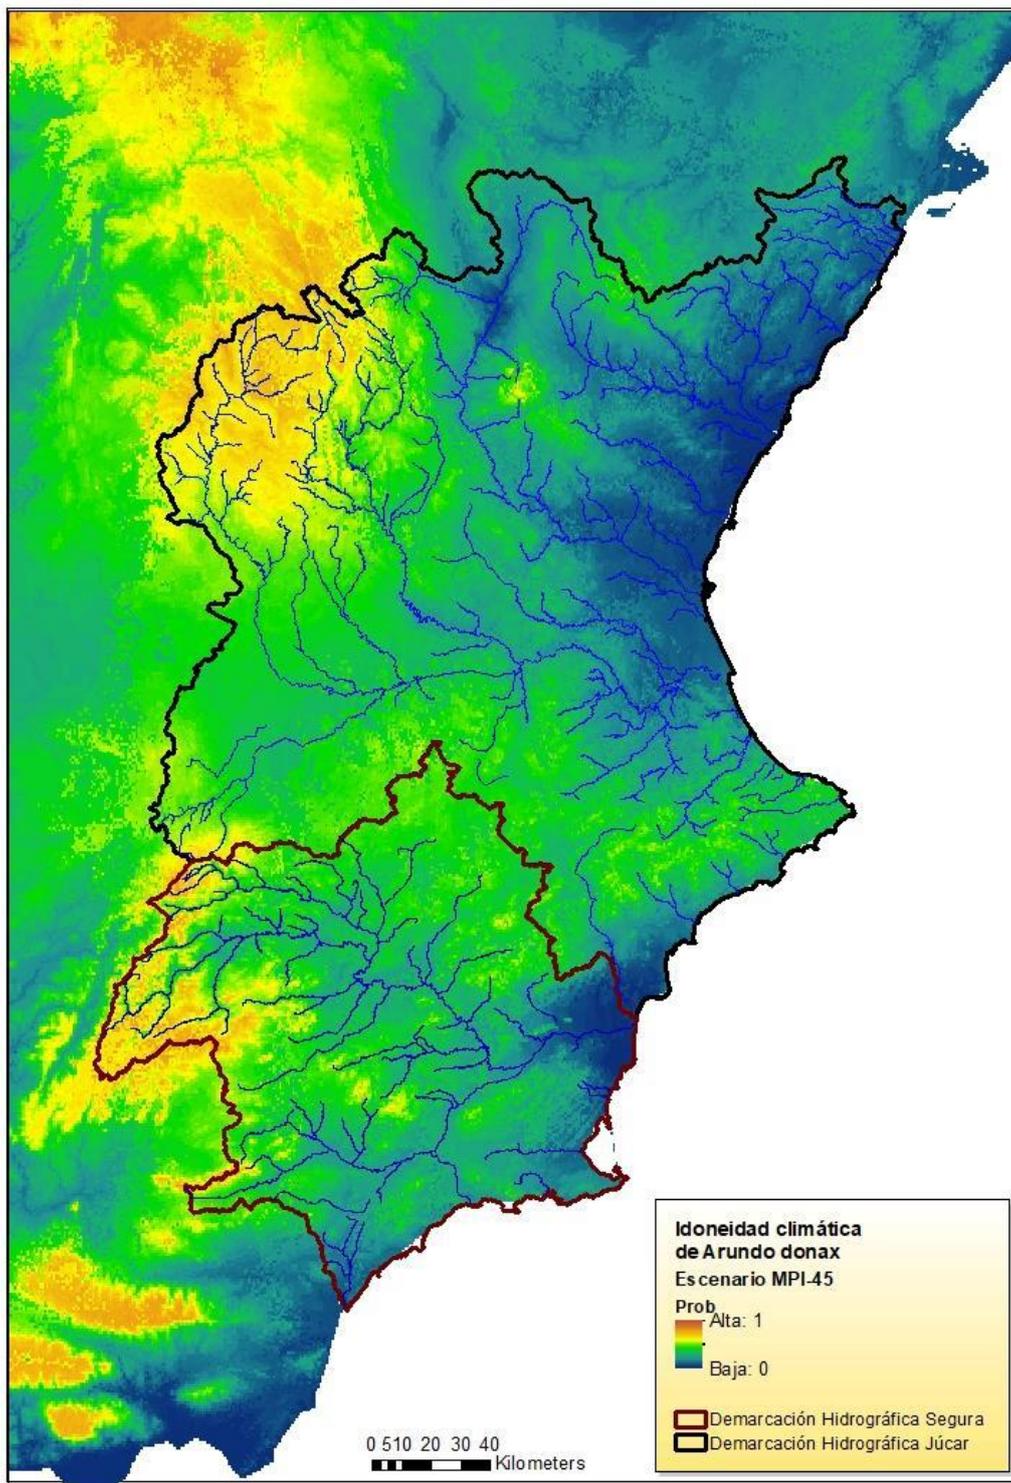


Figura 35: Mapa de distribución potencial en el ámbito de las Demarcaciones Hidrográficas del Júcar y Segura atendiendo a las condiciones climáticas escenario **MPI-ESMR-MR RCP4.5**.

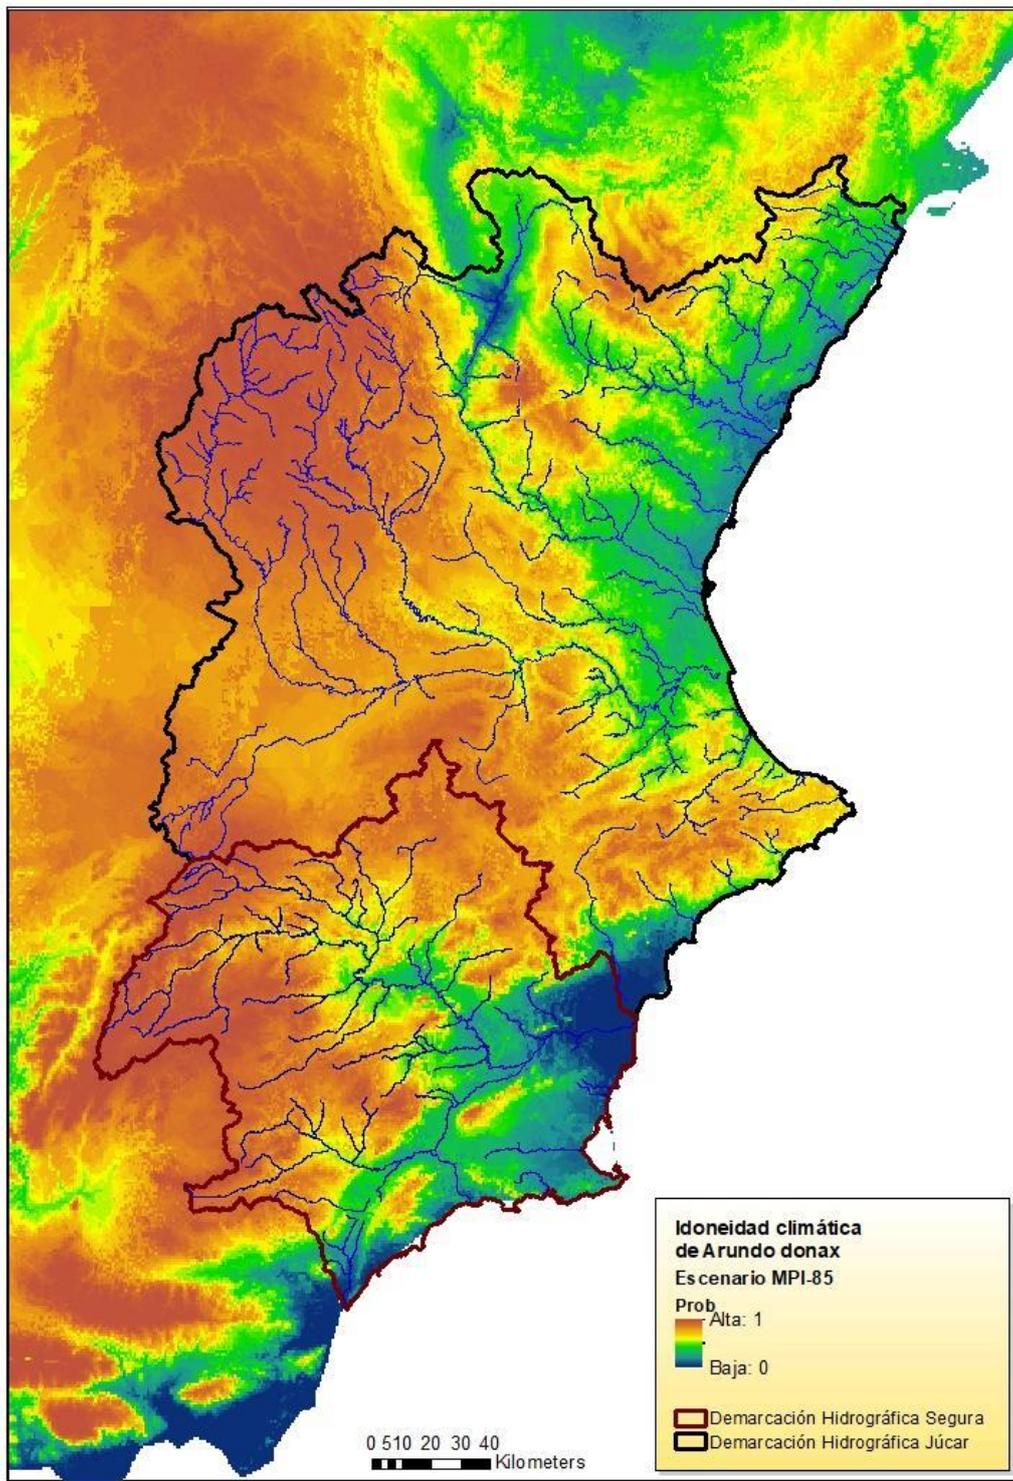


Figura 36: Mapa de distribución potencial en el ámbito de las Demarcaciones Hidrográficas del Júcar y Segura atendiendo a las condiciones climáticas escenario **MPI-ESMR-MR RCP8.5**

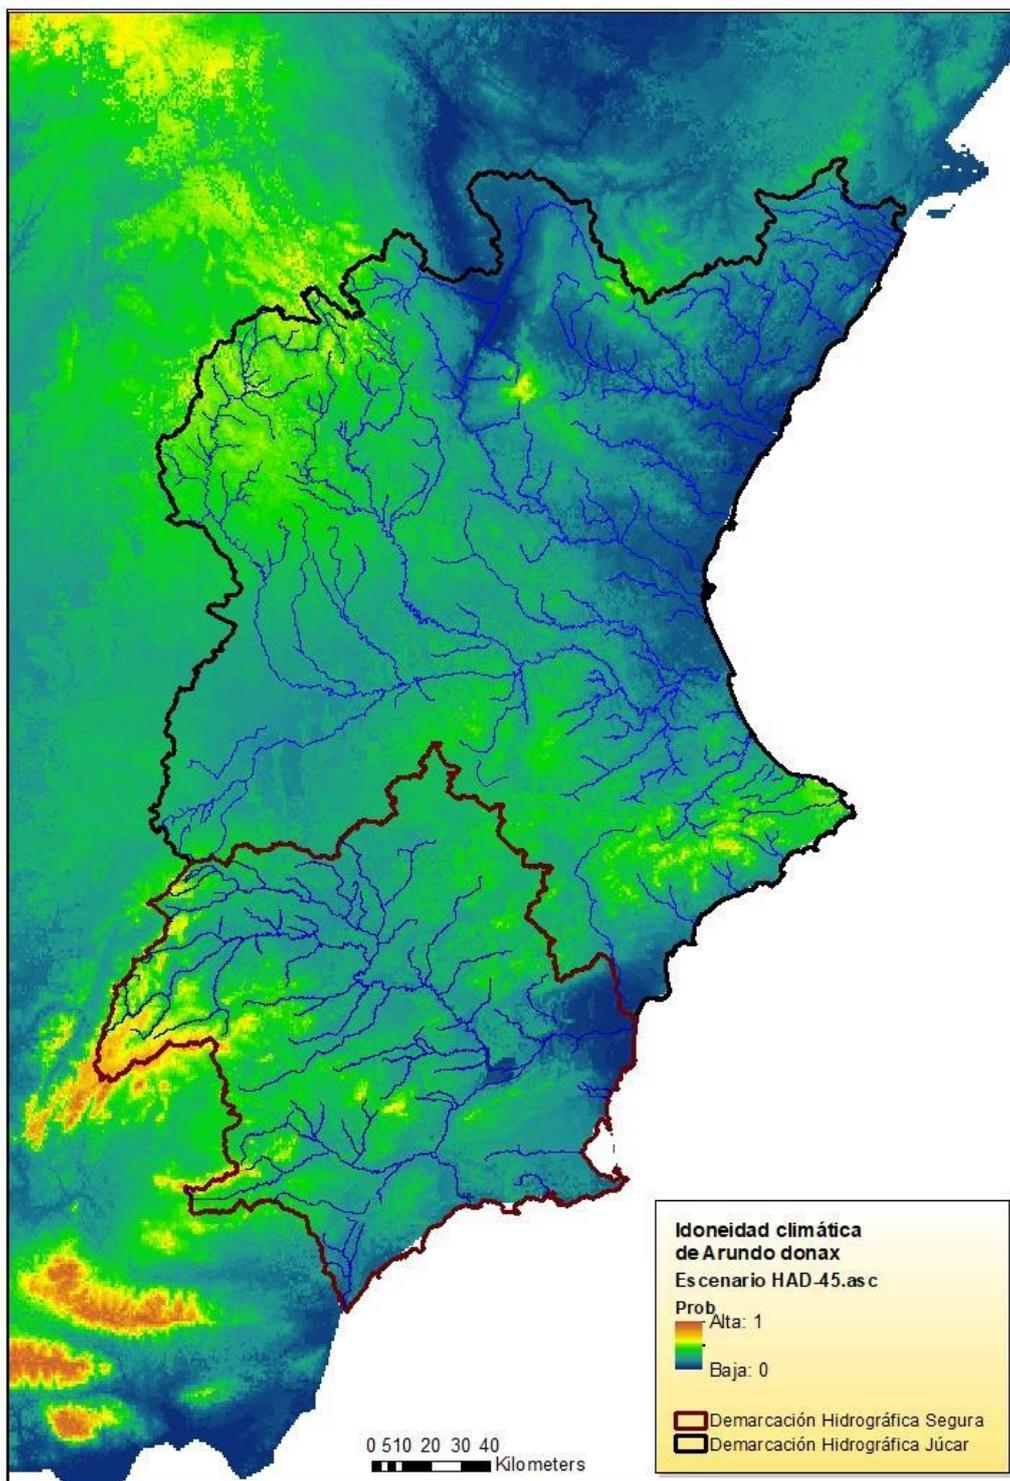


Figura 37: Mapa de distribución potencial en el ámbito de las Demarcaciones Hidrográficas del Júcar y Segura atendiendo a las condiciones climáticas escenario HadGEM2 RCP4.5.

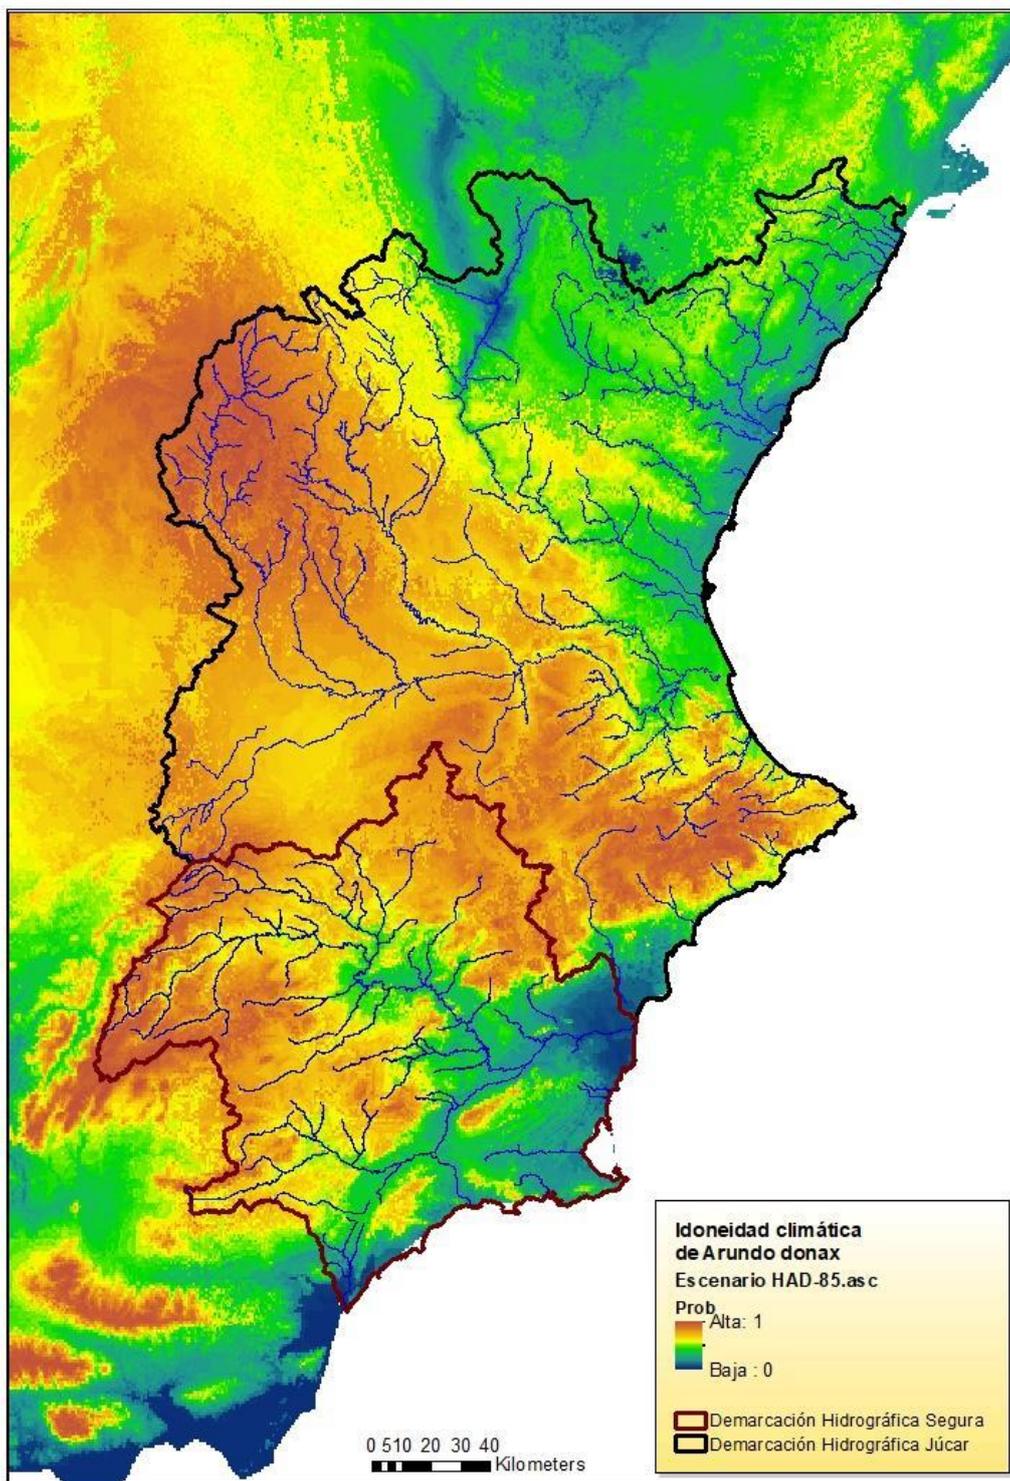


Figura 38: Mapa de distribución potencial en el ámbito de las Demarcaciones Hidrográficas del Júcar y Segura atendiendo a las condiciones climáticas escenario **HadGEM2 RCP8.5**.

4. Conclusiones

Una de las mayores amenazas para la vegetación autóctona en zonas de ribera de las cuencas de los ríos Júcar y Segura es la proliferación de la especie invasora llamada *Arundo Donax*, conocida como caña común.

Actualmente, esta especie tiene mayor presencia en humedales de aguas permanentes o estacionales de zonas cercanas a la costa (especialmente en la franja costera de Castellón y Valencia), y existe preocupación de que, debido al cambio climático, su presencia se vaya extendiendo aguas arriba hasta las cabeceras de los ríos donde aún persisten bosques de ribera autóctonos.

Los resultados muestran que, en efecto, la probabilidad de presencia de esta especie tenderá a aumentar en zonas altas y en el interior de las cuencas, justo donde ahora no está presente. En cambio, tenderá a disminuir en zonas costeras. Los modelos climáticos analizados coinciden en esta tendencia, y ambos muestran que cuanto mayor sea la magnitud del cambio climático (RCP 8.5), la probabilidad de presencia de esta especie será mayor (por encima del 80%) en las zonas citadas. En cambio, bajo forzamientos más moderados (RCP 4.5), el *Arundo Donax* aumentaría respecto al presente, pero su probabilidad de presencia en las cabeceras de los ríos rondaría el 50%.

5. Bibliografía

- Allen, C.D., A.K. Macalady, H. Chenchouni, D. Bachelet, N. McDowell, et al.. A global overview of drought and heat-induced tree mortality reveals emerging climate change risks for forests. *Forest Ecology and Management*, Elsevier, 2010, 259 (4), p. 660 - p. 684.
- Aulló-Maestro, M.E., Moreno-Amat, E. (2011). Protocolo para la modelización de distribución de especies a presente y pasado, a partir de datos de presencia y ausencia de las especies y datos ambientales y contraste con información paleoecológica disponible.
- Bentsen, M., Bethke, I., Debernard, J.B., Iversen, T., Kirkevåg, A., Seland, O., et al., 2013. The Norwegian Earth System Model, NorESM1-M - part 1: description and basic evaluation of the physical climate. *Geosci. Model Dev.* 6, 687–720.
- Brunet, M., Casado, M. J., De Castro, M., Galán, P, López, J.A., Martín, J.M., Pastor, A., Petisco, E., Ramos, P., Ribalaygua, J., Rodríguez, E., Sanz, I. and Torres, L., 2008. Generación de escenarios regionalizados de cambio climático para España. Centro de Publicaciones, Secretaría General Técnica. Ministerio de Medio Ambiente y Medio Rural y Marino. Spanish Meteorology Agency (AEMET).
- Chylek, P., Li, J., Dubey, M.K., Wang, M., Lesins, G., 2011. Observed and model simulated 20th century Arctic temperature variability: Canadian Earth System Model CanESM2. *Atmos. Chem. Phys. Discuss.* 11, 22893–22907. <https://doi.org/10.5194/acpd-11-22893-2011>.
- Collins, W.J., Bellouin, N., Doutriaux-Boucher, M., Gedney, N., Hinton, T., Jones, C.D., Liddicoat, S., Martin, G., O'Connor, F., Rae, J., Senior, C., Totterdell, I., Woodward, S., Reichler, T., Kim, J., Halloran, P., 2008. Evaluation of the HadGEM2 model. Hadley Centre Technical Note HCTN. vol 74. Met Office Hadley Centre, Exeter, UK
- Conesa García, C., Espín Sánchez, D., García Marín, R., Castejón Porcel, G., & Moreno Muñoz, D. (2014). Inversiones térmicas con advección cálida inferior en la Vega Media del Segura (Región de Murcia). *Estudios Geográficos*, 75(277), 521-552. doi:<http://dx.doi.org/10.3989/estgeogr.201416>
- Confederación Hidrográfica del Júcar. Web:www.chj.es
- Confederación Hidrográfica del Segura. Web:www.chsegura.es

- Deltoro Torró, V. Jiménez Ruiz, J & VilánFragueiro, M. Bases para el manejo y control de *Arundodonax* L. (Caña común). Conselleria d'Infraestructures, Territori i Medi Ambient. Generalitat Valenciana. València, 2012.
- Dunne, J.P., John, J.G., Adcroft, A.J., Griffies, S.M., Hallberg, R.W., Shevliakova, E., et al., 2012. GFDL's ESM2 global coupled climate-carbon Earth System Models. Part I: physical formulation and baseline simulation characteristics. *J. Clim.* 25, 6646–6665.
- GBIF.org (2018), *GBIF Home Page*. Disponible en: www.gbif.org.
- Hijmans, R. J., Cameron, S. E., Parra, J. L., Jones, P. G., & Jarvis, A. (2005). Very high resolution interpolated climate surfaces for global land areas. *International journal of climatology*. 25(15), 1965-1978.
- Iversen, T., Bentsen, M., Bethke, I., Debernard, J.B., Kirkevåg, A., Seland, O., et al., 2013. The Norwegian Earth System Model, NorESM1-M - part 2: climate response and scenario projections. *Geosci. Model Dev.* 6, 389–415
- Lamas Casado, D. (2017) Modelización del hábitat potencial actual y futuro del baobab (*Adansoniadigitata* L.) TFG. Madrid: Universidad Politécnica de Madrid. Escuela Técnica Superior de Ingeniería de Montes, Forestal y Medio Natural.
- Laurent Hardion, Régine Verlaque, Kristin Saltonstall, Agathe Leriche, and Bruno Vila (2014). Origin of the invasive *Arundodonax* (Poaceae): a trans-Asian expedition in herbaria. *Ann. Bot.* 114(3): 455–462.
- Marsland, S.J., Haak, H., Jungclaus, J.H., Latif, M., Roske, F., 2003. The Max-Planck-Institute global ocean/sea ice model with orthogonal curvilinear coordinates. *Ocean Model* 5, 91–127.
- Mateo, R. G., Felicísimo, Á. M. & Muñoz, J. (2011) Modelos de distribución de especies: Una revisión sintética. *Rev. Chil. Hist. Nat.* 84, 217–240.
- Miller, J. (2010) Species distribution modeling. *Geogr. Compass*. 4, 490–509.
- Moreno-Amat E. (2017) Reducción de la incertidumbre de los modelos de distribución de especies con datos ecológicos y paleoecológicos. Tesis. Madrid: Universidad Politécnica de Madrid. Escuela Técnica Superior de Ingeniería de Montes, Forestal y Medio Natural.
- Patz J.A., D. Campbell-Lendrum, T. Holloway & J. A. Foley (2005). Impact of regional climate change on human health, *Nature*.
- Phillips, S.J., Anderson, R.P., Schapire, R.E. (2006). Maximum entropy modeling of species geographic distributions. *Ecol. Model.* 190, 231–259.
- Raddatz, T.J., Reick, C.H., Knorr, W., Kattge, J., Roeckner, E., Schnur, R., et al., 2007. Will the tropical land biosphere dominate the climate-carbon

- cycle feedback during the twenty-first century? *Clim. Dyn.* 29, 565–574.
- Ribalaygua, J., Torres, L., Portoles, J., Monjo, R., Gaitan, E., Pino, M.R., 2013b. Description and validation of a two-step analogue/regression downscaling method. *Theor. Appl. Climatol.* 114, 253–269.
- Serra-Varela MJ, Alía R, Pórtoles J, Gonzalo J, Soliño M, Grivet D, et al. (2017) Incorporating exposure to pitch canker disease to support management decisions of *Pinus pinaster* Ait. in the face of climate change. *PLoS ONE* 12(2): e0171549. doi:10.1371/journal.pone.0171549
- Smith, T.T., Zaitchik, B.F., Gohlke, J.M., 2013. Heat waves in the United States: definitions, patterns and trends. *Clim. Chang.* 118, 811–825.
- Vega, J. C. & Guzmán, J. (2011) Regresión PLS y PCA como solución al problema de multicolinealidad en regresión múltiple. *Rev. Matemática Teoría y Apl.* 18, 9–20.
- Voldoire, A., Sanchez-Gomez, E., Melia, D.S.Y., Decharme, B., Cassou, C., Senesi, S., et al., 2013. The CNRM-CM5.1 global climate model: description and basic evaluation. *Clim. Dyn.* 40, 2091–2121
- Watanabe, S., Hajima, T., Sudo, K., Nagashima, T., Takemura, T., Okajima, H., et al., 2011. MIROC-ESM 2010: model description and basic results of CMIP5-20c3m experiments. *Geosci. Model Dev.* 4, 845–872
- Watson L., Lacressonniere G., Gauss M., Engardt M., Andersson C., Josse B., Marecal V., (...), Vautard R. (2015) The impact of meteorological forcings on gas phase air pollutants over Europe *Atmospheric Environment*, 119, pp. 240-257. <https://doi.org/10.1016/j.atmosenv.2015.07.037>
- Xiao-Ge, X., Tong-Wen, W., Jie, Z., 2013. Introduction of CMIP5 experiments carried out with the climate system models of Beijing Climate Center. *Adv. Clim. Chang. Res.* 4,41–49. <https://doi.org/10.3724/SP.J.1248.2013.041>
- Yukimoto, S., Yoshimura, H., Hosaka, M., Sakami, T., Tsujino, H., Hirabara, M., Tanaka, T.Y., Deushi, M., Obata, A., Nakano, H., Adachi, Y., Shindo, E., Yabu, S., Ose, T., Kitoh, A., 2011. Meteorological research institute-earth system model v1 (MRI-ESM1)— model description. Technical Report of MRI. vol 64