

TRABAJO FIN DE MÁSTER

IDENTIFICACIÓN DE MICRO-REFUGIOS MEDIANTE MODELOS TOPOCLIMÁTICOS DE ALTA RESOLUCIÓN EN EL P.N. DE ORDESA Y MONTE PERDIDO

IDENTIFYING MICRO-REFUGIA USING FINE-SCALE TOPOCLIMATIC MODELS IN ORDESA AND MONTE PERDIDO NATIONAL PARK

Autor: Raúl Hoffrén Mansoa

Directores:

María Begoña García González ¹

Manuel Pizarro Gavilán ¹

Miguel Ángel Saz Sánchez ²

¹ Instituto Pirenaico de Ecología (IPE-CSIC)

² Dpto. Geografía y OT – Universidad de Zaragoza

Máster Universitario en

Tecnologías de la Información Geográfica para la Ordenación del Territorio:
Sistemas de Información Geográfica y Teledetección

Septiembre de 2019



Universidad
Zaragoza

Departamento de
Geografía y Ordenación
del Territorio



Resumen

En el presente contexto de cambio climático resulta necesario conocer tanto las áreas más susceptibles como las más resistentes a la pérdida de biodiversidad, de ahí la importancia de identificar micro-refugios climáticos. Para ello es imprescindible disponer de una caracterización climática detallada del área de estudio. A partir de la programación de rutinas en entorno R, en este trabajo se han generado modelos topoclimáticos de alta resolución (5 m) en una de las áreas más complejas orográficamente y con mayor biodiversidad de Europa: el Parque Nacional de Ordesa y Monte Perdido. Se obtuvieron registros de temperatura durante tres años por 73 sensores de campo miniaturizados (iButton®) y se modelizaron las temperaturas máximas y mínimas medias mensuales de un año-tipo. Paralelamente, se generaron diversas variables topográficas y ambientales derivadas de LiDAR que permitieron predecir la variabilidad climática local. Mediante ajustes de modelos lineales, en todos los casos los modelos topoclimáticos fueron más explicativos que los que sólo incluyeron la altitud. La espacialización de los modelos sirvió para generar un "Refugia Index" (RI) para escenarios de calidez o frialdad extremas. Este índice permitió identificar los refugios en ambos tipos de escenarios, y se obtuvo además un índice combinado que destaca los refugios fríos y cálidos independientemente del escenario. El índice combinado resultó ser una variable explicativa muy significativa al analizar la proporción de plantas adaptadas al frío y al calor recogidas en más de 700 inventarios florísticos.

Palabras clave: *Refugia Index, Pirineos, Biodiversidad, Teledetección, Software libre.*

Abstract

In the current context of climate change, it is necessary to identify both the most susceptible and the most resistant areas to biodiversity loss, hence the importance of identifying micro-refugia. Thus, it is essential to have a specific climatic characterization of the study area. Using programming routines in R environment, in this work a fine-scale topoclimatic model (5 m) has been generated in one of the most complex orographically and biodiversity areas in Europe: the Ordesa and Monte Perdido National Park. Based on temperature records updated for three years by 73 miniaturized field sensors (iButton®) the monthly average maximum and minimum of a year-type were modeled. At the same time, several topographic and environmental variables derived from LiDAR were generated to allow predicting local climatic variability. By means of linear model adjustments, in all cases topoclimatic models were more explanatory than those that only include altitude. The spatialization of the models allowed to generate a Refugia Index (RI) for extreme warm and cold scenarios. This index enabled to identify the refugia in both types of scenarios and also to get a combined index that highlights the cold and warm refugia regardless of the scenario. The combined index proved to be a significant explanatory variable when analyzing the proportion of plants adapted to cold and heat collected in more than 700 floristic inventories.

Key Words: *Refugia Index, Pyrenees, Biodiversity, Remote sensing, Freeware.*

Índice general

1. Introducción.....	1
1.1. Antecedentes.....	1
1.2. Objetivos.....	3
2. Ámbito de estudio.....	4
3. Materiales y métodos.....	6
3.1. Materiales.....	8
3.1.1. Entorno R.....	8
3.1.2. Sensores climáticos de campo (<i>iButton</i> ®).....	8
3.1.3. Tecnología LiDAR.....	11
3.1.4. Datos climáticos y de teledetección para comparación de modelos.....	12
3.1.5. Inventarios florísticos para validación biológica.....	12
3.2. Metodología.....	13
3.2.1. Obtención de las variables climáticas dependientes.....	14
3.2.2. Obtención de las variables independientes.....	18
3.2.3. Análisis exploratorio y ajuste de modelos.....	23
3.2.4. Comparación con otras bases de datos.....	26
3.2.5. Cálculo del <i>Refugia Index</i> (RI).....	26
3.2.6. Validación biológica de los refugios climáticos.....	28
4. Resultados.....	28
4.1. Datos climáticos de los <i>iButton</i> ®.....	28
4.1.1. Controles de calidad.....	28
4.1.2. Análisis de las temperaturas.....	29
4.1.3. Comparación con otras fuentes de datos climáticos.....	30
4.1.4. Análisis de los días con crecimiento vegetativo (GDD).....	32
4.2. Predictoras topográficas.....	32
4.3. Ajuste de modelos y validaciones.....	34
4.4. Modelos topoclimáticos.....	37
4.4.1. Temperaturas extremas.....	37
4.4.2. Variabilidad climática.....	38
4.4.3. Aislamiento regional.....	40
4.4.4. Crecimiento vegetativo diario (GDD).....	41
4.5. Refugios climáticos y validación biológica.....	42
5. Discusión.....	45
5.1. Modelo topoclimático y <i>Refugia Index</i>	46
5.2. Valoración del proceso metodológico.....	48
5.3. Líneas de trabajo futuras.....	49
6. Conclusiones.....	50
Agradecimientos.....	52
Bibliografía.....	53
Índice de Tablas y Figuras.....	60

1. Introducción

1.1. Antecedentes

A lo largo de la historia de nuestro planeta se han producido múltiples cambios en el clima global que han dejado huella en los paisajes y el tipo de organismos que habitaban en ellos. En la actualidad, La Tierra se encuentra sumida en la transformación más rápida registrada por causas humanas, lo que se ha dado en llamar el “Antropoceno” [Lewis & Maslin, 2015]. El cambio climático se considera uno de los principales motores desestabilizadores de la integridad planetaria [Rockström *et al.*, 2009], reconociéndose múltiples efectos sobre el medio ambiente con consecuencias posteriores para el ser humano [Scheffers *et al.*, 2016].

El clima tiene una importancia fundamental en la evolución de todos los organismos [Maclean *et al.*, 2019], determinando, en gran medida, su distribución espacial. Los cambios climáticos pueden causar el aislamiento y extinción de especies y hábitats [Niskanen *et al.*, 2016], lo que puede tener efectos especialmente importantes en las regiones montañosas [Patsiou *et al.*, 2014] ya que éstas alojan una tercera parte de la biodiversidad florística del planeta [Körner & Hiltbrunner, 2018] y proporcionan servicios ecosistémicos que son particularmente sensibles a las variaciones climáticas [Blanco-Pastor *et al.*, 2018]. La intensidad del impacto en las poblaciones depende, en gran medida, de la exposición de éstas a los cambios climáticos o del sistema en el que se encuentra a las variaciones espacio-temporales del clima [Sandel *et al.*, 2013; Dobrowski & Parks, 2016]. En términos generales, los organismos tienen dos opciones para sobrevivir a estos cambios: migrar a un lugar más próximo a sus requerimientos térmicos, o resistir si tienen suficiente plasticidad o capacidad genética para adaptarse a las nuevas condiciones climáticas [Graae *et al.*, 2018]. Algunas especies no poseen la capacidad de adaptarse, sobre todo porque los cambios climáticos suelen ocurrir más rápido que las adaptaciones evolutivas de los organismos; otras cuentan con una baja capacidad de dispersión que no les permite migrar fácilmente. En ambos casos, su única opción es la de sobrevivir en refugios climáticos. Las áreas con mayor heterogeneidad ambiental ofrecen más oportunidades a las especies para su persistencia a largo plazo [Graae *et al.*, 2018], ya que esta complejidad en el territorio implica mayor diversidad climática, florística o edáfica y, en definitiva, mayor probabilidad de encontrar un nuevo nicho próximo o de sobrevivir en micro-refugios.

Los refugios climáticos pueden ser definidos como aquellos lugares en los que se mantienen condiciones ambientales adecuadas para la habitabilidad de determinadas especies en un entorno que les es (o se ha convertido por cambios ambientales) poco favorable [Dobrowski, 2010], pudiendo existir refugios fríos o cálidos en función del tipo de adaptación climática del organismo. Las montañas y las zonas costeras, por su heterogeneidad ambiental y su efecto tamponador respectivamente, se han considerado refugios climáticos de biodiversidad a gran escala espacial [Harrison & Noos, 2017], constituyendo un ejemplo perfecto de ello las montañas y costas de las penínsulas del Sur de Europa (Ibérica, Itálica y Balcánica), localizadas en un *hotspot* mundial de biodiversidad [Médail & Diadema, 2009]. También se ha encontrado una estrecha relación entre la abundancia de endemismos y especies raras con zonas climáticas distintivas en Europa, lo que sugiere un importante papel de éstas como refugios de una singular diversidad [Ohlemüller *et al.*, 2008]

A menor escala espacial se encuentran los micro-refugios climáticos, parches locales emplazados en una matriz ambientalmente muy distinta [Ashcroft, 2010; Keppel *et al.*, 2011; Meineri & Hylander, 2017]. Han posibilitado a muchas especies a sobrevivir en condiciones climáticas adversas del pasado [Meineri & Hylander, 2017; Suggitt *et al.*, 2018] y su expansión a medida que el clima se volvía más benévolo, facilitando su persistencia a largo plazo [Keppel *et al.*, 2015]. Su aislamiento y efecto tamponador los convierten en fundamentales, en muchos casos, para la supervivencia y la conservación de la diversidad genética en el contexto de cambio climático actual [Gubler *et al.*, 2018], dada su capacidad de alojar poblaciones de especies fuera de su distribución espacial principal [García *et al.*, 2019]. La identificación de estos refugios es, por tanto, un paso prioritario en la conservación de la biodiversidad. Por ejemplo, su consideración es pieza clave para la generación de modelos predictivos de especies (SDM: *Species Distribution Models*). Dichos modelos han tenido un crecimiento exponencial durante las dos últimas décadas y, en general, han producido resultados alarmantes sobre la pérdida de biodiversidad (ver por ej. Thuiller *et al.*, 2005, Engler *et al.*, 2011), aunque no están exentos de críticas por su inicial simplicidad [Dawson *et al.*, 2011; Araujo *et al.*, 2019]. En los últimos años se ha puesto de manifiesto una considerable mejora predictiva de los clásicos SDM cuando incluyen variables topográficas [Patsiou *et al.*, 2014; Niskanen *et al.*, 2016].

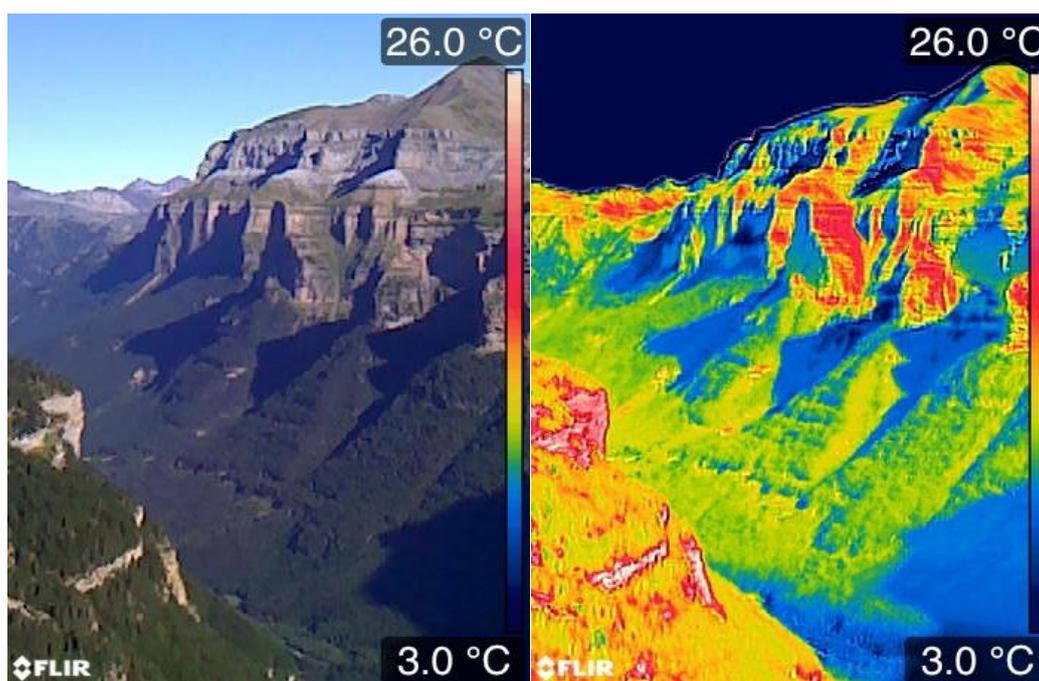


Figura 1.1. Variaciones locales de temperatura detectados por sensor térmico en una zona topográfica compleja (Valle de Ordesa, Pirineos) [Fotografía: MBG].

Los modelos topoclimáticos se han convertido en herramientas esenciales para entender y gestionar los territorios montañosos [Batalla *et al.*, 2018] y, en este sentido, juegan un papel muy importante en la detección de micro-refugios. La elevada heterogeneidad ambiental en montaña, por ejemplo, precisa de estudios de detalle para poder captar las variaciones microclimáticas existentes; es necesario, por tanto, realizar una reducción en la escala o *downscaling* para identificar correctamente estos micro-refugios [Fridley, 2009; Dobrowski, 2011; Niskanen *et al.*, 2016; Meineri & Hylander,

2017; Batalla *et al.*, 2018]. En este contexto, las Tecnologías de la Información Geográfica (TIG) constituyen un conjunto de herramientas de gran importancia ya que posibilitan la obtención de datos espaciales, como registros climáticos, y el análisis del territorio a partir del procesado de la información geoespacial en Sistemas de Información Geográfica (SIG). La integración de estos últimos con otras herramientas permite automatizar procesos y análisis espaciales, así como el tratamiento de datos de teledetección activa y pasiva. Por ejemplo, los sensores térmicos son capaces de recoger la temperatura de la superficie (Figura 1.1) y los datos de teledetección LiDAR (*Light Detection And Ranging*) facilitan la caracterización de la vegetación y el estudio de la biodiversidad, especialmente a escala local gracias a su capacidad de reproducir con gran precisión los objetos existentes en la superficie [Vogeler & Cohen, 2016].

1.2. Objetivos

En este trabajo el objetivo general fue la identificación de refugios climáticos cálidos y fríos en el Parque Nacional de Ordesa y Monte Perdido. Para ello se generaron modelos topoclimáticos a partir de información climática procedente de mini-sensores de campo en 73 estaciones o puntos de muestreo, y de variables topográficas y ambientales. La hipótesis de partida se fundamentó en que la heterogeneidad ambiental del Parque Nacional de Ordesa y Monte Perdido, provocada en buena medida por la extrema rugosidad de terreno, así como su situación en el Pirineo central, donde confluyen dos grandes regiones biogeográficas, ha facilitado la presencia de microclimas a una escala local que constituyen refugios climáticos para las plantas, lo que se refleja en la diversidad florística existente. No se trata de un trabajo de carácter predictivo, sino de caracterización climática a una alta resolución espacial para una zona topográficamente compleja en la que sólo existe una estación meteorológica de la AEMET de largo recorrido (Góriz: datos desde el año 1981), lo que limita en gran medida los estudios climáticos de carácter local.

Como objetivos secundarios a lo anterior, implicó:

- La identificación de micro-refugios climáticos tras selección de modelos topoclimáticos mediante el empleo único de *software libre*, de manera que la metodología aquí propuesta pueda adecuarse a otros ámbitos de estudio similares en un contexto de proyecto colaborativo.
- La importancia de la reducción en la escala o *downscaling* para estudios de carácter local y la necesidad, por tanto, de recurrir a modelos de alta resolución espacial.
- La completa automatización del proceso metodológico para la construcción de los modelos topoclimáticos y la búsqueda de refugios climáticos en espacios montañosos.
- La validación de los sensores de campo con otras fuentes de datos como instrumentos de obtención de datos climáticos de calidad para estudios de carácter local en zonas montañosas.
- La creación de una base de datos sólida y operativa basada en los registros obtenidos por los sensores de campo.

2. Ámbito de estudio

El trabajo se centró en el Parque Nacional de Ordesa y Monte Perdido y su Zona Periférica de Protección (denominado en su conjunto por las siglas PNOMP), localizado en el sector central Pirineo, en la provincia de Huesca. Esta cordillera de 435 km de longitud discurre en dirección armoricana desde el mar Cantábrico (golfo de Vizcaya), en el oeste, hasta el mar Mediterráneo (cabo de Creus), en el este. Su morfología actual proviene de la orogenia alpina, que provocó el levantamiento de los materiales graníticos y metamórficos de origen paleozoico, resistentes a la erosión, y configuró los relieves de mayor entidad. Entre los componentes geomorfológicos de mayor presencia está el modelado glaciar y periglaciar, resultado de los periodos glaciares del Cuaternario. La ocupación de los hielos y las nieves perpetuas produjeron morfologías glaciares como circos glaciares, depósitos morrénicos o valles en artesa. También destaca la morfología fluvial, debido a la actividad erosiva que los cursos fluviales han ejercido durante miles de años sobre los materiales kársticos pirenaicos. Esta complejidad topográfica y su situación geográfica, en el límite entre dos grandes regiones biogeográficas (la Eurosiberiana y la Mediterránea) permite al Pirineo alojar unas 3.400 especies nativas de plantas vasculares, habiendo sido nombrada como uno de los principales puntos marginales de poblaciones de plantas adaptadas al frío en Europa [Abeli *et al.*, 2018].

El PNOMP (Figura 2.1) ocupa un área de 35.287 has (15.608 has el propio Parque, más 19.679 has la zona periférica) desde que en 1982 se ampliara la superficie del antiguo Parque Nacional de Ordesa o del río Ara, declarado como tal en 1918. Constituye un espacio idóneo para la detección de micro-refugios. Se trata de una zona con mucha rugosidad y de elevado gradiente altitudinal, desde los 686 m.s.n.m. en el sur del valle de Añisclo a los 3.355 m.s.n.m. de Monte Perdido, existiendo 34 picos por encima de los 3.000 m s.n.m.). Posee 5 valles principales dispuestos de manera heterogénea: Añisclo, valle fluviokárstico de disposición S-N; Bujaruelo, valle fluivo-periglaciar de disposición SSW-NNE, Escuaín, valle fluviokárstico de disposición SE-NW; Ordesa, valle glaciar de disposición W-NE; y Pineta, valle glaciar de disposición SE-NW. Además, alberga en su interior 1.400 especies de plantas vasculares.

Su compleja orografía, desnivel altitudinal, y la variada orientación de sus valles ha propiciado la existencia de una gran biodiversidad. Contiene 118 hábitats CORINE, de los que 34 son de interés comunitario [Benito, 2018], y 1.338 especies de plantas vasculares a nivel de especie [García *et al.*, 2019]. Ha sido profundamente explorado desde un punto de vista botánico, de forma que es el lugar con más inventarios florísticos de la Península Ibérica [Font *et al.*, 2010]. A partir de la base de datos del Herbario JACA se han contabilizado 52 endemismos estrictamente pirenaicos (más de la mitad de todos los que habitan en el conjunto de la cordillera) y 23 plantas amenazadas o de interés según catálogos de Aragón, Nacional o Directiva Hábitats [García *et al.*, 2019]. Se trata, por tanto, de un lugar de extraordinario interés por la riqueza y singularidad de la flora que contiene.

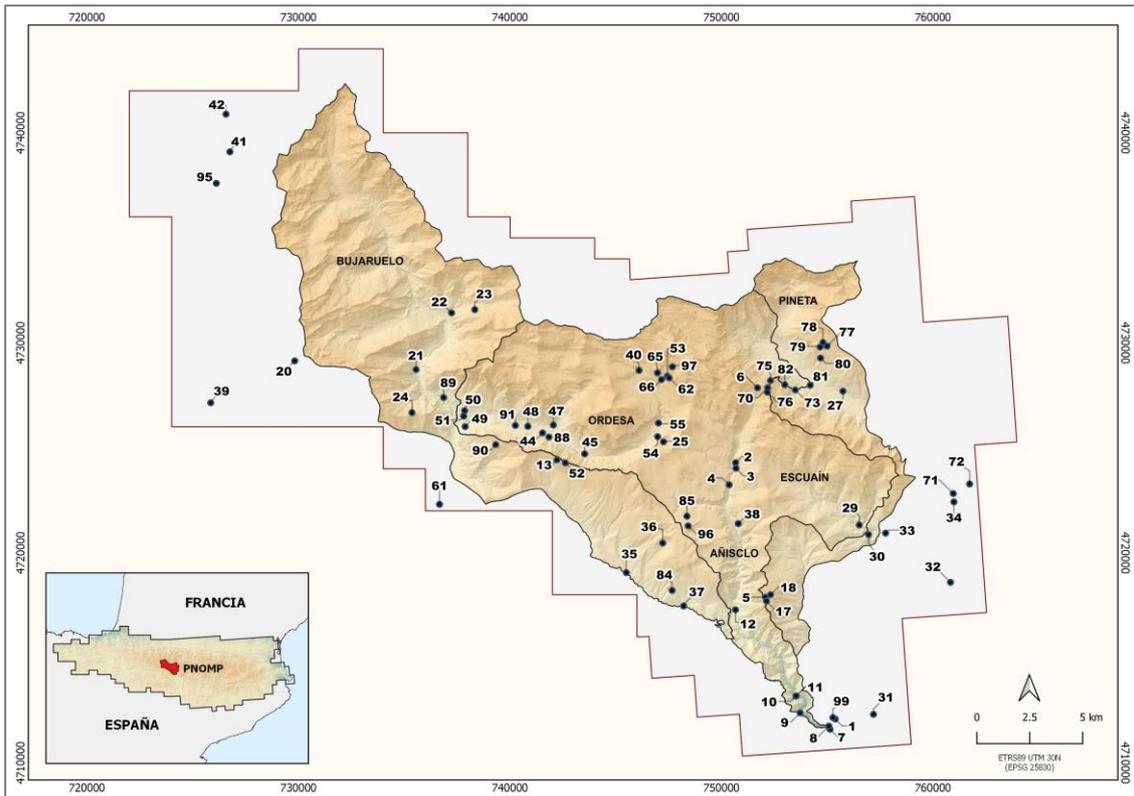


Figura 2.1. Área de estudio: Parque Nacional de Ordesa y Monte Perdido + Zona Periférica de Protección (PNOMP) y área de interpolación del modelo. Se muestra la ubicación de las 73 estaciones o puntos de muestreo y fotos ilustrativas de cada uno de los 4 hábitats en los que se emplazaron las estaciones.

3. Materiales y métodos

La identificación de refugios climáticos en el PNOMP fue abordada a una alta resolución espacial dada la complejidad orográfica del territorio y al hecho de que los micro-refugios suelen presentarse en zonas específicas del mismo [Dobrowski, 2011]. Los modelos climáticos de baja resolución espacial pueden ser adecuados en áreas homogéneas o extensas, pero no así para la detección de micro-refugios en ámbitos relativamente pequeños [Daly, 2006; Ashcroft *et al.*, 2009; Ashcroft, 2010; Dobrowski, 2011]. Además, en zonas topográficamente complejas las temperaturas suelen presentar variaciones locales significativas (< 1 km) respecto al clima regional [Urban *et al.*, 2000; Fridley, 2009; Ashcroft, 2010; Dobrowski, 2011]. Por tanto, modelos de alta resolución espacial implican tener en cuenta no sólo el clima del lugar sino también la topografía del terreno como principal factor de la variación en las temperaturas en zonas rugosas [Luoto & Heikkinen, 2008; Fridley, 2009; Randin *et al.*, 2009; Ashcroft, 2010; Gunton *et al.*, 2015]. Por este motivo, en este trabajo se generaron modelos topoclimáticos a una resolución espacial de 5 m para la totalidad del PNOMP a través de variables que fueran capaces de recoger las variaciones climáticas locales. A partir de estos modelos, se calculó el Índice de Refugio o *Refugia Index* (RI: Ashcroft, Gollan, Warton & Ramp, 2012), desarrollado para encontrar potenciales localizaciones de refugios climáticos en escenarios cálidos y fríos [Ashcroft *et al.*, 2012].

La fuente de datos de temperaturas utilizada para los modelos de este estudio se ha basado en mini-sensores de campo de reciente aparición en el mercado. Conviene recordar que existen múltiples maneras de caracterizar el perfil o nicho térmico de un sistema u organismo a partir de registros térmicos [Figura 3.1, Körner & Hiltbrunner, 2018], y que el enfoque de este estudio ha sido el de aproximarse lo más posible a las temperaturas que experimentan las plantas, dado que el objetivo general es detectar sus refugios climáticos. Por ello no es fácil establecer una relación con modelos basados en estaciones climáticas estándar situadas a 1,5-2 m de altitud y en condiciones muy protegidas, que miden temperatura muy por encima de las plantas y en ambientes abiertos. Los escasos estudios previos realizados hasta la fecha con sensores del mismo tipo a los utilizados en este estudio se han situado a distintas alturas (en aire, en suelo o bajo suelo), lo que puede producir medidas algo diferentes [Körner & Hiltbrunner, 2018]. Estos estudios se han basado en temperaturas extremas (mínimas, máximas o percentiles) [Ashcroft *et al.*, 2012; Ashcroft & Gollan, 2012; Niskanen *et al.*, 2016; Meineri & Hylander, 2017; Gubler *et al.*, 2018; Suggitt *et al.*, 2018] pero también de valores promedios [Meineri & Hylander, 2017; Gubler *et al.*, 2018].

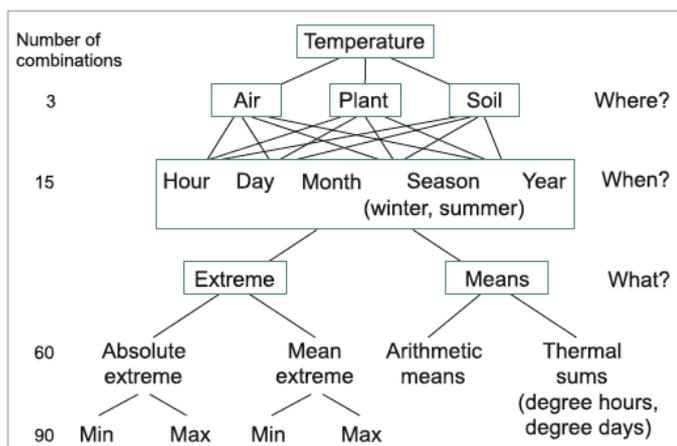


Figura 3.1. Las múltiples combinaciones de datos de temperaturas que pueden ser utilizados para caracterizar el nicho térmico de un organismo o detectar micro-refugios [Figura reproducida de Körner & Hiltbrunner, 2018].

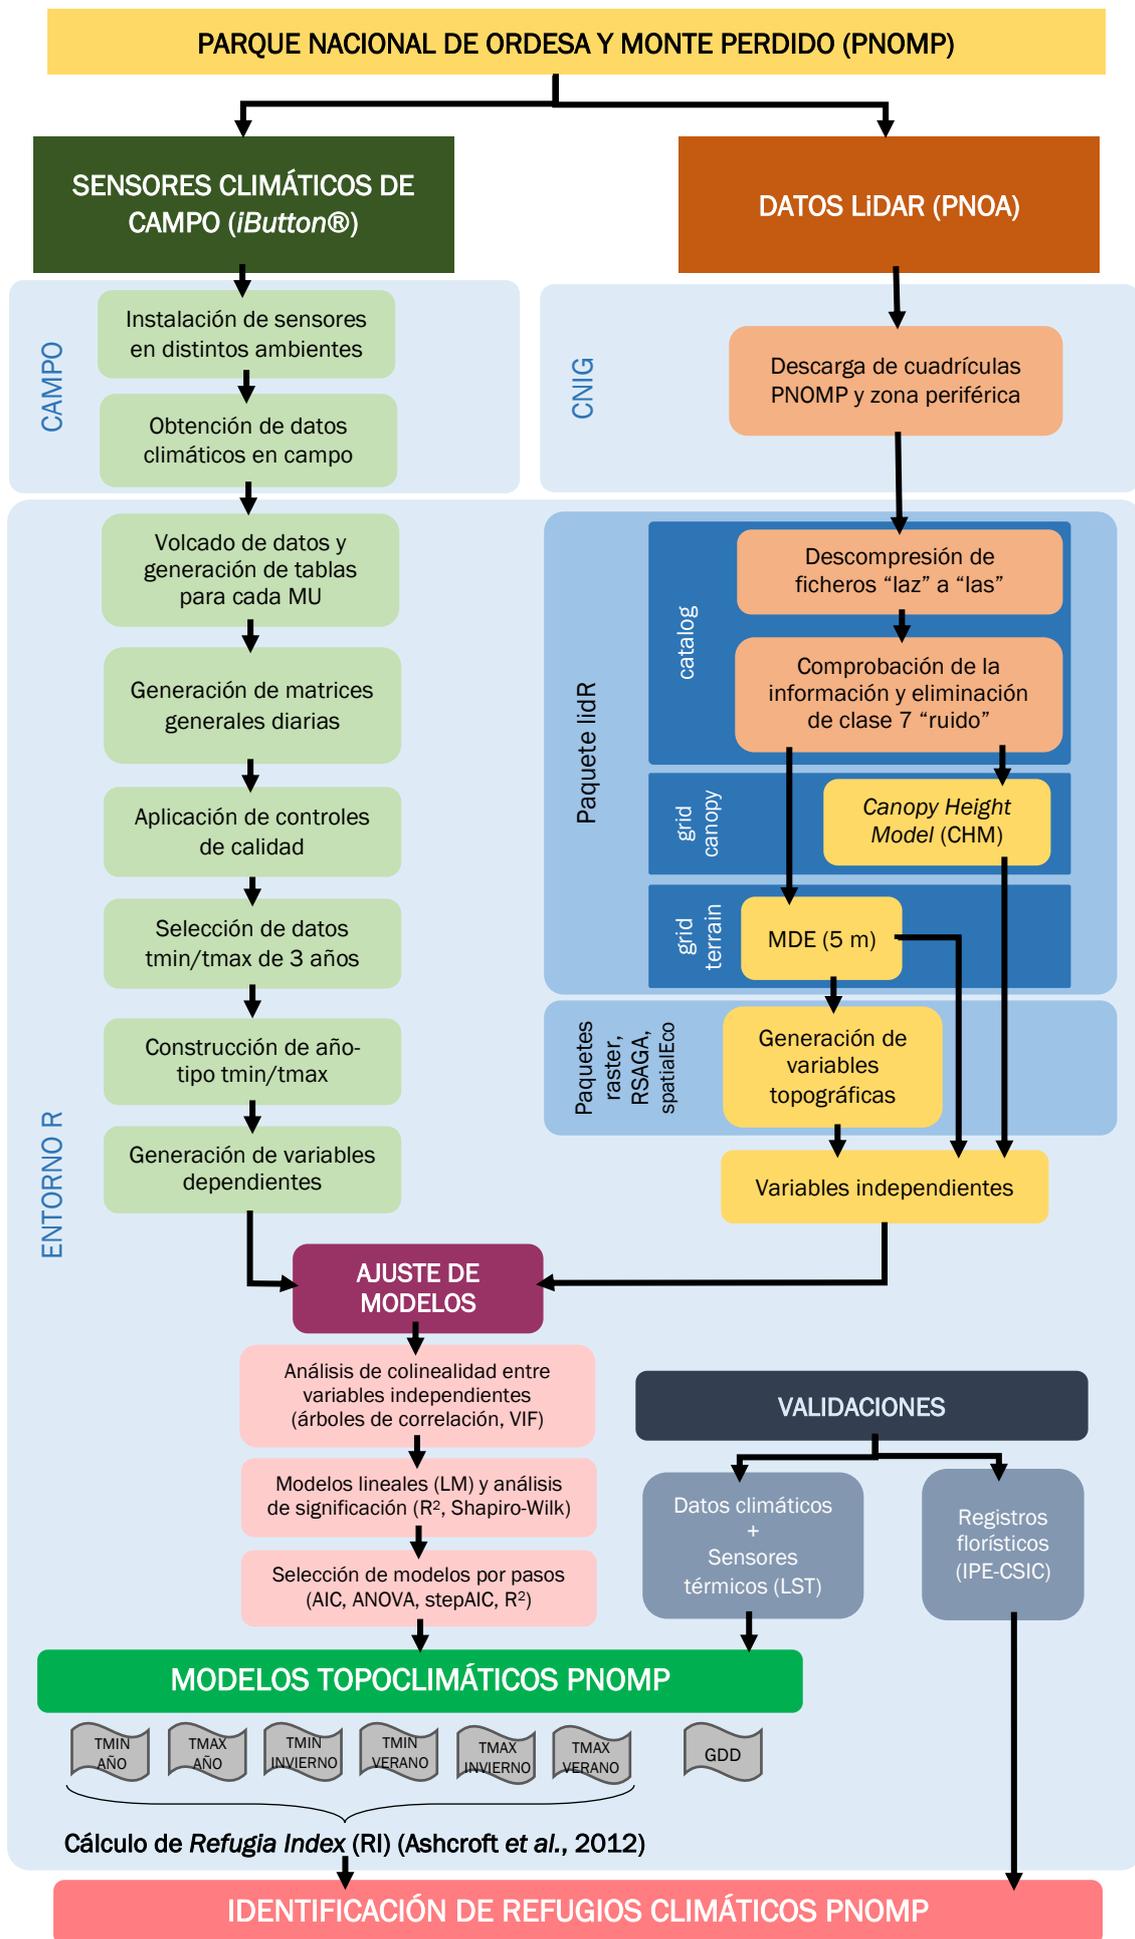


Figura 3.2. Diagrama general del proceso metodológico del estudio.

3.1. Materiales

3.1.1. Entorno R

El entorno de programación R fue la herramienta principal utilizada durante todo el proceso metodológico. Se trata de una plataforma de uso libre y código abierto de análisis estadístico bajo la Licencia Pública General (GPL) del proyecto colaborativo de software libre GNU [Mas, 2013]. Contiene una gran cantidad de paquetes modulares especializados en temas muy diversos que han sido desarrollados por una amplia comunidad de usuarios. Entre estos paquetes están aquellos creados para el análisis espacial y los que permiten operar con Sistemas de Información Geográfica libres (por ejemplo, QGIS, SAGA o GRASS) y datos de teledetección mediante su conexión con el entorno R., convirtiéndolo en una herramienta de enorme potencial para el procesamiento de datos geográficos, el mapeo y el análisis de todo tipo de información georreferenciada [Mas, 2013].

En este trabajo el entorno R permitió la obtención, la organización y el procesado de una amplia base de datos climática procedentes de sensores de campo, el tratamiento de datos de teledetección LiDAR y la generación de información geoespacial, el análisis estadístico de las variables climáticas y geoespaciales para la construcción de los modelos topoclimáticos y su espacialización y, en último término, la detección de los refugios climáticos fríos y cálidos en el PNOMP a partir del cálculo del RI.

3.1.2. Sensores climáticos de campo (*iButton*®)

3.1.2.1. Justificación de uso

La identificación de micro-refugios climáticos se viene desarrollando durante la última década y ha sido abordada en estudios previos a través de dos vías: sensores de campo y estaciones meteorológicas. El uso de sensores se basa en el desarrollo de pequeños registradores de bajo coste que incluyen *data-loggers*, lo que permite la obtención de series temporales de temperaturas en cualquier lugar [Fawcett *et al.*, 2019]. Hasta la fecha, estos minisensores se han utilizado en modelos topoclimáticos de áreas montañosas de los Alpes mediterráneos [Gubler *et al.*, 2018], zonas rugosas costeras del N de Europa [Maclean *et al.*, 2016], y en ámbitos regionales heterogéneos australianos [Ashcroft *et al.*, 2012; Ashcroft & Gollan, 2012; Gollan *et al.*, 2015]. Los modelos topoclimáticos basados en estaciones meteorológicas se han centrado en ámbitos topográficamente más homogéneos y a una escala más regional, como en el noroeste de Finlandia [Niskanen *et al.*, 2016], en el centro y norte de Suecia [Meineri & Hylander, 2017] y en el centro de Inglaterra [Suggitt *et al.*, 2018]. No obstante, también se han realizado estudios en zonas rugosas y heterogéneas a partir de estaciones meteorológicas como en los Alpes mediterráneos [Patsiou *et al.*, 2014].

Dada la complejidad topográfica del PNOMP y el hecho de que sea un área de estudio relativamente pequeña y heterogénea ambientalmente, en este trabajo se utilizaron sensores de campo (*iButton*®) distribuidos por el PNOMP y su área de interpolación que posibilitaron la obtención de datos de temperatura a escala muy local, registrando las temperaturas que experimentan realmente los organismos que allí se encuentran [Ashcroft *et al.*, 2009; Dobrowski, 2011; Gubler *et al.*; 2018], mientras que las estaciones meteorológicas, situadas en altura, pueden tener un componente homogeneizador de

estas particularidades. Además, sólo existe una estación meteorológica de la Agencia Estatal de Meteorología (AEMET) dentro del PNOMP situada a 2.200 m s.n.m. (Góriz) por lo que, en caso de utilizar esta fuente de información, deberían incluirse datos obtenidos fuera del PNOMP e interpolados posteriormente. No obstante, se compararon los valores registrados por los sensores con estaciones meteorológicas proporcionados por el proyecto CLIM'PY y su base de datos STEAD (*Spanish Temperature At Daily-scale*) [Serrano-Notivoli et al., 2019] para validar las temperaturas registradas por los *iButton*®. Se trata de un *dataset* de temperaturas diarias a escala nacional que cubre el periodo entre 1901 y 2015 y que proceden de registros de más de 5.000 estaciones meteorológicas de la Agencia Estatal de Meteorología (AEMET) y del Ministerio de Agricultura y Medio Ambiente del Gobierno de España (MAGRAMA). La comparación de los datos de los sensores se hizo con una serie temporal de los últimos 30 años y a partir de información de las mínimas y las máximas de estaciones situadas en un radio de 50 km del centro del PNOMP e interpoladas a los puntos XYZ de ubicación de los *iButton*®.

3.1.2.2. Características del sensor

Los *iButton*® (Figura 3.3) son dispositivos electrónicos portátiles de reducido tamaño (16 mm de diámetro) desarrollados por la compañía *Maxim Integrated* con numerosas aplicaciones [Fawcett et al., 2019]. En nuestro caso de estudio, se usaron sensores *Termochrones* tipo DS1920 e *Hygrochrones*. La fisonomía de estos aparatos le dota de ciertas particularidades que los diferencian de las estaciones meteorológicas convencionales. Al ser de tamaño reducido y poder ser ubicados en cualquier punto del territorio, están expuestos de manera más directa a las vicisitudes del clima. Durante los meses de invierno y parte de



Figura 3.3. Sensor DS1920 *iButton*®.

la primavera, una gran parte del PNOMP está cubierto por nieve que envuelve a los sensores ubicados cerca del suelo (en pastos y roquedos) y a las plantas. El manto nival protege de temperaturas mínimas extremas a las plantas y esto es lo que les protege de temperaturas extremas en aire. Los *iButton*® registran esta peculiaridad, dando valores de temperatura homogéneos durante todo el periodo en que están cubiertos por la nieve, entre $-1,5^{\circ}\text{C}$ y $1,5^{\circ}\text{C}$; valores que son los que realmente experimentan las plantas que permanecen bajo el manto de nieve. Por otro lado, para evitar los efectos de la radiación solar directa o las tormentas convectivas, los sensores fueron protegidos con una malla mosquitera (Figura 3.4). En este contexto, el 14 de agosto de 2019 se instalaron 6 sensores en la estación meteorológica de Góriz (3 en aire y 3 en suelo, uno sin protección y dos envueltos en dos tipos de tela con distinta luz de malla). Ello permitió comparar los registros dados por ambos durante una semana, y estimar si existen diferencias a diferentes alturas y según el tipo de protección.

3.1.2.3. Puntos de muestreo en el PNOMP

Los 73 *iButton*® utilizados en este estudio se dispusieron en muy diversos ambientes del PNOMP y de su área de interpolación: bosques caducifolios y mixtos, abetales, pinares mediterráneos, montanos y subalpinos; matorrales, pastos subalpinos, gleras y paredones. Una vez colocados en campo, su posición se precisó en el sistema geodésico de referencia ETRS89 para las Península Ibérica, compatible con el datum WGS84, y la proyección UTM



Figura 3.4. Sensores *iButton*® con protección de malla mosquitera. Izda: en árbol; Dcha: en roquedo.

correspondiente, que en el caso del PNOMP es la 30N (zona occidental) y UTM 31N (zona oriental). Para evitar problemas durante el proceso metodológico se trabajó enteramente en proyección UTM 30N, transformándose a este sistema las partes del PNOMP integradas en la zona UTM 31N.

Su distribución por el PNOMP fue realizada de manera progresiva en el tiempo, la mayor parte de ellos entre los años 2012 y 2015. Con frecuencia se localizaron en hábitats de interés comunitario o lugares con presencia de especies de plantas amenazadas, al límite de su distribución o de endemismos (es decir, sitios que presumiblemente podrían ser refugios climáticos); en diferentes tipos de hábitat (bosque, pasto o roquedo). Se dispusieron a distintas alturas (entre 1,20 y 1,50 m del suelo en bosque y entre 2 y 5 cm del suelo en pastos y en roquedos o en grietas donde viven plantas rupícolas en este último caso) con el fin de capturar la temperatura experimentada por las plantas de cada hábitat. Fueron programados para registrar un dato de cada 4 horas (siendo el primer dato de cada día a las 00:00 h), es decir, por cada día se obtuvieron 6 datos de temperatura.

Se trabajó con 73 estaciones o puntos de muestreo localizados entre los 650 y los 2.700 m s.n.m.: 34 en bosques, 23 en zonas abiertas como pastos y matorrales, y 16 en roquedos. Se trata de un número de sensores similar al de otros estudios previos que han realizado modelos topoclimáticos (Ashcroft *et al.*, (2012): 133 *iButton*®; Gubler *et al.*, (2018): 43 *iButton*®), aunque su densidad es mayor debido a la reducida dimensión del área de estudio. La recogida de datos de los sensores fue muy costosa al deber realizarse *in-situ* cada 6 meses en zonas accesibles, y anualmente en lugares elevados más inaccesibles o cubiertos por nieve durante el invierno. Ello ocasionó que en algunos sensores se produjera pérdida de información por memoria llena, al no poder acceder a su ubicación, o deterioro parcial o total por los efectos del clima (tormentas, viento, nieve).

3.1.3. Tecnología LiDAR

El estudio se apoyó en esta tecnología como base para la generación de las variables topográficas. Está fundamentada en la emisión de pulsos láser desde un sensor (generalmente, desde escáneres láser aerotransportados en drones, aviones o helicópteros) y la estimación del tiempo que transcurre hasta que dicho pulso interacciona con la superficie y retorna de nuevo al sensor. Suelen llevar incorporados receptores GNSS-GPS para conocer las coordenadas y la altura del vehículo emisor dando como resultado una nube de puntos tridimensional y georreferenciada que representa la superficie del objeto reflejado.

En este trabajo se usaron los datos LiDAR del PNOA (Plan Nacional de Ortofotografía Aérea), disponibles de manera pública en el Centro Nacional de Información Geográfica (CNIG). Este proyecto está dirigido por el Ministerio de Fomento del Gobierno de España a través de la Dirección General del Instituto Geográfico Nacional (IGN) y del CNIG, además de estar cofinanciado entre la Administración General del Estado y las Comunidades Autónomas [PNOA, 2015]. Entre sus objetivos se encuentra la obtención de Modelos Digitales de Elevaciones (MDEs) de alta precisión para la totalidad del territorio español. Actualmente se encuentra en funcionamiento la segunda cobertura nacional de datos LiDAR con una densidad media de 1 punto por m². Sin embargo, el PNOMP no se encuentra entre las zonas cubiertas por esta segunda cobertura, por lo que se utilizaron datos de la primera correspondiente al año 2010 y con una densidad media de 0,5 puntos por m² (Figura 3.5).



Figura 3.5. Coberturas LiDAR-PNOA publicadas a junio de 2019 [Figura reproducida de IGN-PNOA].

La información LiDAR sirvió para construir un MDE de alta resolución del PNOMP (5 m), siendo la base para la generación de las variables topográficas del modelo topoclimático, y el Modelo de Altura del Dosel Vegetal o *Canopy Height Model* (CHM). El proyecto PNOA y el IGN incorporan entre sus productos un MDE de 5 m de resolución disponible de manera pública; sin embargo, para este trabajo se decidió generar uno nuevo por dos razones: i) desarrollar un proceso automatizado en entorno R que permitiera

obtener un MDE de alta precisión a partir de datos LiDAR y que pudiera ser reproducible para cualquier otro ámbito de estudio; y ii) garantizar que la obtención del CHM, variable independiente de los modelos, procede de la misma nube de puntos que el MDE, el cual será utilizado no sólo como base para la creación de las variables topográficas sino también como predictora del modelo usando la componente de altitud.

3.1.4. Datos climáticos y de teledetección satelital para comparación de modelos

Se usó información de bases de datos climáticas y de temperatura de suelo a partir de datos de sensores remotos para comparar las temperaturas estimadas en diferentes escenarios de temperatura media: anual (BIO-01), estival (BIO-10) e invernal (BIO-11).

- CHELSA (*Climatologies at High-resolution for the Earth's Land Surface Areas*) [Karger et al., 2017]. Base de datos de alta resolución del Instituto Forestal de la Federación Helvética desarrollado en colaboración con el Departamento de Geografía de la Universidad de Hamburgo, generada a partir de temperaturas medias mensuales para el periodo 1979-2003 y con una resolución de 1 km².
- WorldClim [Fick & Hijmans, 2017]. Datos globales de medias mensuales a 1 km² de resolución, tanto la serie de la versión 1 (1971-2000) como la de la versión 2 (2001-2018).
- PDCA (*Pyrenean Digital Atlas Climate*) [Batalla et al., 2018]. *Dataset* de temperaturas mensuales para el periodo 1950-2012 del Pirineo a una resolución de 30 m generado mediante modelos topoclimáticos.

Por su parte, los datos de teledetección satelital permitieron validar la información registrada por los *iButton*® con datos de temperatura a nivel de suelo. Se recurrió a la base de datos EuroLST, basado en información diaria de LST (*Land Surface Temperature*) del sensor MODIS (EOS-TERRA, NASA). Posee una resolución temporal diaria y espacial de 250 m aplicado al continente europeo por Metz et al. (2014) y proporciona información de la temperatura del suelo desde el año 2001 en adelante, lo que constituye un perfecto validador para los datos de los sensores de campo, situados también a nivel de suelo.

3.1.5. Inventarios florísticos para validación biológica de micro-refugios

Dado que el objetivo final del modelo topoclimático era capturar las variables que mejor identificaran los refugios térmicos por su capacidad de alojar plantas capaces de resistir los cambios climáticos, se analizó la relación entre el *Refugia Index* obtenido con el ajuste de modelos topoclimáticos (ver mas adelante), y la proporción de plantas de afinidades cálidas o frías en cada tipo de refugio identificado. Para ello se utilizaron 766 inventarios florísticos realizados en el PNOMP durante los últimos 50 años por botánicos profesionales (más de 15.637 registros de plantas), descargados del portal SIVIM (Sistema de Información de la Vegetación Ibérica y Macaronésica). Tras eliminar aquellos que no contuviesen al menos 10 registros y validar los nombres de los taxa y utilizando la base de datos descrita en García et al (2019) a partir de FLORAPYR [Gómez et al. 2017], cada especie de planta se caracterizó según su corología (Amplia distribución, Endemismo pirenaico, Eurosiberiana, Mediterránea, Alpina y Boreoalpina).

3.2. Metodología

Los métodos utilizados se dividieron en cinco fases principales: i) obtención de las variables dependientes del modelo topoclimático a partir de la información climática diaria procedente de los registros *iButton*®; ii) generación de las variables independientes mediante los datos de teledetección LiDAR del PNOA para la construcción del MDE de alta resolución y las variables topográfico-ambientales derivadas de éste; iii) análisis exploratorio de las variables generadas seleccionando aquéllas más relevantes para la obtención de los modelos topoclimáticos; iv) espacialización de los modelos a toda el área de estudio y comparación con resultados de otros modelos de amplio uso, y; v) cálculo del RI para la identificación de los refugios climáticos cálidos y fríos del PNOMP, el índice combinado y validación de su carácter predictivo mediante inventarios florísticos.

Tabla 3.1. Paquetes utilizados para el análisis de datos espaciales en R.

Fase metodológica de uso	Paquete	Descripción
Organización y análisis de datos climáticos <i>iButton</i> ®	dplyr	Manipulación y operaciones con <i>data frames</i> (Wickham, H.; François, R.; Henry, L.; Müller, K.)
	openxlsx	Creación de ficheros <i>xlsx</i> , escritura de datos y edición de hojas (Walker, A.; Braglia, L.)
	readxl	Importación de datos <i>xls</i> a entorno R (Wickham, H.; Bryan, J. <i>et al.</i>)
Generación de variables dependientes	tidyr	Organización, selección y agregación de datos procedentes de <i>data frames</i> y hojas de cálculo (Wickham, H.; Henry, L.)
Obtención y generación de variables independientes	lidR	Manipulación y visualización de datos LiDAR aeroportados, lectura y escritura de ficheros “ <i>laz</i> ” y “ <i>las</i> ”, eliminación de ruido, filtrado de puntos, normalización, computación de métricas y segmentación en árboles (Roussel, J.R.; Auty, D.; de Boissieu, F.; Sánchez, A.)
	raster	Lectura, escritura, manipulación, análisis y modelado de datos ráster geoespaciales; procesado de grandes conjuntos de datos y operaciones simples con datos vectoriales (Hijmans, R.J. <i>et al.</i>)
	RSAGA	Acceso a los geo-análisis y funciones del terreno del Sistema de Información Geográfica “SAGA” (<i>System for Automated Geoscientific Analyses</i>) usando la versión de comandos de SAGA adaptada a entorno R (Brenning, A.; Bangs, D.; Becker, M.; Schratz, P.; Polakowski, F.)
	spatialEco	Manipulación, creación y modelado de datos espaciales, análisis estadísticos exploratorios y métricas basadas en información ráster (Evans, J.S.; Ram, K.)

El entorno R permitió ejecutar satisfactoriamente todas las fases del trabajo. Se usaron distintos paquetes orientados hacia el análisis de datos espaciales (Tabla 3.1) y los *scripts* generados permitieron obtener y organizar las variables climáticas, tanto los datos procedentes de sensores de campo como los de las estaciones meteorológicas; generar y analizar las variables topográfico-ambientales a partir de paquetes y módulos incorporados

en R para operar con datos abiertos de teledetección LiDAR y SIG libres; realizar análisis exploratorios de las variables para la generación de los modelos topoclimáticos y el cálculo posterior del RI; y, finalmente, visualizar y presentar los resultados a través de figuras, gráficos y productos cartográficos.

3.2.1. Obtención de las variables climáticas dependientes

El objetivo principal de esta primera fase fue disponer de una serie exhaustiva y limpia de datos climáticos. Estudios previos basados en *iButton®* trabajaron con series temporales no muy largas pero a una alta resolución temporal (diaria): Ashcroft *et al.* (2012) utilizó 671 días (2 años) y Gubler *et al.* (2018) 334 días (11 meses). En nuestro caso, se decidió trabajar con los datos diarios registrados por los sensores de campo para caracterizar un año-tipo (12 meses) a partir de datos de 3 años completos (1095 o 1096 días, agrupados por meses consecutivos o no), entre julio de 2012 y julio de 2019. Los datos climáticos seleccionados fueron las temperaturas mínimas y máximas diarias, al ser los extremos térmicos el principal factor que limita la distribución de las plantas, no así las temperaturas medias.

3.2.1.1. Obtención y tratamiento de la información climática

La recogida de los datos de los sensores *iButton®* fue realizada por personal del IPE-CSIC y Agentes de Protección de la Naturaleza (APNs) del PNOMP mediante dispositivos de descarga portátiles desarrollados para tal efecto. El dispositivo se conecta al sensor mediante unas pinzas y la descarga de datos se hace efectiva al presionar el botón correspondiente e iluminarse un *led* que informa si la descarga ha sido correcta (Figura 3.6). Va almacenando en una tarjeta de memoria los registros climáticos tomados por cada uno de los sensores descargados. Como resultado, se obtienen ficheros de texto plano en formato “dat” que incluyen una cabecera (las



Figura 3.6. Descarga de de datos de un *iButton®* en campo.

11 primeras líneas, con los metadatos del sensor y de la información registrada) y los datos climáticos registrados dispuestos en columnas tabuladas. El nombre de estos ficheros es correlativo y no proporciona información explícita del sensor del que procede; esta información se tuvo que extraer de los propios metadatos de cada fichero.

Para la obtención de temperaturas correspondientes a un año-tipo hubo que trabajar con un número estimado próximo a 500 ficheros “dat” procedentes de las distintas descargas realizadas, de los cuales aproximadamente 200 fueron gestionados durante el último año para el desarrollo de este trabajo. Tras finalizar el volcado de cada nueva descarga, ésta fue adjuntada a los datos ya existentes para cada estación. El proceso fue muy laborioso debido a la fragmentación de la información registrada (interrupción de registros por saturación de memoria del sensor y *rollover*, anulación manual de datos

durante el periodo entre el lanzamiento de *iButton*® en oficina y su colocación, etc.). El proceso completo tuvo las siguientes fases:

- i) Extracción de metadatos: La cabecera de los ficheros “dat” contenía información como el código del sensor, necesario para establecer la vinculación con su estación correspondiente; el intervalo de muestreo, para detectar aquéllos erróneos (distintos a las 4 horas predefinidas); o el número de datos registrados.
- ii) Obtención y almacenamiento de datos climáticos: Los valores de temperatura del fichero “dat” fueron transferidos a la tabla de su correspondiente estación usando como clave identificadora el código del sensor. Se creó una lista diaria secuencial en R que sirvió para unir los datos recogidos por el sensor a partir de la fecha y advertir de posibles discontinuidades en la serie temporal. En el caso de que ya hubiera datos procedentes de volcados previos para esa estación, se usó la última fecha y hora registrada en la tabla y se buscó ese registro en el fichero “dat” para adjuntar la información a partir de la fecha y/u hora inmediatamente siguiente; de este modo, se evitó el borrado de datos anteriores.
- iii) Generación de tablas con datos diarios para cada estación: A partir de los 6 datos diarios se extrajeron las temperaturas mínimas y máximas.
- iv) Generación de la matriz general de temperaturas mínimas y máximas: Se crearon dos tablas, una para las mínimas y otra para las máximas, en el que las filas representaron los días y las columnas las estaciones o puntos de muestreo del PNOMP, quedando configurada, de esta manera, la base de datos diaria para producir las variables dependientes.

3.2.1.2. Aplicación de los controles de calidad

La información climática procedente tanto de *iButton*® como de estaciones meteorológicas fue sometida a un control de calidad con el fin de detectar valores sospechosos en los registros de temperatura (Figura 3.7). Como *dato sospechoso* se definió aquél que cumpliera alguno de los siguientes criterios: i) temperatura mínima mayor que la temperatura máxima en el mismo día; ii) varios días consecutivos con el mismo valor de temperatura; y iii) valores extremos anómalos. No existen criterios fijos de control para cualquier base de datos climática ya que algunos se utilizan con mayor frecuencia en función del problema y la observación [Serrano-Notivoli, 2016]. Por este motivo, los controles de calidad aplicados fueron realizados tanto de manera automática como a partir de criterio experto, según el caso concreto, aunque la identificación de estos registros anómalos se hizo siempre de manera iterativa para cada una de las celdas de la matriz general de temperaturas, tanto para mínimas como para máximas.

Para verificar que la temperatura mínima no era superior a la temperatura máxima en un mismo día se realizaron tres iteraciones sucesivas. La primera generó una nueva matriz de error en la que se extrajeron las celdas con los datos erróneos a partir de la comparación celda por celda de la temperatura mínima y máxima para un mismo día y estación. La extracción no se hizo del valor de temperatura sino de la posición XY de este dato en la matriz general, es decir, el lugar en la matriz donde se encuentra el registro erróneo. Una vez terminado el control, en la segunda iteración se creó otra tabla que tomó el valor XY extraído y se identificó la fecha (coordenada X) y la estación (coordenada Y) del dato para poder identificar el dato sospechoso en las matrices generales. Finalmente, la última iteración correspondió a la eliminación automática de los datos erróneos para esos días tanto para las temperaturas mínimas como para las máximas.

Para la identificación de días consecutivos se determinó como sospechoso un registro con el mismo valor 5 o más días seguidos, aplicándose este supuesto a los registros de estaciones potencialmente no cubiertas por manto nival (rango de temperaturas homogéneas admitidas por cubrimiento: de $-1,5^{\circ}\text{C}$ a $1,5^{\circ}\text{C}$). El proceso de detección de estos valores fue similar al supuesto anterior: se creó una matriz de error para extraer la posición XY de los datos consecutivos en las matrices generales y esta información fue recodificada a su correspondiente día y estación. En este caso, los registros sospechosos fueron eliminados siguiendo un criterio experto y no de manera automática, ya que algunos registros consecutivos pueden no ser realmente erróneos.

Los *outliers* o valores extremos anómalos son aquellos no conformes a la variabilidad térmica natural del sitio y fueron identificados atendiendo al criterio experto, dado que ciertos valores extremos pueden ser confundidos con datos anómalos cuando en realidad no lo son. Los sensores de campo registran una mayor variabilidad en las temperaturas al estar más expuestos al clima, situados en ocasiones en zonas singulares como roquedos que pueden calentarse, y presentar amplitudes térmicas diarias y/o anuales más heterogéneas. Por ello, se decidió inspeccionar *outliers* detectados a partir de valores predefinidos: para temperaturas mínimas, aquellas inferiores a -10°C y superiores a 20°C ; y para temperaturas máximas, las inferiores a -3°C y superiores a 40°C .

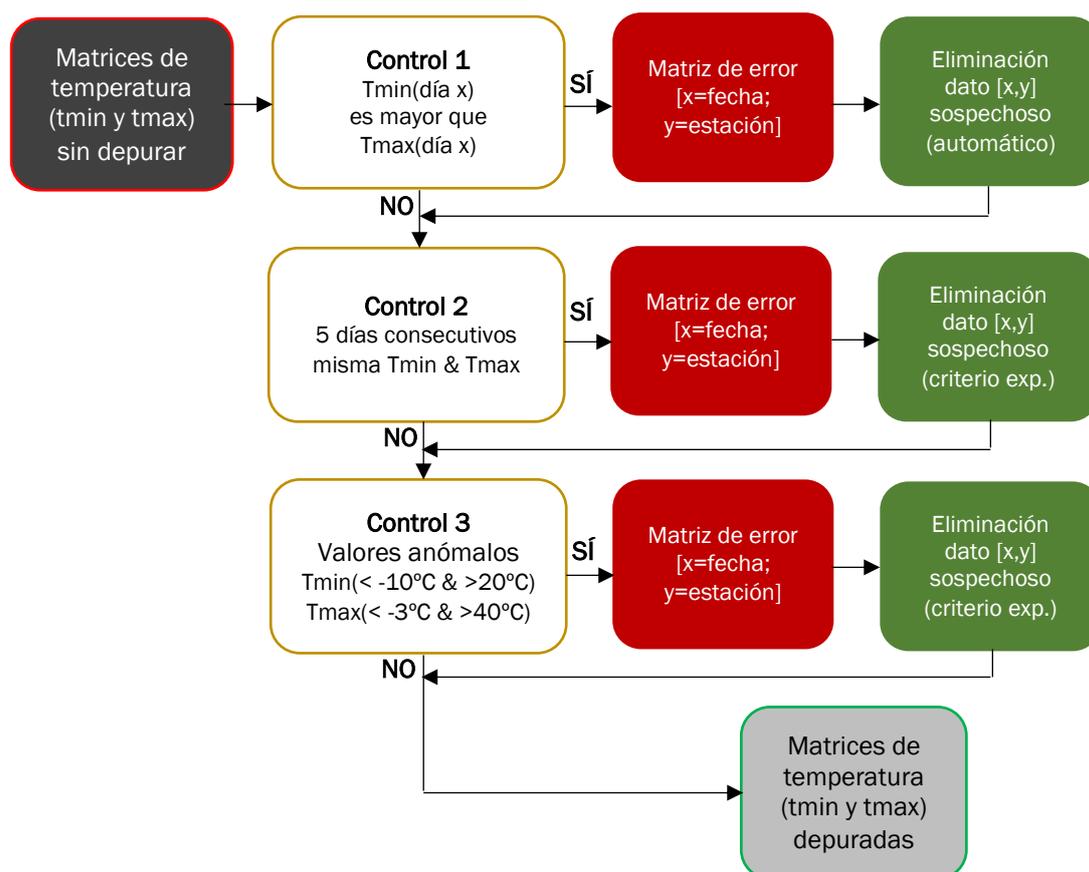


Figura 3.7. Diagrama de flujo de los controles de calidad realizados para las matrices generales de temperaturas máximas y mínimas.

3.2.1.3. Generación de las variables dependientes

Una vez organizados los datos climáticos diarios y realizados los controles de calidad, se generaron las series temporales que conformaron el año-tipo para las variables climáticas o dependientes. Se seleccionaron un total de 3 años completos (36 meses) para cada estación a resolución diaria (1.095 o 1.096 días, dependiendo de los años bisiestos), siendo esta serie idéntica tanto para las mínimas como para las máximas. Se generaron igualmente valores de máximas y mínimas mensuales, siendo 21 el número mínimo de días por mes con 6 registros horarios, descartándose el valor mensual en caso contrario.

La selección de meses para configurar el año-tipo comprendió principalmente los años 2016 y 2018, aunque problemas asociados al registro y la recogida de datos de los *iButton*® y la depuración previa realizada por los controles de calidad, obligaron a utilizar algunos meses de periodos anteriores o posteriores. Este proceso de selección tuvo que hacerse en gabinete y no de manera automática. Sólo algunas estaciones quedaron con registros algo inferiores a los 3 años en total, aunque fueron introducidas en los modelos por su relevancia en el estudio dada su peculiar ubicación o su tipo de hábitat. (Figura 3.8).



Figura 3.8. Selección de la serie temporal para cada uno de los 73 puntos de muestreo.

A partir de estas series se creó el año-tipo como el promedio de las mínimas y de las máximas para cada mes de los 3 años. De esta manera, se obtuvo una tabla con 12 datos mensuales del año-tipo tanto para las mínimas como para las máximas con el fin de caracterizar la temperatura que soportarían las plantas en un año promedio. Los datos mensuales permitieron calcular las variables dependientes para la construcción de los modelos topoclimáticos y que son requeridas por el RI (Tabla 3.2).

Tabla 3.2. Variables dependientes del modelo para la búsqueda de refugios mediante RI.

Variable dependiente	Descripción
Temperatura mínima anual	Promedio de las mínimas de los 12 meses
Temperatura máxima anual	Promedio de las máximas de los 12 meses
Temperatura mínima de invierno	Promedio de las mínimas de diciembre, enero y febrero
Temperatura máxima de invierno	Promedio de las máximas de diciembre, enero y febrero
Temperatura mínima de verano	Promedio de las mínimas de junio, julio y agosto
Temperatura máxima de verano	Promedio de las máximas de junio, julio y agosto

Además de las variables calculadas para el RI se derivó directamente de la serie temporal de 3 años los días de crecimiento vegetativo o *Growing Degree Days* (GDD), que son aquéllos con temperatura media diaria superior a 5°C y que permite el desarrollo de las plantas.

3.2.2. Obtención de las variables independientes

En esta segunda fase se trabajó en la generación de los predictores topográfico-ambientales o variables independientes de los datos *iButton*®. Estas variables fueron seleccionadas por su influencia en la variabilidad de la temperatura en zonas topográficamente complejas, creándose un total de 11 predictores ráster para el área del PNOMP usando cuatro paquetes en entorno R: “lidR” [Roussel, Auty, de Boissieu & Sánchez], “raster” [Hijmans et al.], “RSAGA” [Brenning, Bangs, Becker, Schratz & Polakowski] y “spatialEco” [Evans & Ram] (Tabla 3.3).

El paquete “raster” permitió, en todos los casos, exportar los resultados en formato “tif”. En esta fase se procesaron los datos LiDAR para la construcción del MDE y el CHM, se generaron el resto de predictoras topográfico-ambientales y, finalmente, se agruparon todas las variables en una capa multibanda.

Tabla 3.3. Variables predictoras generadas para los modelos topoclimáticos.

Forma de obtención	Variable	Descripción	Unidad	Referencias
Paquete "lidR"	Altitud	MDE	m.s.n.m.	* <i>variable principal</i>
	CHM – Canopy Height Model	Modelo de Altura del Dosel Vegetal	Log(m)	Ashcroft <i>et al.</i> , 2012 Maclean <i>et al.</i> , 2019
Paquete "raster"	Pendiente	Pendiente topográfica en grados.	°	Maclean <i>et al.</i> , 2016 Niskanen <i>et al.</i> , 2016 Bátori <i>et al.</i> , 2017 Meineri & Hylander, 2017 Gubler <i>et al.</i> , 2018
	Orientación	Orientación respecto al norte en grados.	°	Meineri & Hylander, 2017 Gubler <i>et al.</i> , 2018
	Elevación relativa	Altitud de un punto respecto a los de su alrededor a partir de funciones focales.	m	Ashcroft & Gollan, 2012 Meineri & Hylander, 2017
Fórmula	SEI – Solar Exposure Index	Índice combinado de pendiente y orientación según Balice <i>et al.</i> , 2000.	Índice	Balice <i>et al.</i> , 2000 Ashcroft <i>et al.</i> , 2012 Gubler <i>et al.</i> , 2018 Suggitt <i>et al.</i> , 2018
SAGA-GIS en entorno R (Paquete "RSAGA")	PISR – Potential Incoming Solar Radiation	Índice de Radiación Solar Potencial Incidente calculado para un año-tipo.	KWh/m ²	Hofierka & Suri, 2002 Niskanen <i>et al.</i> , 2016 Meineri & Hylander, 2017 Gubler <i>et al.</i> , 2018 Niederheiser <i>et al.</i> , 2018
	WEI – Wind Exposition Index	Índice de Exposición al Viento.	Índice	Boehner & Antonic, 2009 Gerlitz <i>et al.</i> , 2015 Maclean <i>et al.</i> , 2016 Harris & Baird, 2018
	TRI – Terrain Ruggedness Index	Índice de Rugosidad del Terreno.	Índice (Log)	Riley <i>et al.</i> , 1999 Niederheiser <i>et al.</i> , 2018 Tile & Bemmels, 2018
	TWI – Topographic Wetness Index	Índice de Humedad Topográfica.	Índice	Beven & Kirkby, 1979 Hojati & Mokarram, 2016 Niskanen <i>et al.</i> , 2016 Meineri & Hylander, 2017
Paquete "spatialEco"	Curvatura del terreno	Índice de Concavidad/Convexidad del terreno	Índice	McNab, 1989 Bolstand & Lillesand, 1992 McNab, 1993 Gubler <i>et al.</i> , 2018

3.2.2.1. Tratamiento de los datos LiDAR

Para la creación del MDE de alta resolución y el CHM del PNOMP se descargaron un total de 135 archivos LiDAR del programa PNOA disponibles de manera pública en el centro de descargas del CNIG, que cubrían la totalidad del área de estudio y su zona periférica. Se trata de ficheros digitales con información altimétrica de la nube de puntos distribuidos en ficheros de 2x2 km de extensión que forman un conjunto de mallas cuadrículas que cubren la totalidad del territorio nacional. Los archivos se encuentran georreferenciados en el sistema geodésico de referencia ETRS89 para la Península Ibérica y la proyección UTM según el huso correspondiente (en el caso del PNOMP, el 30N y el 31N). Estos ficheros se obtuvieron en formato “laz”, una versión comprimida de los archivos “las”, introduciendo una máscara vectorial con los límites del PNOMP y de su zona periférica en el visor del centro de descargas para la selección automática de las cuadrículas. Este proceso de obtención de las mallas LiDAR fue el único no automatizado en R puesto que actualmente no está disponible la descarga de datos del IGN a través de *scripting*.

El tratamiento de la información se hizo enteramente con el paquete “lidR”. Dada la enorme cantidad de datos a procesar, el primer paso fue el ajuste de los parámetros de computación (función propia de “lidR”) como la definición del límite de memoria, número de núcleos o *cores* a utilizar, el tamaño del procesado para cada cuadrícula LiDAR (sub-cuadrículas) o el tamaño del *buffer* de procesado entre sub-cuadrículas para evitar vacíos entre éstas. Esto permitió optimizar los recursos computacionales y agilizar el procesado de los datos LiDAR. Asimismo, se definió para la totalidad de las cuadrículas la proyección UTM 30N, por lo que la zona oriental del PNOMP (en UTM 31N) tuvo que ser transformada a este huso.

Tras ello se procedió a la descompresión de los archivos “laz” a formato “las”. Todos ellos se encontraban clasificados por defecto de manera automática en diferentes clases existiendo algunos errores altimétricos catalogados como “ruido” y clasificados en la clase 7. Seguidamente se generó un catálogo para englobar en un único *dataset* las 135 cuadrículas “las” mediante la función “catalog”. Seguidamente, se extrajeron los retornos con valores anómalos eliminando la clase 7 (“ruido”) del *dataset* a través de la función “lasfilter”. Con la nube de puntos filtrada se aplicó la función “grid_terrain” que interpoló la nube de puntos clasificados como suelo (clase 2) a partir del método TIN y permitió la generación del MDE a una resolución de 5 m (Figura 3.9).

El último paso consistió en la creación de la variable CHM mediante la función “grid_canopy” sobre el *dataset*, que produjo un Modelo Digital de Superficie (MDS) usando el algoritmo “pitfree” de Khosravipur *et al.* (2014), basado en la triangulación de Delaunay, y extrajo las clases de vegetación de la nube de puntos para estimar la altura de cubrimiento del dosel vegetal. Debido a la existencia de paredones verticales en el PNOMP con vegetación, algunos píxeles de CHM obtuvieron valores de 45 m. El CHM fue elegida como variable porque condiciona la entrada de la radiación solar a niveles superficiales [Dobrowski, 2011; Ashcroft & Gollan, 2012; Maclean *et al.*, 2016; Meineri & Hylander, 2017], pudiendo crear micro-climas locales en estos niveles donde habitan las plantas. Ha sido usada como variable predictora para la identificación de micro-refugios en los estudios de Ashcroft *et al.* (2012) y Maclean *et al.* (2019). Dado el carácter no-predictivo del estudio sino de caracterización de hábitats, no se tuvo en cuenta el desfase temporal existente desde la toma de datos LiDAR (2010).

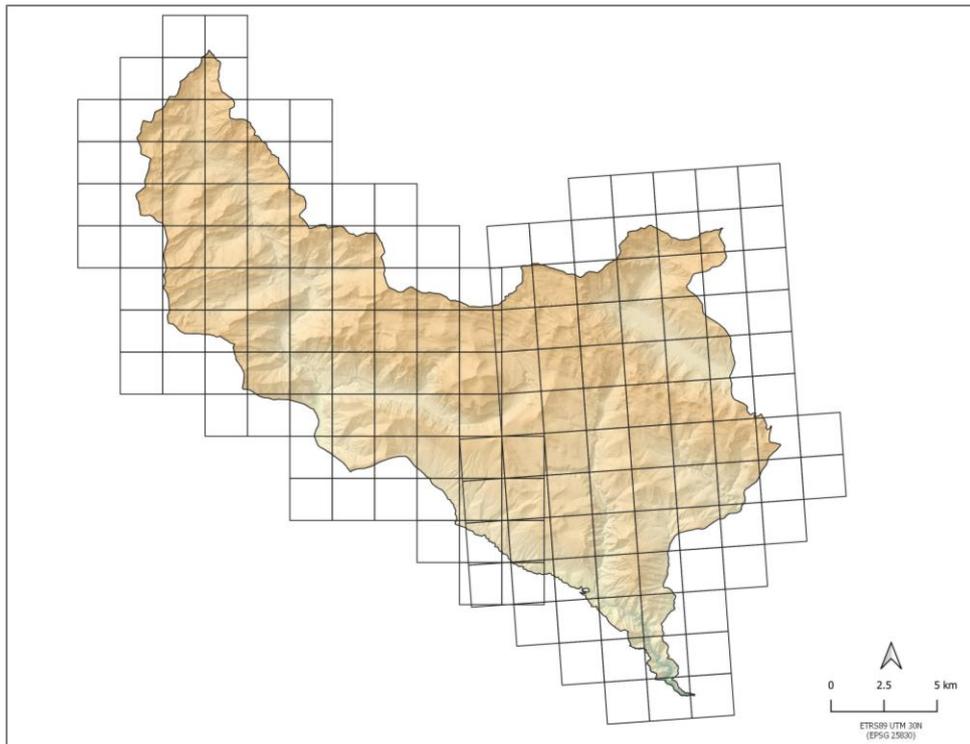


Figura 3.9. MDE de 5 m de resolución resultante de LiDAR con cuadrículas LiDAR-PNOA utilizadas.

3.2.2.2. Generación de los predictores topográfico-ambientales

El MDE generado con LiDAR se usó para obtener las variables topográficas predictoras a una resolución de 5 m mediante diferentes paquetes en entorno R. El módulo *terrain* del paquete “raster” calculó la pendiente, la orientación y la elevación relativa a partir del MDE. El paquete “RSAGA” permitió la conexión del modo de comandos del SIG “SAGA” al entorno R para generar las variables basadas en índices topográfico-ambientales (excepto el SEI). Para poder realizar los procesos en SAGA, hubo que convertir los ráster de entrada a formato “sgrd” y, posteriormente, exportar los de salida como “tif” haciendo uso del paquete “raster”. Por último, el paquete “spatialEco” posibilitó la obtención de la curvatura del terreno a partir del Índice de Concavidad/Convexidad.

- Las principales variables derivadas del MDE fueron la pendiente (calculada en grados) y la orientación (en grados), ambas usadas en un gran número de estudios microclimáticos previos [Lundquist *et al.*, 2008; Ashcroft *et al.*, 2012; Keppel *et al.*, 2015; Maclean *et al.*, 2016; Niskanen *et al.*, 2016; Bátori *et al.*, 2017; Meineri & Hylander, 2017; Gubler *et al.*, 2018; Niederheiser *et al.*, 2018; Suggitt *et al.*, 2018], y utilizadas para calcular las variables predictoras del modelo basadas en índices topográfico-ambientales.
- La elevación relativa se usó como aproximación a la corriente fría del aire o *cold-air drainage* [Ashcroft & Gollan, 2012; Meineri & Hylander, 2017], factor climático que se produce desde las altas a las bajas elevaciones con efectos pronunciados en las temperaturas locales de los fondos de valle [Dobrowski, 2011; Novick *et al.*, 2016]. Este hecho produce inversiones térmicas en las zonas bajas donde la temperatura aumenta con la elevación [Hylander *et al.*, 2015]. Su cálculo se realizó a partir de la diferencia entre dos funciones focales (máximas y mínimas) incluidas en el paquete “raster” mediante una ventana *kernel* de 9x9 aplicada sobre el MDE.

- El Índice de Exposición o *Solar Exposure Index* (SEI) se calculó a partir de la fórmula propuesta por Balice et al. (2000) que pone en relación la pendiente (calculada para este índice en porcentaje) y la orientación para estimar el grado de exposición solar que un punto del territorio experimenta durante las estaciones de crecimiento vegetativo. La ecuación asume que en un sitio con pendientes escarpadas y una orientación de 190° respecto al norte geográfico recibirá la mayor cantidad de radiación solar [Balice et al., 2000; Ashcroft et al., 2012; Gubler et al.; 2018], un factor que en zonas topográficamente complejas puede producir variaciones climáticas locales significativas.

$$SEI = pendiente * \cos\left(\frac{\pi * (orientacion - 190)}{180}\right)$$

- El grado en que un punto del territorio está expuesto al viento fue calculado a través del Índice de Exposición al Viento o *Wind Exposure Index* (WEI) basado en los estudios de Boehner & Antonic (2009). Este índice calculó el promedio del efecto del viento en todas las direcciones en un píxel usando un paso angular [Boehner & Antonic, 2009; Maclean et al., 2016; Harris & Baird, 2018]. Los valores por debajo de 1 significaron áreas protegidas del efecto del viento mientras que los que se situaron por encima de 1 indicaron áreas de gran exposición. Estas diferencias suelen propiciar cambios en las temperaturas a escala local, especialmente en áreas rugosas.
- El cálculo de la rugosidad se realizó a través del Índice de Rugosidad del Terreno o *Terrain Ruggedness Index* (TRI) de Riley et al. (1999). Este modelo proporcionó una medida cuantitativa de la heterogeneidad topográfica a partir del MDE mediante la aplicación de funciones focales basadas en la vecindad entre píxeles, donde una mayor diferencia indica una alta rugosidad del terreno [Riley et al., 1999; Niederheiser et al., 2018; Tile & Bemmels, 2018]. Por su parte, el Índice de Humedad Topográfica o *Topographic Wetness Index* (TWI), de Beven & Kirkby (1979), permitió aproximarse al contenido de humedad del suelo y modelizar potenciales áreas de acumulación de agua [Beven & Kirkby, 1979; Moore et al., 1991; Boehner & Selige, 2006; Meineri & Hylander, 2017].
- Por último, con “spatialEco” se calculó la curvatura del terreno como otra forma de aproximación a la corriente de aire frío o *cold-air drainage* [Meineri & Hylander, 2017; Gubler et al., 2018] mediante el Índice de Concavidad/Convexidad de McNab (1989), Bolstand & Lillesand (1992) y McNab (1993). Esta variable se considera un componente importante de aproximación ecológica al permitir modelar la forma del terreno, que influye en un gran conjunto de patrones climáticos incluyendo las temperaturas a nivel superficial, sobre todo en áreas montañosas [McNab, 1993].

3.2.2.3. Extracción de los valores a los puntos de muestreo

Obtenidas las 11 variables topográfico-ambientales (Figura 3.10) se procedió a su agrupación en un archivo ráster multibanda mediante la función “stack” del paquete “raster”, archivo del que se extrajeron los valores de cada una de las variables predictoras en las 73 estaciones del PNOMP dotadas de *iButton*®. De esta forma se pudieron generar dos tablas compuestas por las estaciones (filas) y las variables dependientes e independientes (columnas), uniéndose posteriormente para generar la matriz final que entraría en el proceso de modelización.

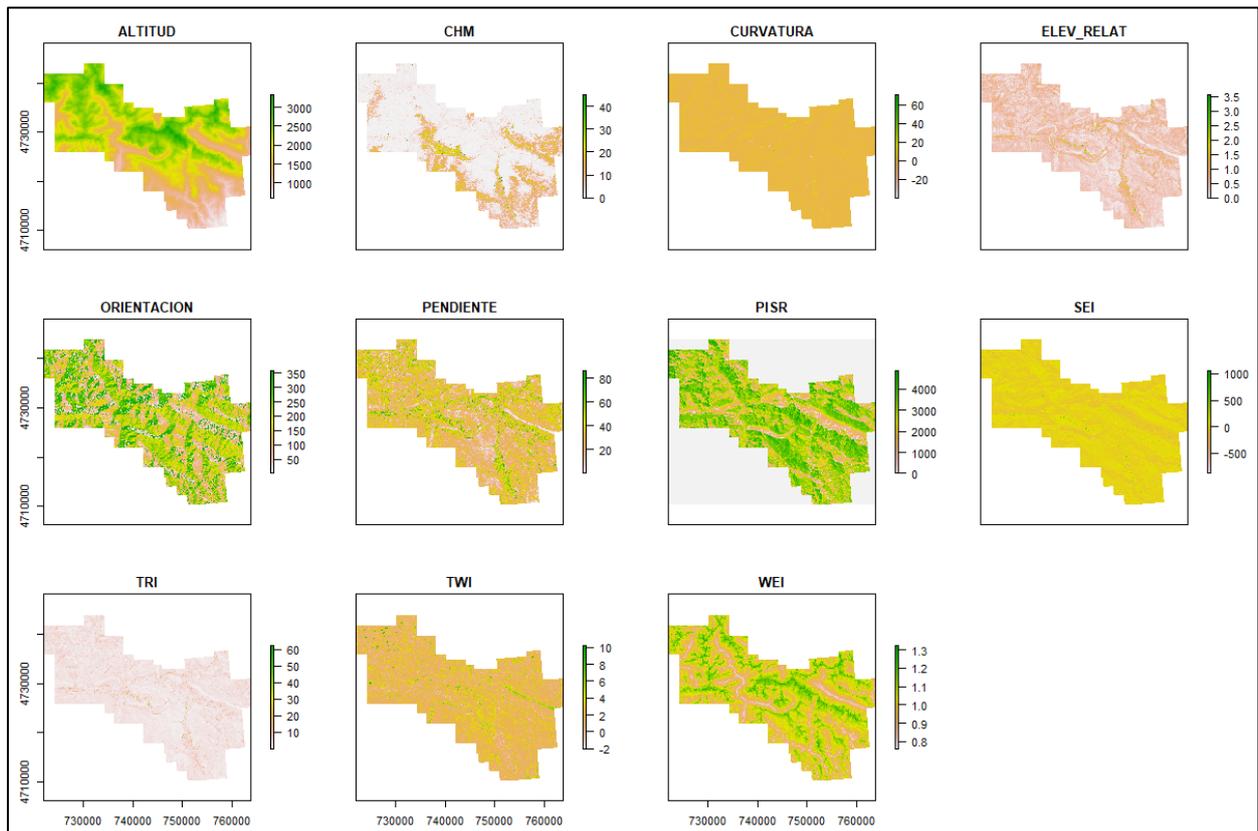


Figura 3.10. Variables topográfico-ambientales predictoras generadas: i) Altitud; ii) CHM; iii) Curvatura; iv) Elevación relativa; v) Orientación; vi) Pendiente; vii) PISR; viii) SEI; ix) TRI; x) TWI; xi) WEI.

3.2.3. Análisis exploratorio y ajuste de modelos

Se realizaron diversos análisis exploratorios de las variables dependientes e independientes previa a su modelización. En primer lugar, se confirmó que todas las predictoras se ajustaban a una distribución normal excepto CHM y TRI que tuvieron que ser transformadas logarítmicamente. Posteriormente, distintos análisis de correlación mostraron la existencia de asociaciones significativas y colinealidad entre algunas de ellas, identificándose cuatro grandes grupos de variables relacionadas mediante árbol de correlación (Figura 3.11): 1) SEI y PISR; 2) orientación y curvatura; 3) TWI, TRI, elevación relativa y pendiente; 4) CHM, WEI y altitud; la correlación fue menor en el grupo 1 y mayor en el 2 (ramificación más baja y alta respectivamente).

Una posterior *comparación por pares* (Figura 3.12) identificó una alta correlación ($R^2 \geq 0,60$) en ciertas variables que se relacionaban con los grupos establecidos por el árbol de correlación; por ejemplo, la altitud y WEI; elevación relativa, pendiente, TRI y TWI; y PISR y SEI. Finalmente, se examinó la relación de cada una de las variables dependientes con las independientes para estimar el grado de ajuste de las primeras a cada una de las predictoras.

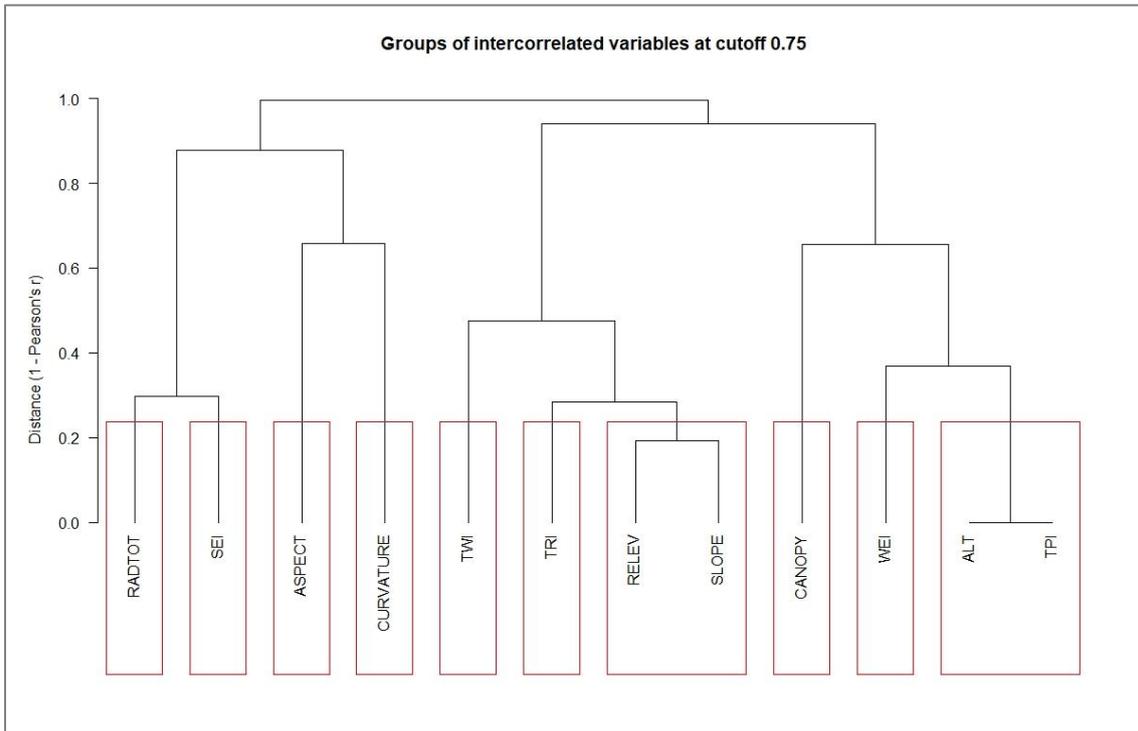


Figura 3.11. Árbol de correlación de las variables predictoras. Se formaron cuatro grandes grupos (ramificaciones) de relación.

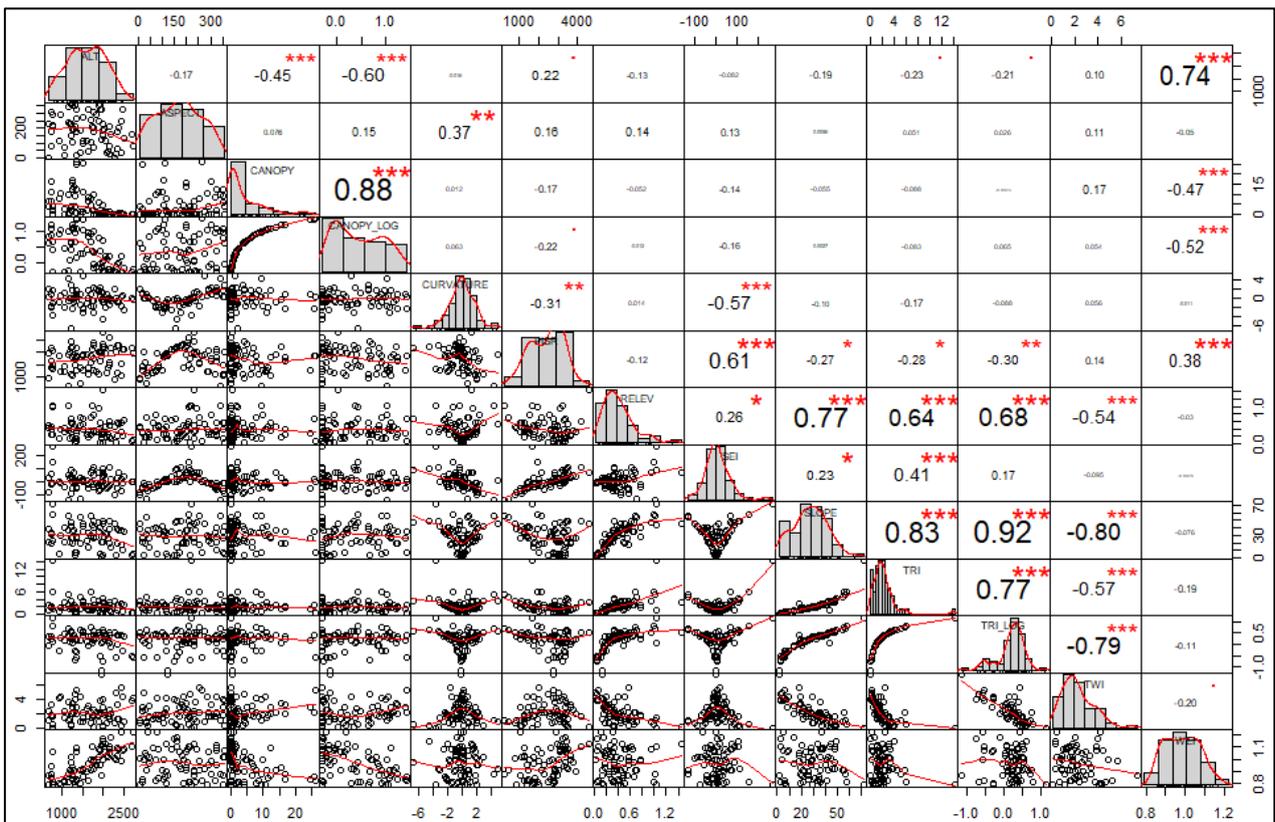


Figura 3.12. Gráfico de comparación por pares de las variables predictoras. Se identificaron relaciones similares a los identificados en el árbol de correlación.

Las variables independientes introducidas finalmente en los modelos fueron la altitud, por poseer la mayor correlación de todas las predictoras con las variables climáticas, y una variable de cada uno de los cuatro grupos identificados por el árbol de correlación, siendo éstas las que menor conflicto tenían con el resto de predictoras (examinado en el gráfico de correlaciones): PISR, orientación, TWI y CHM. Se realizó, como último paso exploratorio, un análisis VIF (*Variance Inflation Factor*) que confirmó la no-colinealidad de las variables definitivas.

Tras comprobar mediante modelos GAM (*Generalized Additive Models*) que la relación entre temperaturas y la principal variable predictora (altitud) era lineal se procedió al ajuste de modelos mediante funciones lineales (LM), creándose tres tipos de modelos para cada variable climática en los que se compararon sus ajustes para determinar el más significativo. El primer modelo fue el topográfico-básico e incluyó como única variable predictora la altitud; el segundo fue el modelo CHM, que usó la altitud y el CHM como predictoras; y el tercero fue el modelo topográfico-completo, que incluyó todas las variables seleccionadas potencialmente como predictoras (altitud, PISR, orientación, TWI y CHM). Ello permitió conocer el grado de relevancia de la inclusión del CHM y del conjunto de las variables topográficas en los modelos frente a la altitud, que suele presentarse como principal predictora de la temperatura y que, en nuestro caso, fue la que mayor correlación tuvo con las variables climáticas. Los mejores ajustes se lograron, en todos los casos, con el modelo topográfico-completo excepto en las temperaturas mínimas de invierno, que alcanzó una mayor significación en el modelo CHM.

Para cada variable dependiente y mediante análisis exploratorios por pasos se compararon modelos con distintas combinaciones de las variables predictoras, utilizando para su selección el menor índice AIC (*Akaike's Information Criterion*), los valores de VIF ($VIF < 2$), y la existencia de diferencias significativas resultantes de un análisis ANOVA (*Analysis of Variance*) entre modelos con distintas variables predictoras. En todos los casos el modelo topográfico-completo fue más explicativo respecto a sus alternativos excepto en las mínimas de invierno que lo fue el modelo CHM. Para cada variable climática se determinó así un conjunto diferente de predictoras que serán la base de los modelos topoclimáticos y el RI (Tabla 3.4).

Tabla 3.4. Predictoras seleccionadas para cada modelo topoclimático

Variable climática (dependiente)	Variables predictoras (independientes)
Temperatura mínima anual	Altitud, CHM, orientación, TWI
Temperatura máxima anual	Altitud, PISR, orientación, TWI
Temperatura mínima de invierno	Altitud, CHM
Temperatura mínima de verano	Altitud, PISR, orientación, TWI
Temperatura máxima de invierno	Altitud, PISR, TWI
Temperatura máxima de verano	Altitud, CHM, PISR, orientación, TWI
<i>Growing Degree Day</i> (GDD base 5°C)	Altitud, PISR, TWI

Los modelos topoclimáticos generados fueron espacializados a la totalidad del PNOMP y zona periférica obteniéndose 6 archivos ráster a una resolución de 5 m mediante el paquete “raster”.

3.2.4. Comparación con otras bases de datos

Con el fin de explorar e interpretar diferencias entre los resultados obtenidos en el presente estudio y los que se hubiesen generado mediante modelos públicos de uso frecuente, se realizó una comparación de diferentes variables climáticas (temperatura media anual, estival e invernal) con los datos climáticos de CHELSA, WorldClim y PDCA, y de temperatura de suelo extraído de EuroLST (MODIS). Los *datasets* descargados fueron recortados al área de estudio y extraída la información en los 73 puntos de muestreo para los tres escenarios. Se aplicó el estadístico Kruskal-Wallis de comparación de medias para establecer el grado de significación entre modelos y se generaron gráficas de caja (*boxplots*) para comparación visual. En el caso concreto de EuroLST, la comparación pudo considerarse una validación del modelo propuesto en este estudio, puesto que sus datos eran muy similares a los que proporcionan los *iButton*® excepto en el caso de bosques. Por esa razón, las comparaciones se realizaron de forma separada para cada tipo de hábitat.

3.2.5. Cálculo del Refugia Index (RI)

Los potenciales refugios climáticos del PNOMP fueron identificados a partir de los modelos topoclimáticos usando el concepto de *Refugia Index* (RI) propuesto por Ashcroft *et al.* (2012). Se trata de una aproximación analítica que combina:

- i) Las temperaturas extremas, con el fin de generar escenarios inhóspitos en los que detectar refugios.
- ii) Las localizaciones que son climáticamente más estables, puesto que la estabilidad es un requisito inherente al concepto de refugio en situación de cambios en las temperaturas.
- iii) Las localizaciones con temperaturas más diferentes al promedio de la región, dado que, por definición, un refugio para un organismo se encuentra aislado en una matriz ambiental desfavorable.

Puesto que el concepto de refugio es relativo, y lo que puede ser refugio para un organismo adaptado al calor no lo será para uno adaptado al frío, este índice fue calculado tanto para escenarios cálidos como fríos haciendo uso de las temperaturas máximas y mínimas respectivamente. En el escenario cálido, las temperaturas extremas utilizadas fueron las máximas anuales, la estabilidad climática fue el resultado de la diferencia entre las máximas de verano y las de invierno, y la diferencia respecto a la región se obtuvo mediante la diferencia entre la temperatura máxima de verano y el promedio de las máximas de verano para toda el área de estudio. Asimismo, para el escenario frío se utilizaron como temperaturas extremas las mínimas anuales, la estabilidad climática fue la diferencia entre las temperaturas mínimas de verano y las de invierno, y la diferencia respecto a la región se halló mediante la diferencia entre la mínima de invierno y el promedio de la mínima de invierno para toda el área de estudio.

Tabla 3.5. Variables incluidas en el *Refugia Index*

Escenario	Variable climática	Forma de obtención
Cálido	i) Temperatura extrema	Temperatura máxima anual
	ii) Variabilidad climática	Diferencia entre la máxima de verano y la máxima de invierno
	iii) Aislamiento regional	Diferencia entre la máxima de verano en un punto y el promedio de las máximas de verano del PNOMP
Frío	i) Temperatura extrema	Temperatura mínima anual
	ii) Variabilidad climática	Diferencia entre la mínima de verano y la mínima de invierno
	iii) Aislamiento regional	Diferencia entre la mínima de invierno en un punto y el promedio de las mínimas de invierno del PNOMP

Estos tres componentes fueron estandarizados para poder hacerlos comparables entre sí mediante los *Z-valores* ($[x - \text{media}] / \text{desviación estándar}$). Resultados positivos de estos *Z-valores* indican sitios con temperaturas elevadas, con alta variabilidad climática (inestable) y más cálidos que el promedio de la región; resultados negativos de los *Z-valores* indican lugares con temperaturas bajas, con poca variabilidad climática (estable) y más fríos que el promedio de la región. La obtención del RI se obtuvo mediante dos fórmulas en función de si el valor del *Z-valor* de la diferencia respecto a la región era positiva (sitio cálido) o negativa (sitio frío).

En caso de que el sitio fuera más frío que la región:

$$RI = \frac{(Ztemp + Zvar + Zmatrix)}{3}$$

En caso de que el sitio fuera más cálido que la región:

$$RI = \frac{(Ztemp + (-1) * Zvar + Zmatrix)}{3}$$

Donde *Ztemp* es el *Z-valor* basado en las temperaturas extremas, *Zvar* es el *Z-valor* basado en la variabilidad climática y *Zmatrix* es el *Z-valor* basado en la diferencia respecto a la región. Cuando el valor de *Zmatrix* era positivo fue necesario invertir el signo de *Zvar* ya que la estabilidad climática viene dada por valores negativos y ello penalizaba el valor final de RI para refugios cálidos. La fórmula permitió la identificación de refugios climáticos fríos cuando los valores RI fueron bajos (< 0), teniendo en cuenta que un refugio frío debe tener temperaturas bajas ($Ztemp < 0$), estabilidad climática ($Zvar < 0$) y diferencias negativas respecto a la temperatura regional ($Zmatrix < 0$). Asimismo, los refugios cálidos obtuvieron valores RI altos (> 0) al tener temperaturas altas ($Ztemp > 0$), ser igualmente estables ($Zvar < 0$; por ello en este caso *Zvar* tuvo que ser invertida) y con diferencias positivas respecto a la temperatura de la región ($Zmatrix > 0$). La obtención del RI para cada pixel definido en el PNOMP permitió identificar potenciales refugios climáticos y generar las cartografías finales de refugios climáticos fríos para un contexto de aumento de las temperaturas (escenario cálido) y de refugios climáticos cálidos para un contexto de

descenso térmico (escenario frío). Finalmente, se elaboró un “Índice de Refugio Combinado” mediante la suma de los valores resultantes en ambos escenarios, que muestra las zonas del PNOMP más cálidas y estables (valores altos en los dos escenarios) y más frías (valores bajos en los dos escenarios) con independencia del escenario cálido o frío. Al integrar los dos tipos de escenarios, este índice combinado destaca los lugares que han podido servir como refugio en distintas épocas geológicas, alternándose periodos glaciares e interglaciares.

3.2.6 Validación biológica de los refugios climáticos

Dado que los inventarios florísticos se encuentran georreferenciados en la proyección UTM 30N a escala de 1 km², tras superponer la malla UTM a la zona de estudio se calculó un RI para cada UTM como el valor medio de todos los píxeles de 5x5 m incluidos en cada UTM. El porcentaje medio de plantas alpinas y boreoalpinas (adaptadas al frío), y mediterráneas (adaptadas al calor) de los inventarios contenidos en cada UTM se promedió para obtener un único valor de la frecuencia de adaptadas al frío y al calor por separado en cada celda. Con el fin de explorar si existe una buena asociación entre lo que nuestros modelos determinan como refugios cálidos o refugios fríos y la composición de plantas de afinidades cálidas o frías respectivamente, se calculó el coeficiente de correlación de Pearson entre el “RI combinado” de cada UTM y la proporción de plantas cálidas y plantas frías. Una buena relación (positiva o negativa) indicará que el modelo está realmente detectando refugios climáticos, validando de esta forma el modelo topoclimático. Para asegurar que la relación entre “RI combinado” y proporción de plantas no es debida al efecto de la altitud (variable muy ligada a las temperaturas extremas que se usan en el RI), se compararon dos modelos GLM (*Generalized Linear Model*) asociando las proporciones de los dos tipos de plantas y el RI combinado, con y sin la variable altitud, lo que permitirá determinar si su efecto es significativo.

4. Resultados

4.1. Datos climáticos de los iButton®

4.1.1. Controles de calidad

Los controles de calidad aplicados a los datos diarios no detectaron valores de mínimas que fueran más elevadas que las máximas en un mismo día en toda la serie temporal. Sin embargo, se identificaron numerosos casos de días consecutivos con un mismo valor de temperatura, tanto en mínimas como en máximas, que fue necesario verificar. La gran mayoría de estos casos se debió al cubrimiento de nieve que experimentan los sensores entre los meses de diciembre y abril (en las zonas más expuestas se alargaba hasta mayo-junio), propiciando que los valores registrados fueran homogéneos durante muchas jornadas seguidas, con un rango térmico entre -1,5°C y 1,5°C. Estos casos se produjeron en las estaciones situadas en roquedos (*rocks*) y matorrales (*grassland*) (Figura 4.1), sitios más expuestos a estas situaciones y localizados en zonas elevadas (Figura 4.2). Se trata del escenario real que soportan las plantas en estas zonas, por lo que estos registros no fueron eliminados. Los pocos casos restantes fueron examinados y descartados por ser sumamente sospechosos.

Respecto a los valores anómalos en las mínimas, aquellos por debajo de -10°C no fueron suprimidos ya que los datos procedían de estaciones situadas en sitios elevados, durante los meses de invierno y en días muy fríos (valores muy bajos en otras estaciones próximas). Sin embargo, se eliminaron valores mínimos por encima de 20°C cuando éstos se producían en los meses de invierno y no existía correlación temporal ni espacial con *iButton*® próximos. Por su parte, en las máximas tampoco se eliminaron valores por debajo de -3°C por producirse, nuevamente, en sitios altos y en meses fríos; pero se detectaron numerosos casos por encima de 40°C y de 50°C que fueron revisados y, en algunas ocasiones eliminados. En este sentido, se comprobó que los *iButton*® suelen experimentar valores muy elevados en los meses más cálidos (verano) y en zonas de matorrales y roquedos, expuestas a la radiación solar (Figura 4.3). Según el estudio de Ashcroft *et al.* (2012) realizado con *iButton*®, estos sensores suelen calentarse hasta alcanzar valores de 55°C en los días más cálidos, siendo de media unos 10°C superior a observatorios meteorológicos. Estas diferencias se explican por la mayor cercanía al suelo de los primeros respecto a los segundos; en nuestro caso entre 2 y 5 cm de altura.

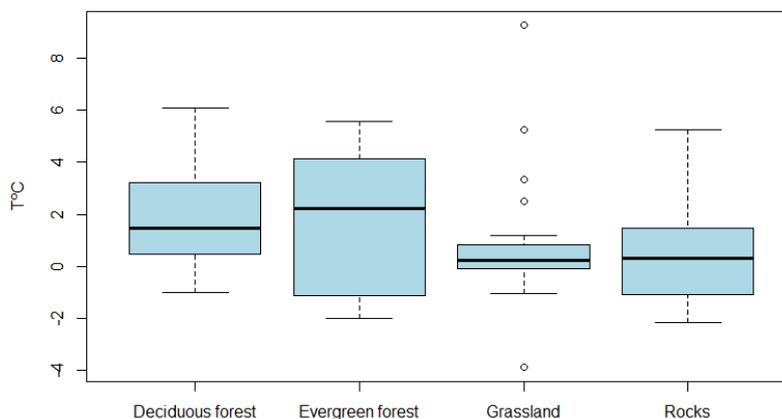
Tabla 4.1. Resumen de los valores registrados por los sensores en los 73 puntos de muestreo.

Datos (diarios)	Mínima	Máxima	Media	Percentil 5	Percentil 95	Desv. Est.
Temperaturas mínimas	-19°C	24°C	$4,35^{\circ}\text{C}$	-7°C	18°C	$0,89^{\circ}\text{C}$
Temperaturas máximas	-15°C	55°C	$12,73^{\circ}\text{C}$	5°C	$20,54^{\circ}\text{C}$	$2,01^{\circ}\text{C}$

4.1.2. Análisis de las temperaturas

Los datos diarios (Tabla 4.1) registraron un valor mínimo absoluto el 6 de febrero de 2015 de -19°C en la estación 97, situada en un pasto rocoso alpino a 2.662 m s.n.m., y la más próxima a Monte Perdido. La máxima absoluta se dio el 3 de agosto de 2017 en la estación 99 con 55°C , situada en un tomillar-romeral muy expuesto con pinos dispersos y manchas de suelo descubierto, ubicado en la entrada del valle de Añisclo. La máxima más baja se produjo en la estación 48 el 18 de enero de 2017, situada en el valle de Ordesa bajo bosque de salguerales y cascajos y en un periodo de temperaturas generalizadas muy bajas, pero más acusada en este sitio por inversión térmica. La mínima más elevada fue registrada por la estación 7 el 4 de agosto de 2017 con $22,5^{\circ}\text{C}$, en un pinar mixto en el extremo sur del valle de Añisclo.

Figura 4.1. Distribución de las temperaturas medias de febrero en el PNOMP según hábitat. Se observa una menor variabilidad en las zonas abiertas de pastos y matorrales (Grassland), producto del cubrimiento nival que produce temperaturas homogéneas y consecutivas durante varios días en invierno y primavera.



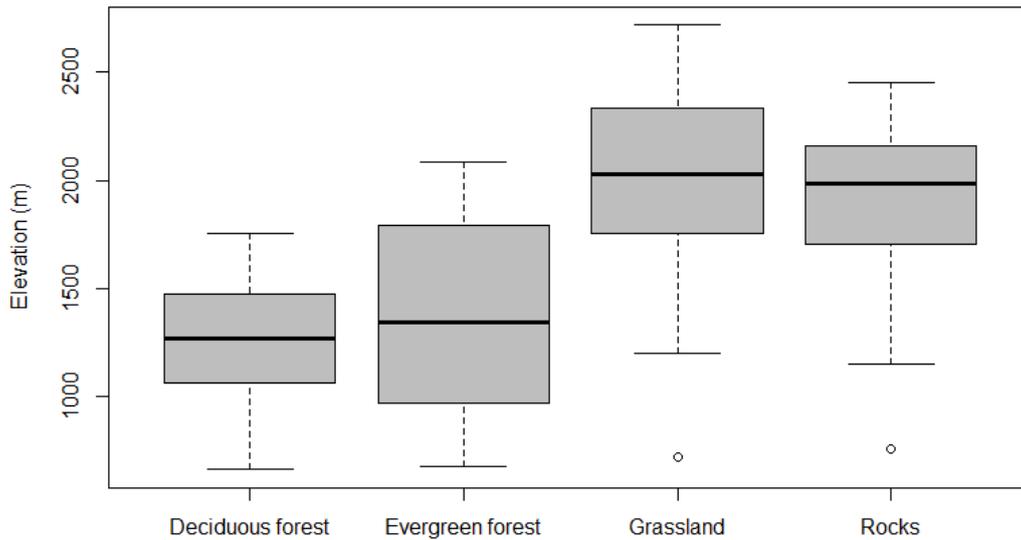


Figura 4.2. Rango altitudinal por tipo de hábitat. Las zonas de matorrales y roquedo se sitúan en zonas más elevadas y, por tanto, expuestas a la nieve.

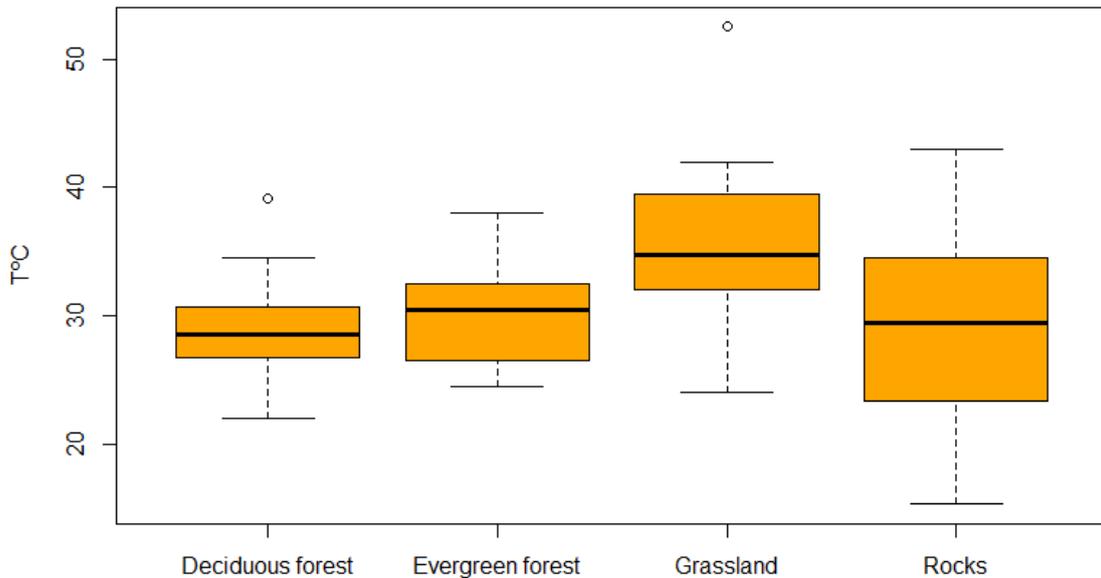


Figura 4.3. Percentil 95 de las temperaturas máximas diarias según el tipo de hábitat. Los hábitats con vegetación tipo pasto y matorral (Grassland) y los roquedos (Rocks) son los que presentan los valores más altos y una mayor amplitud térmica.

4.1.3. Comparación con otras fuentes de datos climáticos

La agrupación de los datos por meses permitió generar un año-tipo, y generar las variables dependientes para el modelo topoclimático y la identificación de refugios (Figura 4.4). Las temperaturas medias mínimas y máximas anuales y de verano e invierno se compararon con las obtenidas a partir de la base de datos STEAD del proyecto CLIM'PY para los mismos puntos de muestreo, mediante correlación *pairwise* (Tabla 4.2). La relación más significativa se produjo con las máximas anuales (correlación de Pearson: 0,6303) mientras que en invierno el efecto de la nieve dio como resultado la correlación más baja en las mínimas (0,3033).

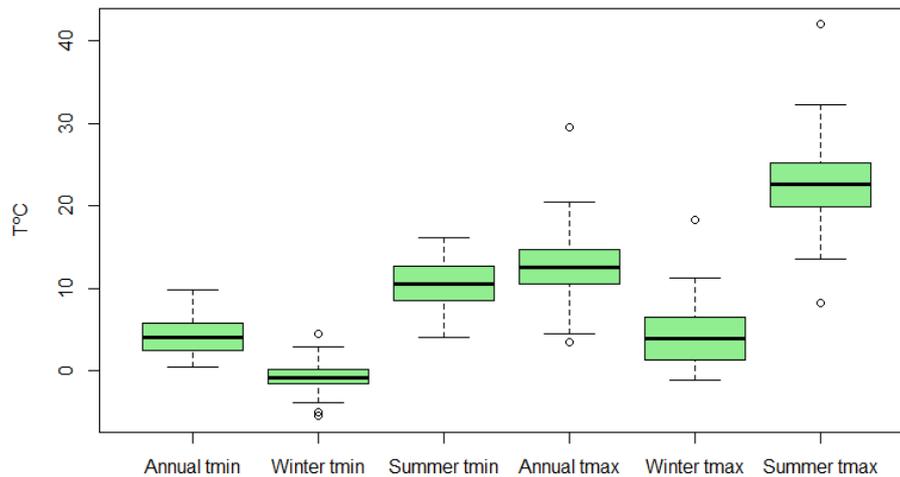


Figura 4.4. Rango de temperaturas de las variables dependientes de los modelos topoclimáticos para la detección de los refugios.

Tabla 4.2. Correlación *pairwise* entre sensores de campo y CLIM'PY.

	Tmin anual	Tmax anual	Tmin invierno	Tmin verano	Tmax invierno	Tmax verano
<i>iButton</i>® ~ CLIM'PY	0,5737	0,6303	0,3033	0,5336	0,5046	0,4620

Por otro lado, se compararon los resultados proporcionados por 6 sensores situados en la estación meteorológica del Refugio de Góriz y los de la propia estación durante la semana del 14 al 21 de agosto de 2019 (Figura 4.5). Los *iButton*® registraron valores más extremos en las mínimas y máximas diarias, siendo en estas últimas más acusadas especialmente en los sensores depositados a nivel de suelo. Se pudo advertir que los sensores emplazados a pocos cm del suelo son más proclives a calentarse y producir amplitudes diarias más rápidas y acusadas que los ubicados en aire. La estación meteorológica recogió valores mucho más homogéneos y algo más retardados que los sensores gracias a su mayor grado de protección. En esta prueba los sensores fueron protegidos de diferente forma (sin cobertura, con malla y con tela); los resultados indicaron que no hubo diferencias relevantes debido al tipo de protección ni entre los de aire ni entre los de suelo.

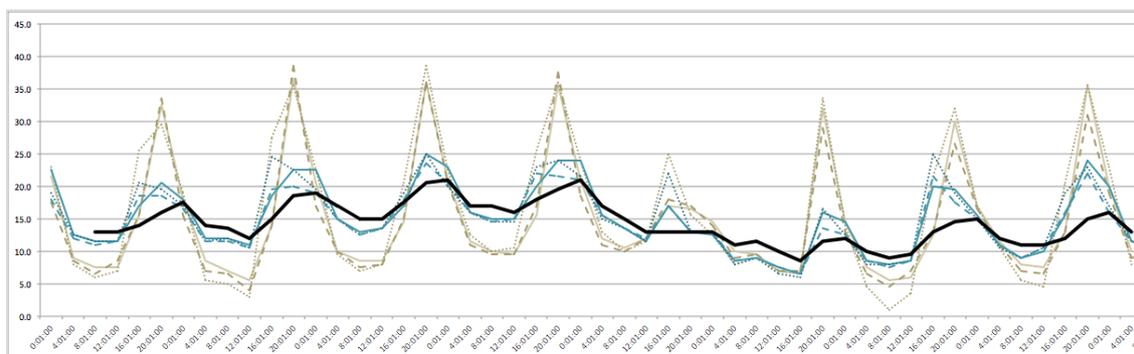


Figura 4.5. Valores registrados en el Refugio de Góriz durante la semana del 14 al 21 de agosto de 2019. En negro: estación meteorológica; en azul: 3 sensores en aire dispuestos a la misma altura que la estación de aire: 5 m; en marrón: 3 sensores en suelo dispuestos a 5 cm de altura bajo la estación. La línea continua se refiere a *iButton* sin protección, y las discontinuas a *iButtons* con protección de 2 mallas que permiten un mayor o menor paso de luz.

4.1.4. Análisis de los días con crecimiento vegetativo (GDD)

Los resultados para los tres años seleccionados mostraron que la estación 99, ubicada en la entrada sur de Añisclo, fue la que mayor número de crecimiento vegetativo (GDD) tuvo, con 1.058 días de 1.096 con valores de temperatura por encima de los 5°C. Otras estaciones próximas del mismo valle obtuvieron también valores GDD altos como la estación 1: 930 días; la estación 7: 905 días; la estación 9 (“A5”): 896 días; o la estación 10: 855 días. En este sentido, esta zona boscosa destacó por poseer temperaturas por encima de la media que se ven reflejadas en los altos valores del GDD. Por el contrario, la estación 53 obtuvo el menor valor GDD con 297 días seguido de la estación 65: 342 días, ambas en zonas de suelo desnudo. El tipo de hábitat determinó en buena medida estas diferencias, observándose una menor variabilidad y mayor número de GDD en bosques mientras que en matorrales y roquedos, zonas menos protegidas de la nieve, los valores GDD fueron, en general, más bajos y con mayor varianza (Figura 4.6).

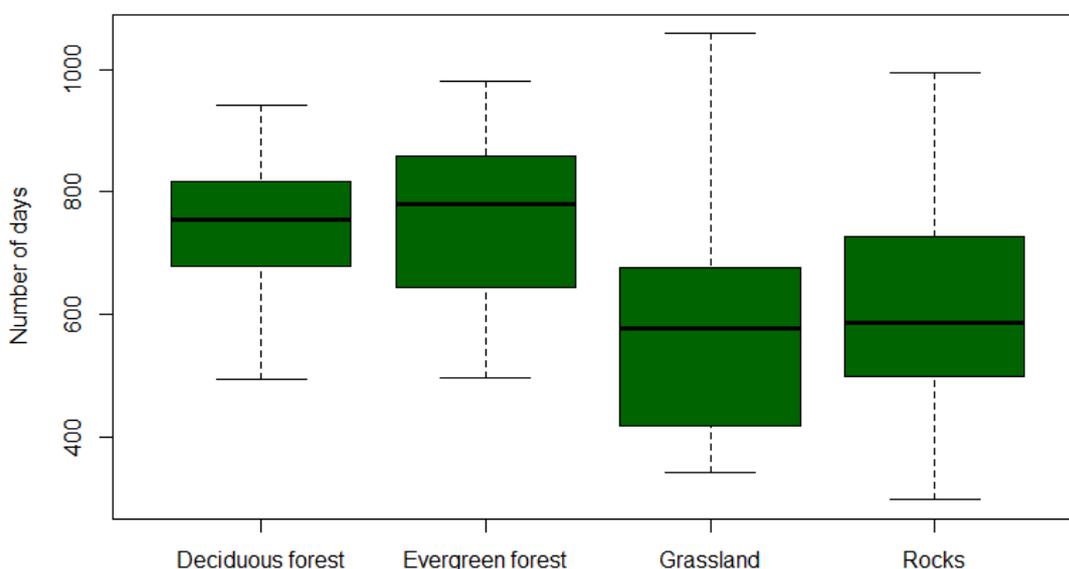


Figura 4.6. Número de días con crecimiento vegetativo (GDD) por tipo de hábitat.

4.2. Predictoras topográficas

Los análisis exploratorios identificaron correlaciones de Pearson significativas de las variables climáticas de los modelos con la altitud excepto en las mínimas de invierno ($cor = -0,3913$). En este escenario se observaron diferencias al distinguir por el tipo de hábitat (Figura 4.7) produciéndose una escasa correlación en matorrales debido al efecto mitigador del manto de nieve en las temperaturas. También se advirtió de una menor correlación con las máximas de verano ($cor = -0,4895$), especialmente en roquedos (Figura 4.8) dada su mayor exposición a la radiación solar y al calentamiento del suelo. Las mayores correlaciones se dieron con las mínimas anuales ($cor = -0,8264$) y estivales ($cor = -0,8525$).

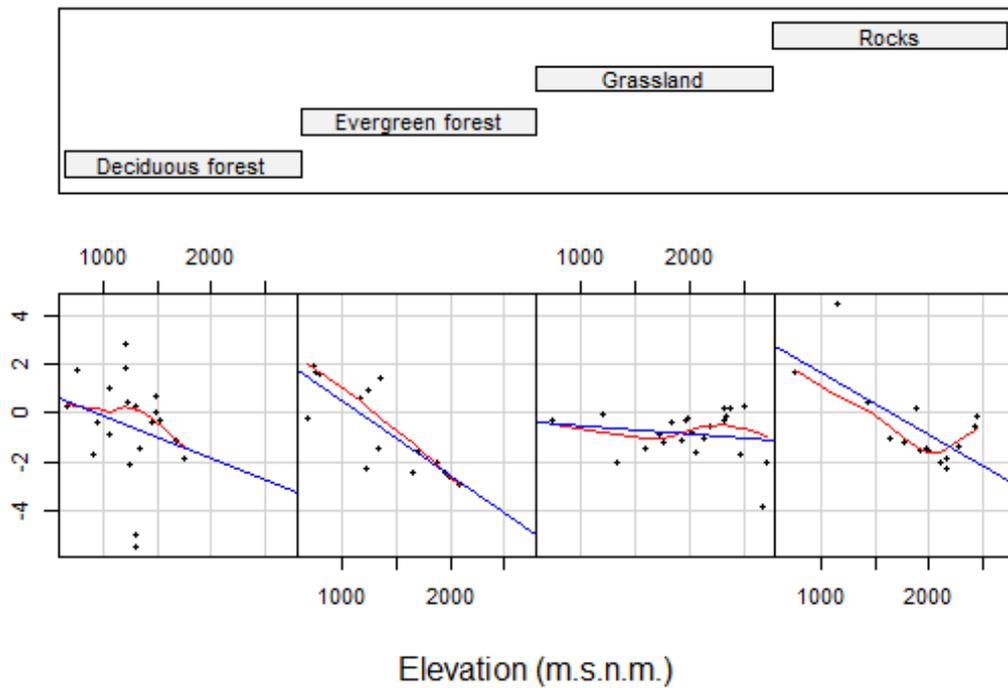


Figura 4.7. Correlación de las mínimas de invierno con la altitud según el tipo de hábitat. Se observa la falta de relación en el hábitat con vegetación abierta (Grassland) por el continuado efecto amortiguador de la nieve en las temperaturas.

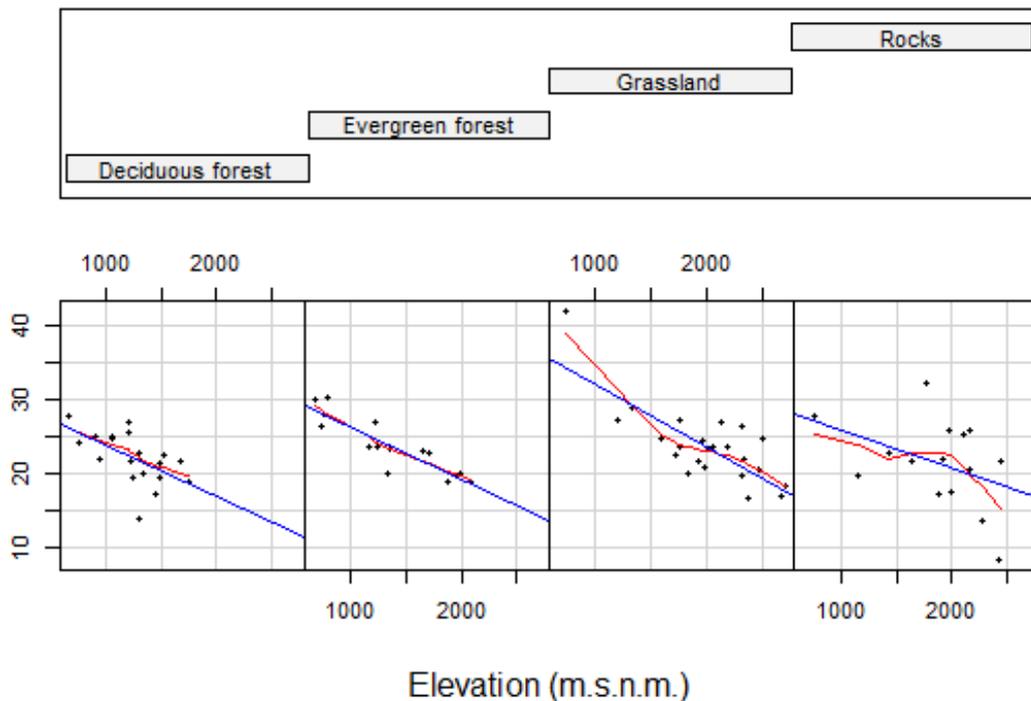


Figura 4.8. Correlación de las máximas de verano con la altitud según el tipo de hábitat. Se observa una menor relación en la clase de los roquedos (Rocks) probablemente porque sus variadas exposiciones resultan en valores más extremos de forma más independiente a la altitud: un fuerte calentamiento en las orientaciones S y por el contrario una mayor protección frente a los efectos de la radiación en las caras N.

4.3. Ajuste de modelos y validaciones

Los modelos topográficos mejoraron sustancialmente al resto de modelos más sencillos, siendo mayor su significación respecto a los no-topográficos en la máxima anual, la máxima invernal y el GDD. Como única excepción, las mínimas de invierno tuvieron un ajuste menos bajo en el modelo CHM, aunque las diferencias entre éste y el topográfico no fueron significativas según el análisis AIC realizado.

Las mínimas de invierno y las máximas de verano tuvieron los ajustes más bajos en el modelo topoclimático final ($R^2=0,2023$ y $R^2=0,3827$, respectivamente) mientras que los mejores ajustes se dieron con las mínimas de verano y las mínimas anuales ($R^2=0,7896$ y $R^2=0,7260$, respectivamente). Por su parte, el número de días de crecimiento vegetal (GDD) alcanzó un ajuste máximo de $R^2=0,8406$ siendo la variable climática de mejor ajuste, aunque no formó parte del cálculo del RI.

Tabla 4.3. Grado de ajuste de modelos (valor de R^2).

Factor de refugio	Variable climática	Modelo no-topográfico	Modelo CHM	Modelo topográfico	Modelo final (por pasos)
Temperaturas extremas	Tmin anual	0,6785	0,7014	0,7260	0,7297
	Tmax anual	0,4489	0,4672	0,6431	0,6417
Amplitud térmica estacional e intra-anual	Tmin invierno	0,1412	0,2023	0,1886	0,2023
	Tmin verano	0,7230	0,7315	0,7896	0,7874
	Tmax invierno	0,4490	0,4550	0,6297	0,6308
	Tmax verano	0,2289	0,2677	0,3827	0,3827
	GDD	0,7424	0,7433	0,8406	0,8428

Las comprobaciones de los registros de temperatura para la validación final de los modelos mostraron una amplia similitud con los datos de EuroLST ($p < 0,05$), basado en la temperatura del suelo a partir de información MODIS, para las temperaturas medias anuales (Figura 4.9) y de verano (Figura 4.10). En invierno se observó que el efecto de cubrimiento nival produjo medias superiores en los *iButton*® respecto a los registrados por EuroLST (Figura 4.11), que no es capaz de estimar la temperatura bajo nieve. Los modelos basados en datos climáticos fueron similares entre sí pero diferentes a EuroLST e *iButton*® (“Topoclimate”) ya que sus registros proceden de estaciones meteorológicas situadas a mayor altura.

Figura 4.9. Comparación múltiple de temperaturas medias anuales (escenario BIO-01) según datos climáticos y temperatura de suelo obtenidas por sensor remoto y en este estudio (TOPOCLIMATE). De izquierda a derecha: WorldClim1, WorldClim2, CHELSA, PDCA, EuroLST, TOPOCLIMATE. El modelo EuroLST es que mejor se ajusta a los datos de los *iButton*® (“Topoclimate”), no existiendo diferencias significativas según análisis Kruskal-Wallis ($p>0,05$).

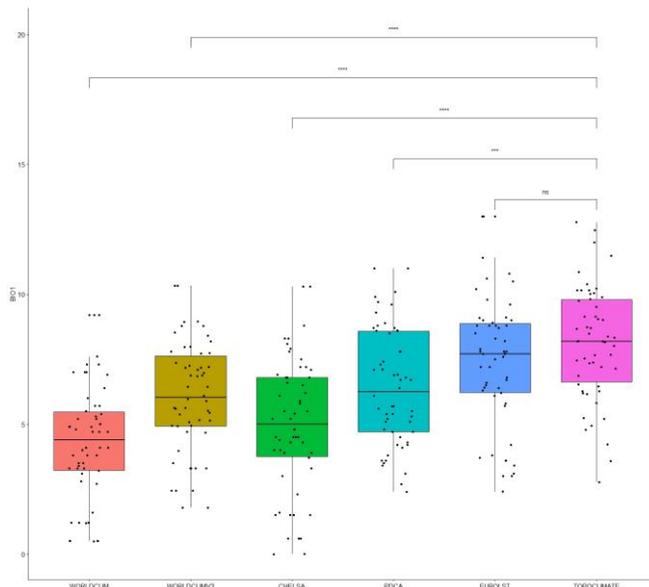


Figura 4.10. Comparación de temperaturas medias de verano (escenario BIO-10) con datos climáticos y temperatura de suelo. De izquierda a derecha: WorldClim1, WorldClim2, CHELSA, PDCA, EuroLST, TOPOCLIMATE. El modelo EuroLST es que mejor se ajusta a los datos de los *iButton*® (“Topoclimate”), no existiendo diferencias significativas (Kruskal-Wallis, $p>0,05$).

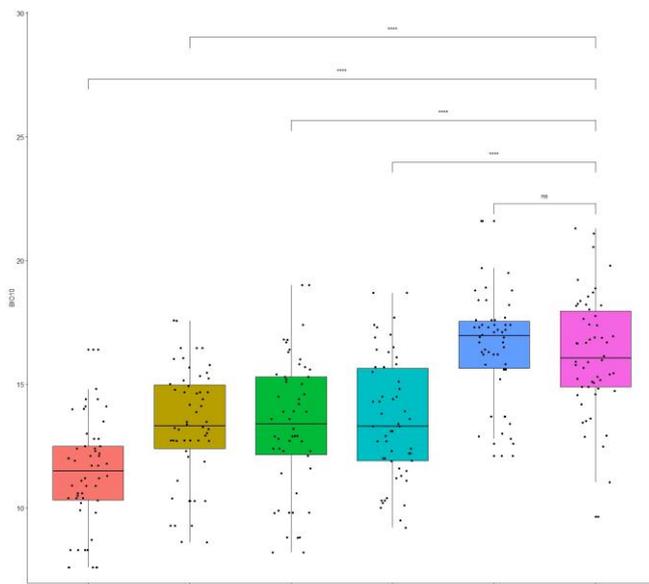
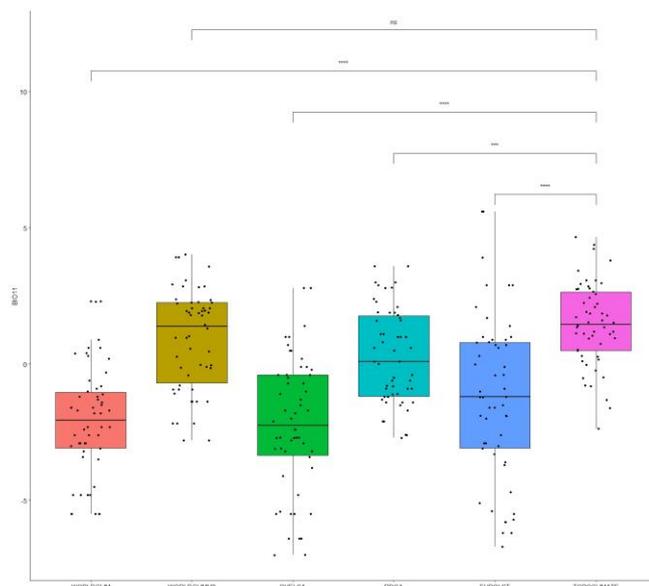


Figura 4.11. Comparación de temperaturas medias de invierno (escenario BIO-11) con datos climáticos y temperatura de suelo y efecto del cubrimiento nival en el modelo de los *iButton*® (“Topoclimate”). De izquierda a derecha: WorldClim1, WorldClim2, CHELSA, PDCA, EuroLST, TOPOCLIMATE. En este escenario aparecen diferencias significativas con EuroLST (Kruskal-Wallis, $p<0,05$) debido al manto nival, de forma que la temperatura en superficie es percibida de distinta forma en superficie y bajo nieve.



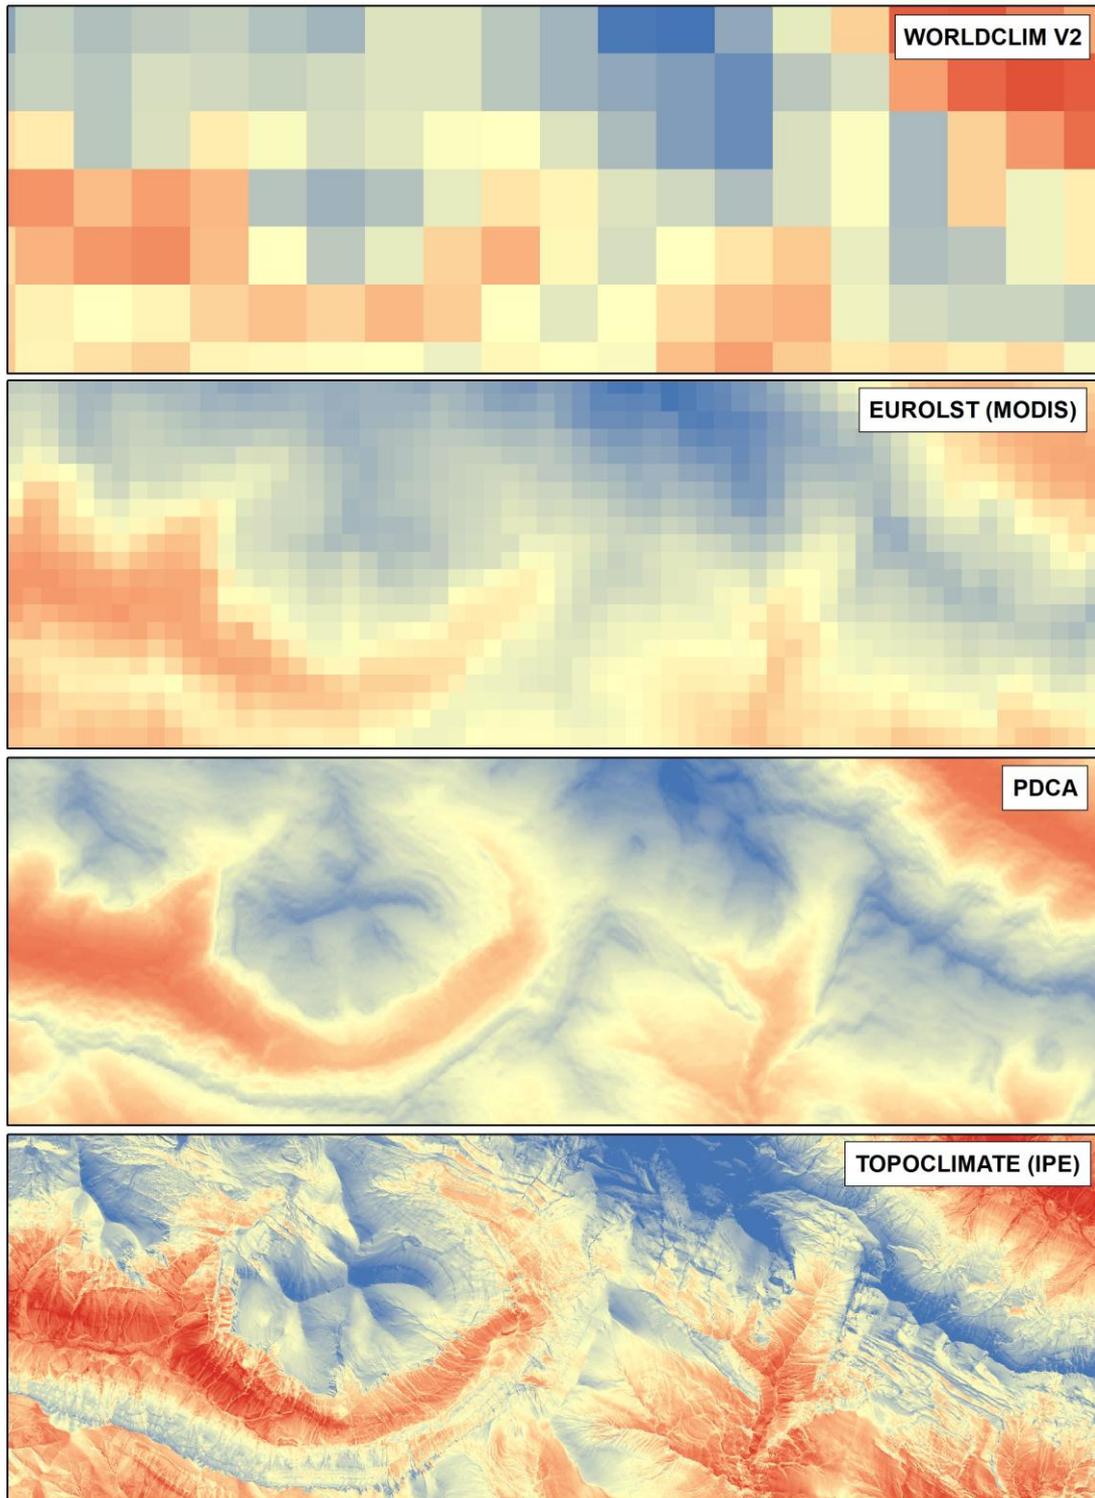


Figura 4.12. Detalle de las diferencias en la resolución en función de la base de datos climática para una misma zona de estudio (valle de Ordesa y zona de Góriz): i) WorldClim2: 1 km; EuroLST (MODIS): 250 m; PDCA: 30 m; Topoclimate: 5 m.

4.4. Modelos topoclimáticos

4.4.1. Temperaturas extremas

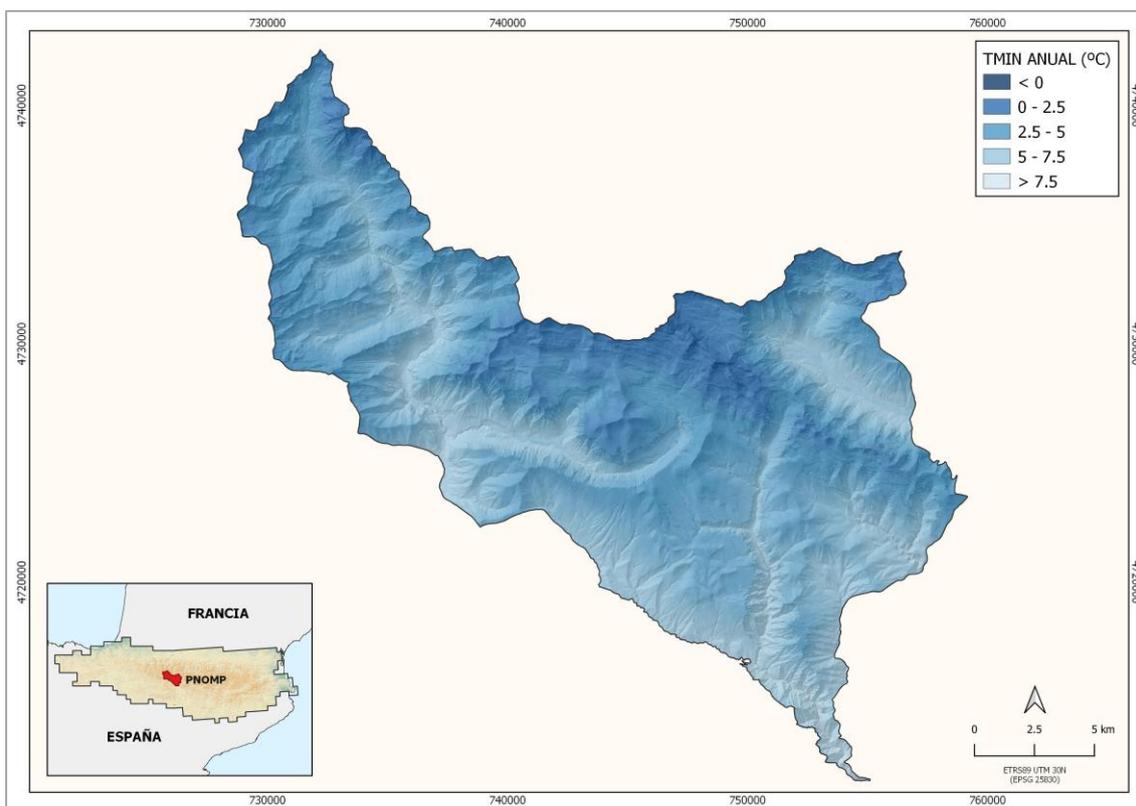


Figura 4.13. Cartografía de las temperaturas mínimas anuales (°C).

Las temperaturas mínimas del año fueron espacializadas con el modelo topoclimático, cuyo ajuste fue de $R^2 = 0,7297$ (Figura 4.13). Las mejores predictoras fueron la altitud, el CHM, la orientación y el TWI. Los valores más bajos se localizaron en las zonas elevadas (macizo de Monte Perdido) y laderas de umbría mientras que las más elevadas se concentraron en la entrada meridional de depresiones topográficas como los cañones de Añisclo y Escuaín. Se observaron diferencias térmicas sustanciales según la orientación de la ladera y por gradiente altitudinal. Los paredones kársticos de las sierras del valle de Ordesa mostraron mínimas algo más bajas que su alrededor.

Por su parte, las temperaturas máximas del año fueron espacializadas con un ajuste $R^2 = 0,6431$ (Figura 4.14). Las mejores predictoras fueron la altitud, el PISR, la orientación y el TWI. Los valores más bajos se localizaron nuevamente en las zonas más elevadas, especialmente en Monte Perdido, mientras que los registros más altos se localizaron en los principales valles (Añisclo, entrada de Ordesa y Pineta) y en zonas de solana, existiendo mucha más diferencia en este caso según la orientación de la ladera.

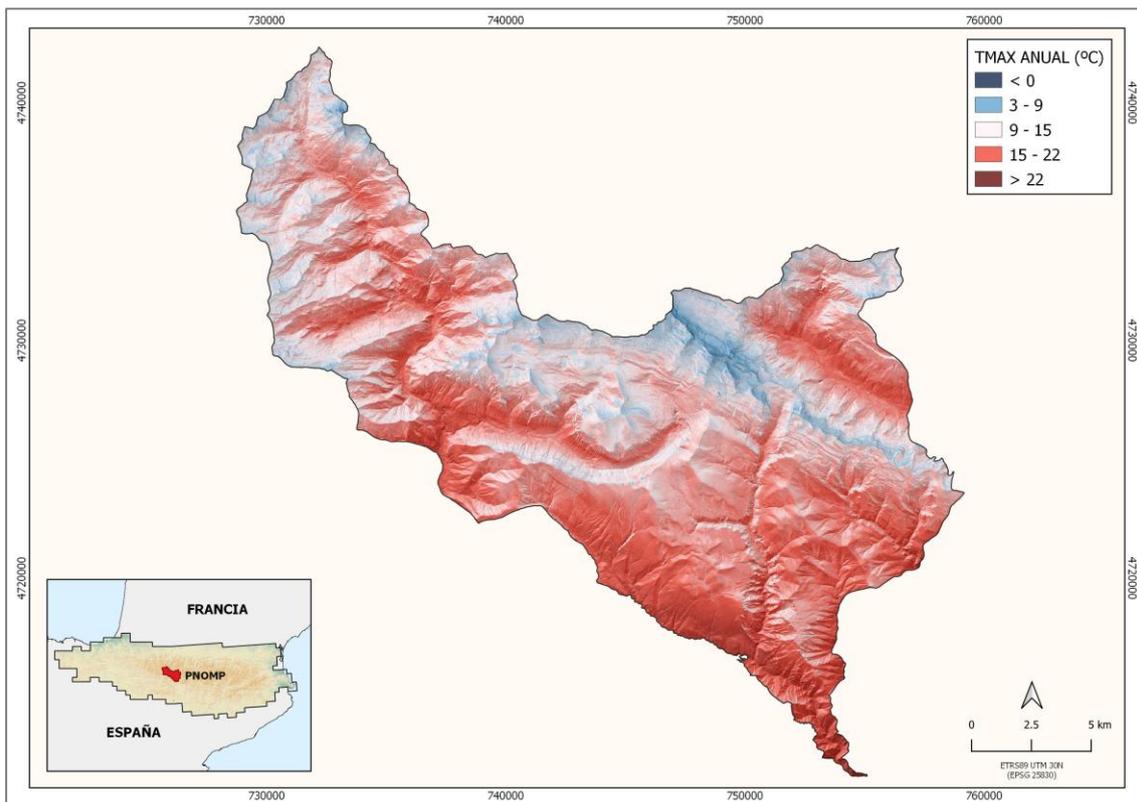


Figura 4.14. Cartografía de las temperaturas máximas anuales (°C).

4.4.2. Variabilidad climática

La variabilidad térmica fue espacializada con un nivel de ajuste menor que las temperaturas extremas, debido principalmente a las mínimas de invierno (cubrimiento nival) y las máximas de verano (insolación).

La variabilidad en las temperaturas mínimas se obtuvo a partir de la diferencia entre las mínimas de verano (ajuste del modelo: $R^2 = 0,7874$) y las de invierno ($R^2 = 0,2023$) (Figura 4.15). Las zonas más estables se localizaron en las zonas elevadas y con ausencia de vegetación (matorrales y roquedos) motivado por la inercia que impone el cubrimiento nival invernal y por las bajas temperaturas mínimas estivales. Esta estabilidad también pudo observarse en las laderas umbrosas de Ordesa y en el fondo del valle de Pineta cercano al río Cinca. En la parte baja del valle de Bujaruelo y gran parte de Ordesa la amplitud térmica fue mayor, excepto en algunos puntos de este último, así como en las laderas de solana, sobre todo en Pineta y Ordesa. En ambos casos, se trata de zonas boscosas (CHM alto) y poco elevadas que no experimentan cubrimiento nival en invierno y se encuentran expuestas a las inversiones térmicas. En el caso de Ordesa, las zonas más elevadas y los paredones que miran al sur mostraron una menor variabilidad.

La variabilidad en las temperaturas máximas se obtuvo a partir de la diferencia entre las máximas de verano (ajuste del modelo: $R^2 = 0,3827$) y las de invierno ($R^2 = 0,6297$) (Figura 4.16). Al contrario que en el escenario anterior, los fondos de valle y las laderas de solana mostraron una menor amplitud térmica, zonas con altos niveles de CHM y menos expuestas a la radiación solar. Algunos sitios elevados mostraron también cierta estabilidad (NE de Pineta, sectores de Escuaín o puntos concretos en Bujaruelo). La

variabilidad fue mayor en laderas de umbría, especialmente en zonas altas de matorrales y roquedos expuestas a una mayor radiación solar incidente.

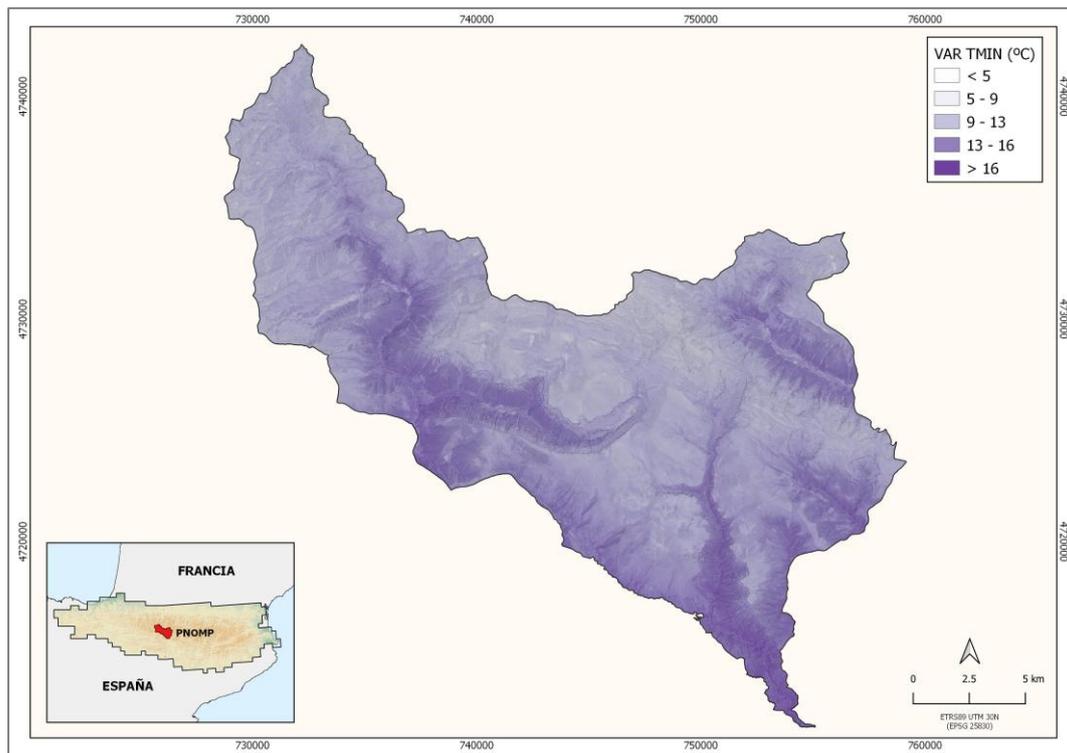


Figura 4.15. Cartografía de la variabilidad climática de las temperaturas mínimas (°C).

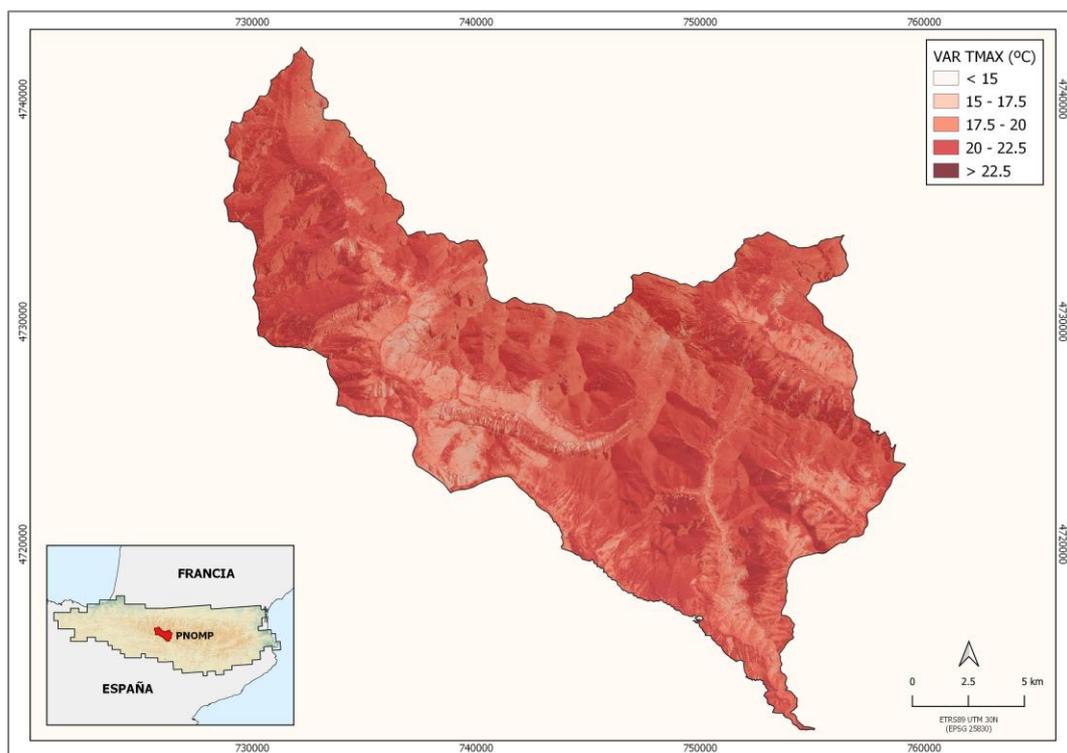


Figura 4.16. Cartografía de la variabilidad climática de las temperaturas máximas (°C).

4.4.3. Aislamiento regional

El aislamiento regional fue espacializado a partir de las mínimas de invierno para el escenario frío, y de las máximas de verano para el escenario cálido. Se calculó como la diferencia entre el valor de cada punto y el valor promedio de la totalidad de puntos en el PNOMP. Estos modelos permitieron resaltar las zonas que poseen un clima más distintivo respecto a los de su alrededor.

En las temperaturas mínimas (Figura 4.17), las zonas con temperaturas más frías respecto a la región ($T_{min} < 0^{\circ}\text{C}$) se concentraron en los macizos elevados de Monte Perdido y Pineta, en las cimas de Cotatuero y Sierra de las Cutas (Ordesa), laderas de umbría y zonas de menor cubrimiento forestal. Los lugares más cálidos ($T_{min} > 0^{\circ}\text{C}$) se localizaron en el fondo del valle de Pineta, en las laderas de solana y el sector sur del valle de Añisclo, entrada del valle de Ordesa y valles laterales de Bujaruelo; zonas con mayor insolación en invierno y libre del efecto de las nieves.

Respecto a las temperaturas máximas (Figura 4.18), los sectores menos cálidos ($T_{max} < 0^{\circ}\text{C}$) se localizaron en las zonas más elevadas de Monte Perdido y la sierra norte del valle del Pineta, así como en la cara norte de las laderas de Ordesa, es decir, debido a la elevación y la orientación respectivamente. Por su parte, las zonas más cálidas ($T_{max} > 0^{\circ}\text{C}$) se concentraron en el sector sur del PNOMP, en las solanas de Bujaruelo y Pineta, el fondo del cañón de Añisclo y en los paredones de Ordesa con orientación sur, pendiente casi vertical y sin cubimiento arbóreo.

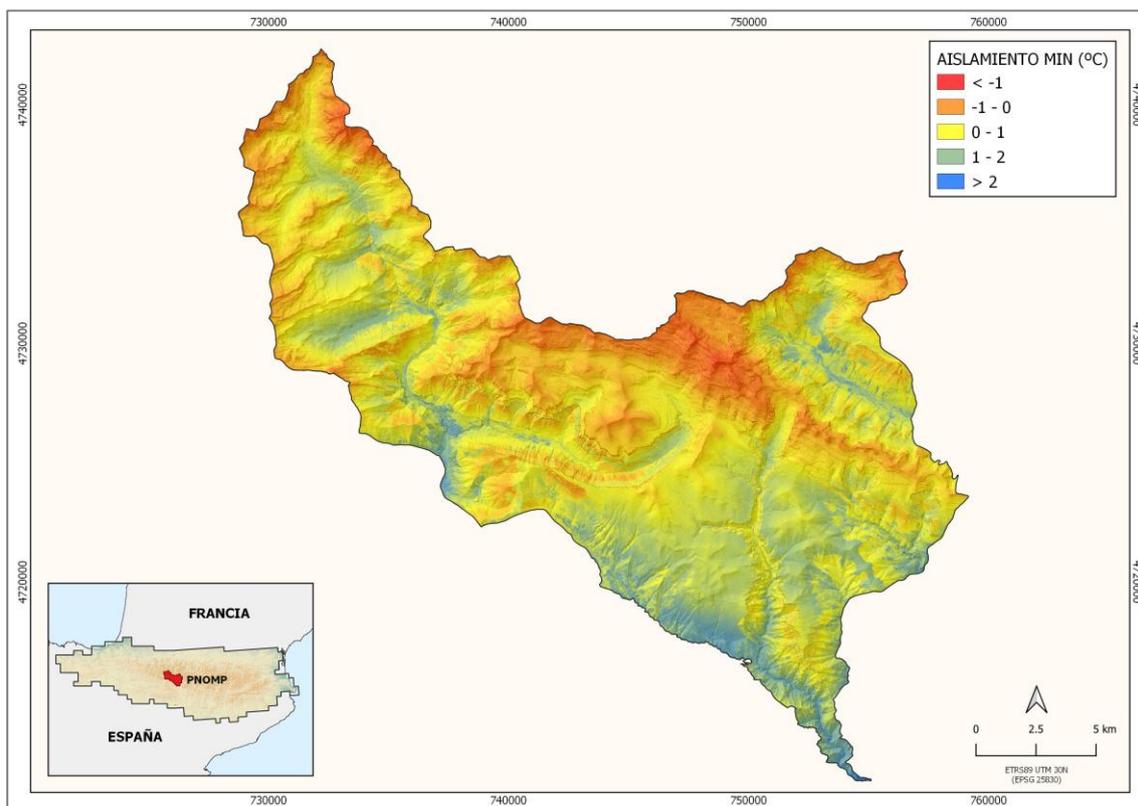


Figura 4.17. Cartografía del “aislamiento” de cada punto respecto al conjunto de valores del Parque para temperaturas mínimas ($^{\circ}\text{C}$).

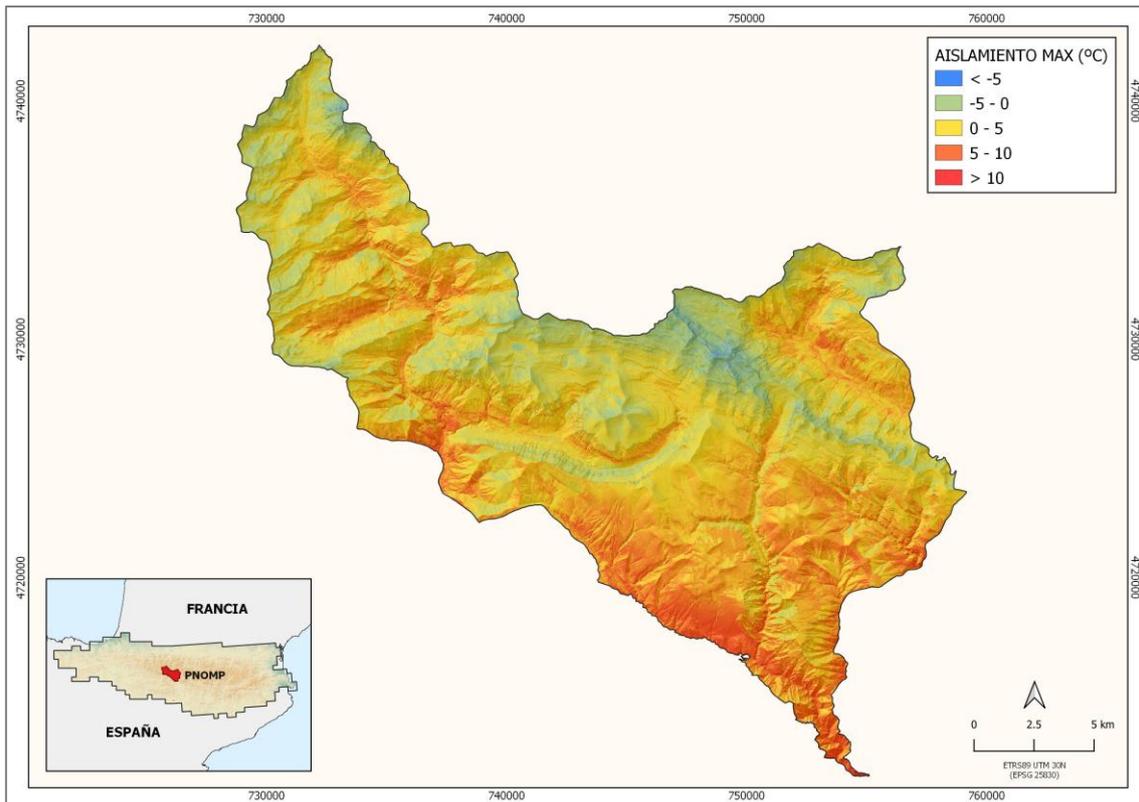


Figura 4.18. Cartografía del “aislamiento” de cada punto respecto al conjunto de valores del Parque para las temperaturas máximas (°C).

4.4.4. Crecimiento vegetativo diario (GDD)

El crecimiento vegetativo diario fue espacializado a partir del número de *Growing Degree Days* (GDD) con un ajuste $R^2=0,8428$ siendo las mejores predictoras la altitud, el PISR y el TWI. Para la cartografía final se promedió el número total de días (calculado para 3 años) por un año-tipo (Figura 4.19). Las zonas con los valores más elevados de GDD (más de 300 días anuales) se localizaron en la entrada del valle de Añisclo, la zona sur de Bujaruelo y Ordesa y sectores concretos de Escuaín y Pineta; en definitiva, depresiones topográficas con escasa altitud y hábitats dominados por vegetación arbórea. Por el contrario, los sectores elevados de Monte Perdido y Pineta obtuvieron los valores GDD más bajos, con menos de 100 días al año de crecimiento vegetal. Los resultados son muy comparables a los mapas de las mínimas y las máximas anuales y permiten observar las zonas más propensas a estar cubiertas por nieves, que son aquéllas con los valores GDD anuales más bajos. Por el contrario, en los lugares con GDD elevados se infiere que el cubrimiento nival es escaso o nulo.

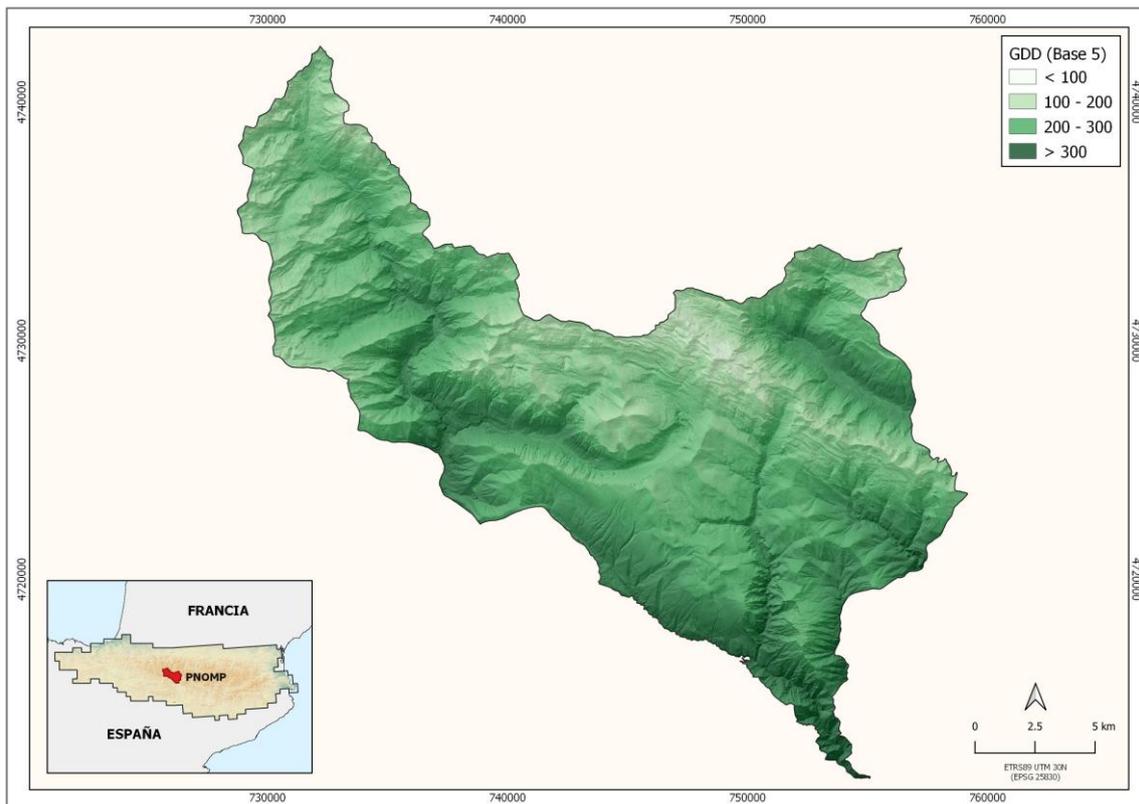


Figura 4.19. Cartografía del nº de días anuales con crecimiento vegetativo o *Growing Degree Day* (GDD base 5: T°C media diaria $\geq 5^\circ\text{C}$).

4.5. Refugios climáticos y validación biológica

Para un escenario cálido o interglacial (Figura 4.20) los refugios fríos que facilitarían la persistencia de plantas de afinidades alpinas y boreoalpinas se localizaron principalmente en el macizo de Monte Perdido, ladera sur de Ordesa (sierra de las Cutas), sectores elevados y laderas umbrosas de Bujaruelo y ladera sur del valle de Pineta. En el valle de Añisclo, extremadamente rugoso, estos refugios aparecieron de manera localizada en laderas elevadas y escarpadas de orientación N-NW y SE, pero también en el fondo de valle en su tramo medio-alto. También constituyeron refugios fríos los paredones kársticos de solana de Ordesa, que habían mostrado en las temperaturas mínimas poca variabilidad climática y valores por debajo del promedio regional. En general, las áreas de refugios más extensas aparecen en la mitad septentrional del PNOMP, mientras que en el sur predomina una distribución más parcheada y concentrada.

Para un escenario frío o periodo glacial (Figura 4.21) los refugios cálidos tuvieron una menor presencia espacial que los refugios fríos. Se localizaron principalmente en los sectores meridionales del PNOMP, expuestos a una mayor radiación solar y menor descenso térmico en invierno como las sierras de solana del sur y la totalidad de los sectores más bajo del valle de Añisclo; en zonas altas con escasa vegetación, como sectores de Bujaruelo y la amplia zona sur cercana a Añisclo; y en lugares con escasas o nulas inversiones térmicas, como determinadas zonas de Pineta y las laderas de solana poco elevadas de Ordesa y Pineta.

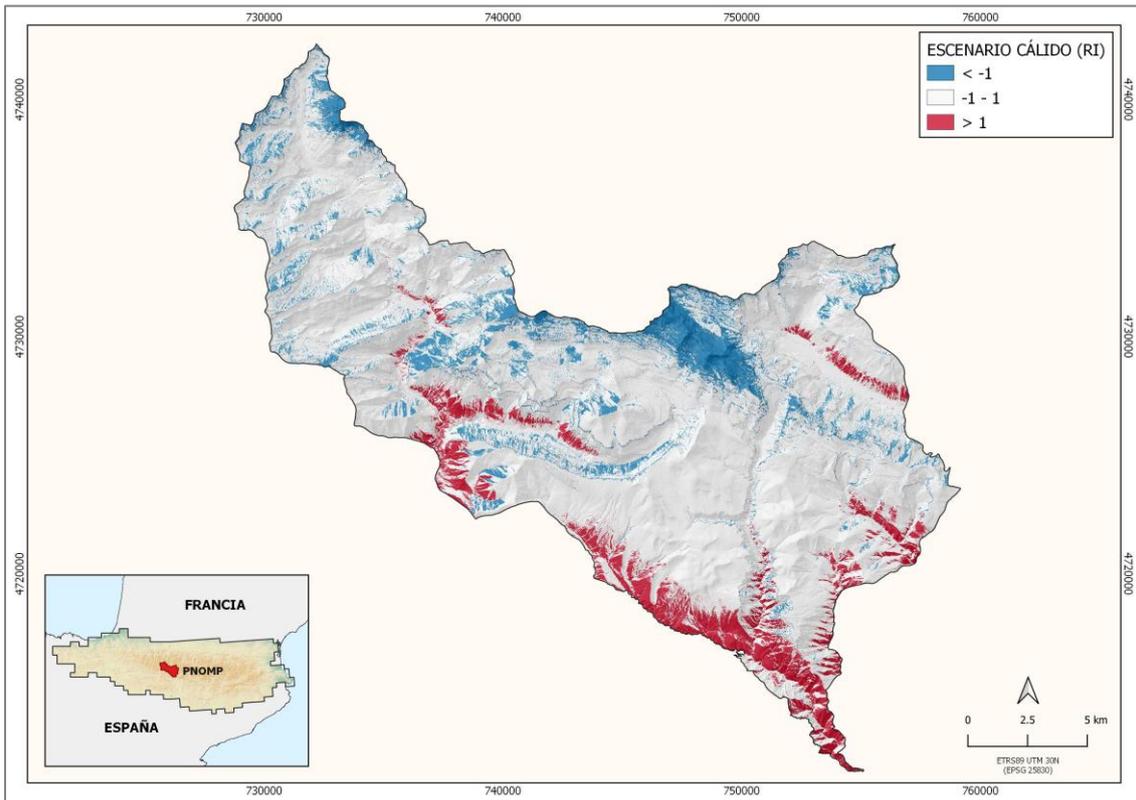


Figura 4.20. Cartografía de los refugios climáticos fríos (RI < -1) y cálidos (RI > 1) del PNOMP para un escenario cálido.

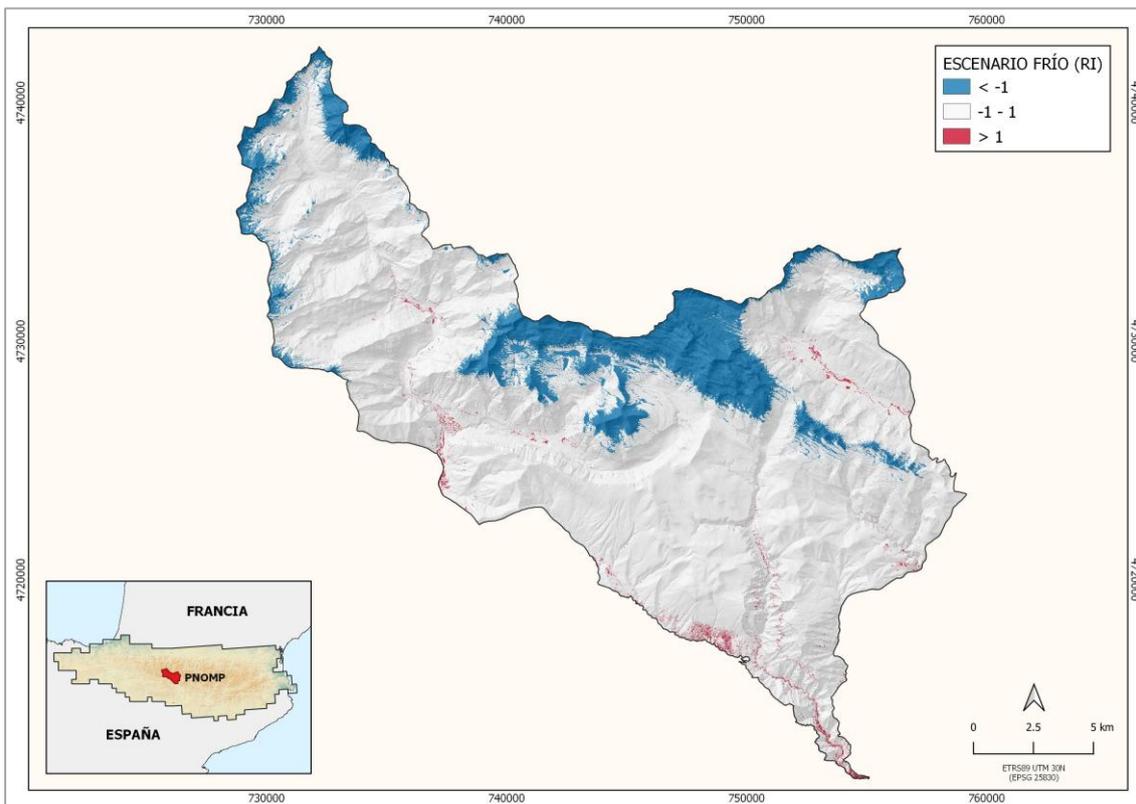


Figura 4.21. Cartografía de los refugios climáticos fríos (RI < -1) y cálidos (RI > 1) del PNOMP para un escenario frío.

Los dos escenarios fueron combinados para mostrar en una única cartografía los refugios fríos y los refugios cálidos del PNOMP (Figura 4.22) a partir del Índice de Refugio Combinado.

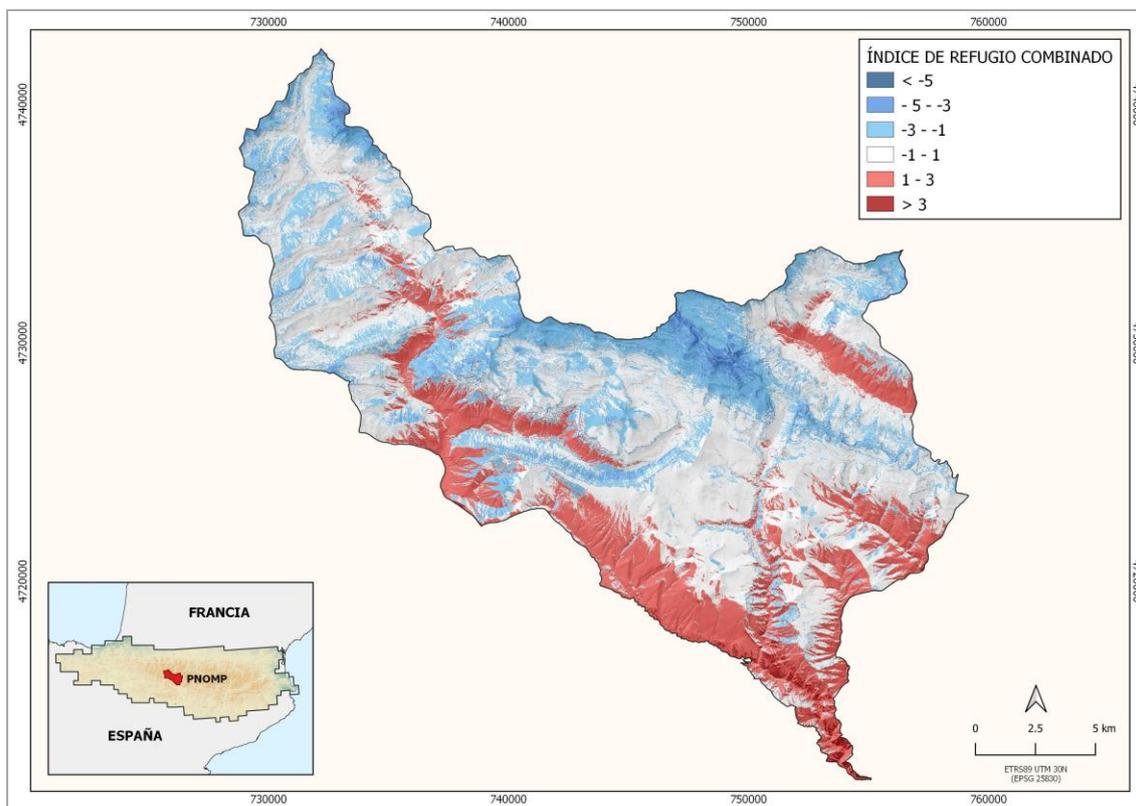


Figura 4.22. Cartografía del Índice de Refugio Combinado que muestra los refugios climáticos fríos ($RI < 1$) y cálidos ($RI > 1$) del PNOMP para cualquier escenario climático.

El análisis de correlación entre el RI combinado de las UTM y el porcentaje de plantas de afinidades cálidas o frías reveló una asociación muy significativa entre estas dos variables, positiva en el caso de refugios cálidos (mayores valores positivos de RI se relacionan con una mayor proporción de plantas cálidas) y negativa en el caso de los refugios fríos (menores valores de RI se relacionan con una mayor proporción de plantas alpinas y boreoalpinas). Estos resultados se vieron apoyados con el modelo GLM, que determinó que esta relación no se debe (exclusivamente) al componente de la altitud, es decir, que las plantas cálidas son proporcionalmente más abundantes en las zonas bajas y las frías en las zonas altas. El RI combinado contiene información más explicativa que la que proporciona la altitud, ya que en el caso de las plantas cálidas es el que tiene un efecto significativo sobre su mayor proporción en los inventarios ($p=0,029$), a diferencia de la altitud ($p=0,323$) (Figura 4.23). Esto se debe también al hecho de que muchas plantas mediterráneas pueden encontrarse a elevadas altitudes en las vertientes S del Pirineo, especialmente en roquedos con fuerte insolación. En el caso de las plantas frías ambas variables (altitud: $p=0.002$, RI combinado: $p=0.0005$) resultaron ser altamente significativas para explicar la proporción en los inventarios florísticos (Figura 4.24).

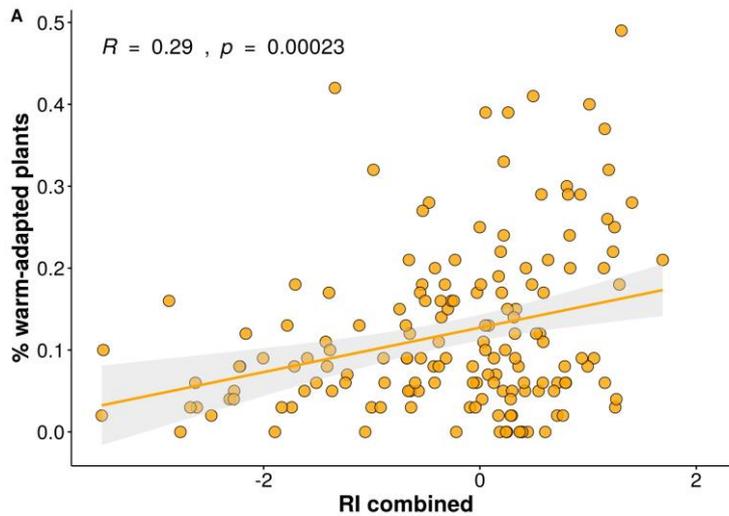


Figura 4.23. Coeficiente de correlación de Pearson entre el *Refugia Index* combinado de cada UTM del PNOMP donde existen inventarios florísticos, y la proporción de plantas adaptadas al calor.

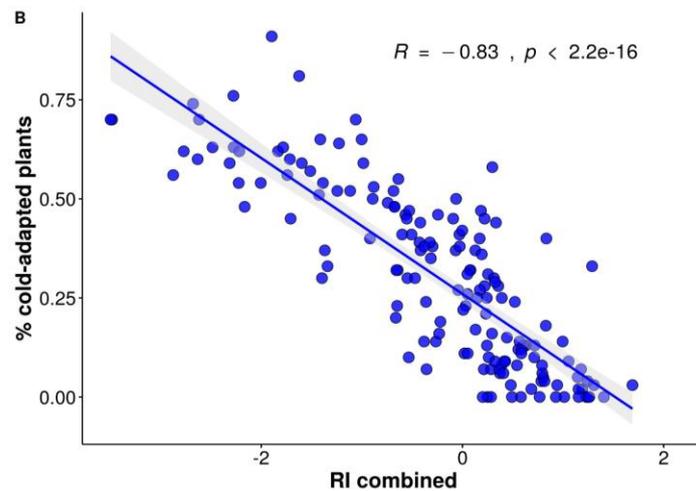


Figura 4.24. Coeficiente de correlación de Pearson entre el *Refugia Index* combinado de cada UTM del PNOMP donde existen inventarios florísticos, y la proporción de plantas adaptadas al frío.

5. Discusión

En el contexto de cambio climático en el que nos encontramos, y cuando ya se habla de la “sexta extinción” por la acelerada pérdida de biodiversidad constatada en las últimas décadas [Pimm *et al.*, 2014; Kolbert, 2014] muchas de las especies de lenta capacidad de migración sólo tendrán la posibilidad de persistir si resisten en refugios climáticos, gracias al amortiguamiento de temperaturas extremas que define estos ambientes. Para poder predecir qué fracción de la biodiversidad dependerá de refugios climáticos es necesario, en primer lugar, averiguar dónde se encuentran. Este estudio ha permitido identificar refugios tanto para especies de plantas cálidas como frías en uno de los lugares más biodiversos y complejos del Pirineo, a partir de la generación de modelos topoclimáticos a una alta resolución espacial (5 m), y usando sensores de campo que pudieron ser validados por los datos que ofrece EuroLST basado en el sensor MODIS.

5.1. Modelo topoclimático y *Refugia Index*

El primer resultado metodológico obtenido ha sido la validación de los registros de los sensores utilizados. Los valores de temperatura que han recogido sobre el suelo han sido sensiblemente mayores que los datos basados en aire y en estaciones convencionales como las de AEMET, donde se amortiguan los extremos climáticos. Por tanto, las plantas soportan contrastes térmicos que las estaciones meteorológicas no registran dada su orientación hacia el clima regional y la disposición de sus sensores en zonas abiertas y en altura. En este sentido, aunque el uso de *iButton*® ha sido satisfactorio en otros trabajos similares [Ashcroft & Gollan, 2012; Ashcroft *et al.*, 2012; Gubler *et al.*, 2018], este estudio se ha visto notablemente respaldado por la buena correlación existente con EuroLST, justificando el uso de estos mini-sensores como *proxies* de las temperaturas que experimentan las plantas y que marcan su nicho térmico.

La disposición de los sensores utilizados junto a los organismos vivos registra los valores verdaderamente relevantes para su fisiología, y ha permitido descifrar claramente, en el caso de las temperaturas mínimas invernales, que el efecto de la nieve en zonas elevadas de pasto, matorral y roquedo modifica las temperaturas que se esperarían para estos lugares por su altitud. Los resultados mostraron una escasa relación con la altitud en este escenario (la variable que mejor correlación obtuvo con las variables climáticas) especialmente en los hábitats de pastos y matorrales y, en menor medida, roquedos. La realización de análisis considerando el dosel vegetal y el tipo de hábitat por separado ha ayudado a comprender los resultados finales y el ajuste del modelo, un efecto que, de nuevo, no existe cuando se trabaja con estaciones meteorológicas. Bajo el manto de nieve los registros de los sensores oscilaron en el estrecho rango comprendido entre -1,5°C y 1,5°C, cuando por encima de ellos las condiciones climáticas eran más extremas. Esto pudo confirmarse al observar los datos de EuroLST en invierno (BIO-11) siendo el único escenario en la que hubo diferencias con los registros de los *iButton*®. Este efecto *iglú* es el que previene a los organismos de sufrir las bajas temperaturas del exterior y lo que les permite persistir en estas áreas sin sufrir los dañinos efectos de la congelación. Por tanto, los registros de los sensores fueron correctos para el propósito del estudio. No obstante, para poder modelizar adecuadamente este escenario sería preciso obtener variables que recogieran el factor de alteración térmico que la nieve produce bajo su manto respecto a la superficie.

En verano las temperaturas son más altas y la radiación solar incidente es mayor. Además, el suelo tiende a calentarse por el día y enfriarse por la noche más y de manera más veloz. Esta situación fue captada por los sensores, tal y como mostraron los que a efecto comparativo se colocaron en la estación meteorológica de Góriz: los *iButton*® respondieron más rápido y de manera más intensa al aumento de las temperaturas. Además, el aumento del contraste fue progresivo en función de la cercanía al suelo. En otros estudios ya se advirtió de esta circunstancia [Ashcroft & Gollan, 2012]; por ello, no se pueden eliminar automáticamente valores sospechosos tales como registros elevados. Este carácter extremo de las máximas se tradujo en que las variables independientes no fueron capaces de predecir bien los valores observados y, por tanto, un bajo nivel de ajuste del modelo para las medias de las mínimas de invierno.

En términos generales, los resultados de este trabajo resaltan la evidente mejora que supone la inclusión de variables topográficas para modelizar el microclima en espacios montañosos. Los modelos ensayados mejoraron su ajuste al introducir estas variables de

alta resolución como predictoras además de la altitud, existiendo diferencias significativas en todos los casos, mejora que también se puso de manifiesto en Meineri & Hylander, (2017). Los escasos modelos topoclimáticos publicados hasta la fecha se han basado en temperaturas extremas (mínimas, máximas o percentiles) [Ashcroft *et al.*, 2012; Ashcroft & Gollan, 2012; Niskanen *et al.*, 2016; Meineri & Hylander, 2017; Gubler *et al.*, 2018; Suggitt *et al.*, 2018] pero también de valores promedios [Meineri & Hylander, 2017; Gubler *et al.*, 2018].

Con frecuencia se ha utilizado la temperatura media para definir el nicho térmico de los organismos y realizar modelos predictivos sobre sus probabilidades de supervivencia. Sin embargo, de las 90 posibles formas que Körner & Hiltbrunner (2018) muestran para caracterizar las temperaturas que experimenta un ser vivo, sólo unas pocas son realmente importantes, como las temperaturas extremas por ser las que limitan su fisiología y les permiten persistir en un lugar. En nuestro caso, para el cálculo del RI se usaron temperaturas extremas provenientes de las mínimas y las máximas anuales, que son el resultado del promedio del año-tipo generado para cada punto muestral (el cual procede a su vez del promedio de los tres años completos seleccionados). No se trata, por tanto, de valores extremos absolutos sino de extremos medios, lo que sentiría un organismo-tipo a lo largo de un año. Ashcroft *et al.* (2012) y Gubler *et al.* (2018) usaron para sus modelos el percentil 5 y el 95 como variables climáticas limitantes para la vida de las plantas con notables resultados. En este estudio, los percentiles no se consideraron por el efecto de la nieve y el elevado gradiente altitudinal que produciría, en cada punto muestral, valores extremos muy dispares. El uso de valores extremos medios, por tanto, parece más adecuado en espacios de montaña donde la presencia de nieve puede alterar considerablemente el efecto de la altitud, ya que se relativizan los valores extremos y se reducen las diferencias motivadas por la elevación.

La aplicación del RI en este estudio ha dado muy buenos resultados, pero existen otras aproximaciones que también pueden ser válidas para encontrar refugios climáticos; por ejemplo, usando el GDD. El modelado de esta variable permitió conocer la distribución espacial del número de días de crecimiento vegetal, que está fuertemente asociado a las temperaturas extremas y, en menor medida, a la variabilidad climática. Se trata de una variable que ha sido usada en otros estudios [Niskanen *et al.*, 2016; Meineri & Hylander, 2017; Gubler *et al.*, 2018] como predictora del meso y microclima. El GDD podría ser una alternativa a las temperaturas extremas de invierno, por cuanto se infiere que en días sin crecimiento vegetativo las temperaturas mínimas y máximas serán muy bajas.

El Índice de Refugio Combinado facilitó la localización de zonas atemporales de refugios climáticos, por ser independientes del tipo de escenario general sobre el que se definen (cálido o frío), lo que podría evocar situaciones pasadas de periodos glaciario-interglaciario. Se trata de lugares en los que el clima es muy diferente al de su alrededor ya que han sido identificados por ser extremos pero estables y estar aislados del patrón climático regional. La cartografía que se ha generado de este índice (ver Figura 4.21) ha permitido dar a conocer el área y la localización que ocuparían ambos tipos de refugio cuando las condiciones ambientales les fueran benévolas. Cuanto más extremo sea el valor de un sitio dado por este índice mayor será su capacidad de persistir en condiciones que se tornen desfavorables. Este nuevo índice combinado, generado para este estudio, permite por tanto la localización de áreas en las que la persistencia de la biodiversidad ha sido (en el pasado) y será facilitada (en el futuro), y a la que podrían migrar organismos desde otros lugares amenazados por cambio climático.

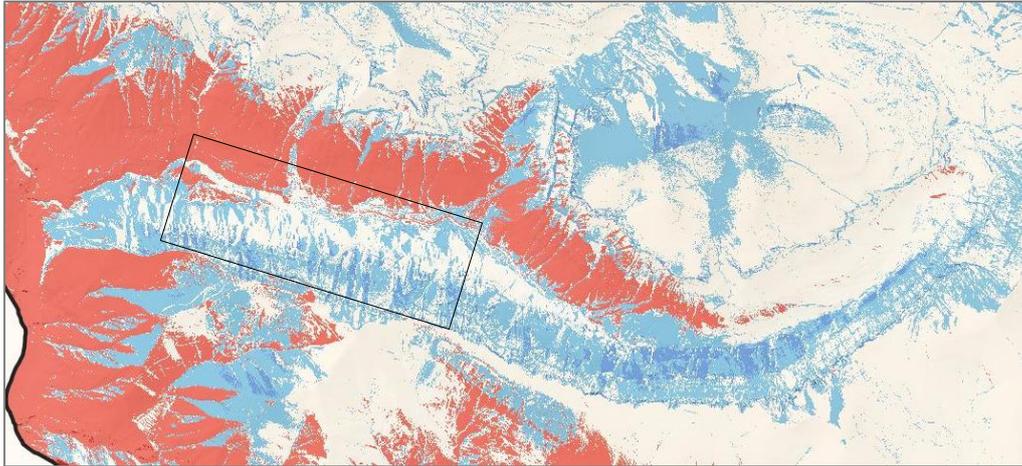


Figura 5.1. Mapa de refugios climáticos en el valle de Ordesa para ambos escenarios (a partir del Índice de Refugio Combinado).

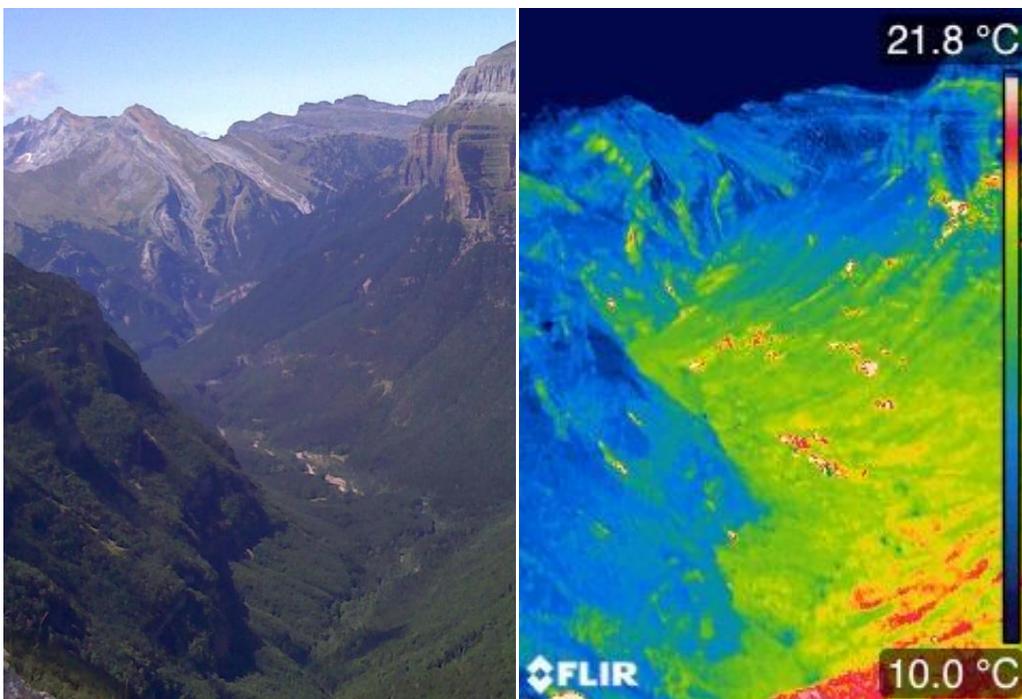


Figura 5.2. Vista aérea del valle de Ordesa en color real (izda) y en cámara térmica (dcha); tomada el 14-8-2018 a las 12:00 solares [Fotografía: MBG]. Se observa la relación entre el detalle del mapa de refugios (Figura 5.1) y los valores registrados por el sensor térmico. A la izquierda, la ladera de umbría de las Sierra de las Cutas con valores azules (fríos) y los parches rojizos (cálidos) en las laderas no muy elevadas de solana.

5.2. Valoración del proceso metodológico

La identificación de los refugios climáticos en el PNOMP fue abordada mediante el uso del entorno R y la integración en éste de SIG y datos de teledetección LiDAR. La generación de *scripts* en R permitió automatizar los procesos y reducir sustancialmente el coste de tiempo, especialmente si más adelante se realiza una extrapolación a otros ámbitos. De esta manera, los métodos aquí propuestos pueden ser aplicados fácilmente a otras áreas y propósitos similares. El único obstáculo fue la no disponibilidad de descarga automatizada

de los datos LiDAR del PNOA; estos tuvieron que realizarse directamente desde el centro de descargas del CNIG.

El empleo de *scripting* en R u otros entornos para la generación de modelos topoclimáticos se ha empezado a desarrollar recientemente gracias a la cada vez mayor disponibilidad de paquetes orientados al análisis geoespacial. Por ejemplo, ha sido usado en el estudio de Maclean *et al.* (2019) para modelizar microclimas en la costa de Cornualles (Reino Unido) y el código está disponible en el repositorio oficial de R para usarlo y adaptarlo a otros objetivos similares. En otros estudios, como Niskanen *et al.* (2016), se usaron códigos en lenguaje Python para obtener variables topográficas como el TWI [Prasad Pathak, 2013], obteniendo resultados muy satisfactorios. El uso de la teledetección también ha permitido encontrar refugios, como en Dubinin *et al.* (2018) que basó su estudio en ámbito mediterráneo en el cálculo del Índice de Vegetación Diferencial Normalizado (NDVI) para detectar especies raras en ambientes secos. Ashcroft *et al.* (2012) y Maclean *et al.* (2019) utilizaron el CHM derivado de datos LiDAR como predictora; en ambos casos fue una variable importante para sus modelos.

La disponibilidad en España de manera pública de datos LiDAR del programa PNOA permite obtener MDE y MDS a una alta resolución espacial que son muy aptos para estudios como el presente, en el que la topografía y ciertas métricas como el CHM a muy pequeña escala juegan un papel fundamental en la aparición de microclimas y micro-refugios. La puesta en marcha, en la actualidad, de la segunda cobertura de datos LiDAR del PNOA con mayor densidad de puntos (1 punto/m²) permitirá generar variables derivadas con un mayor nivel de detalle que, sin duda, ayudarán a mejorar los estudios de carácter local. Por otro lado, los progresivos avances realizados desde la comunidad de usuarios del entorno R garantizan una posible mejora de los paquetes orientados hacia el análisis geoespacial y una integración mayor con los SIG y la teledetección.

No obstante, los resultados obtenidos en este estudio son muy positivos en el contexto de las TIG, puesto que con el empleo de mini-sensores de bajo coste y de herramientas *libres* y colaborativas se ha podido identificar satisfactoriamente refugios climáticos en el PNOMP ya que han sido refrendados por datos biológicos. Los sensores *iButton*® tuvieron un comportamiento en campo muy bueno, aunque no exento de errores en algunos casos (roturas, pérdidas, fallos de memoria, elevada exposición al clima o, incluso, vandalismo). Sin embargo, se lograron series temporales continuas a una resolución temporal muy alta que facilitaron los posteriores análisis y la generación de *grids* topoclimáticos con un grado de ajuste notable. Por su parte, la programación de rutinas en R permitió integrar en un único entorno la organización de una amplia base de datos climática, análisis y operaciones geoespaciales, procesos estadísticos para la construcción de los modelos, su espacialización y el cálculo del RI, con resultados altamente satisfactorios.

5.3. Líneas de trabajo futuras

Los positivos resultados obtenidos en este estudio promueven la aplicación de la metodología para la identificación de refugios climáticos en otras áreas semejantes; por ejemplo, a la totalidad del Pirineo. En este sentido, el PNOMP ha constituido un óptimo escenario como punto de partida gracias a su compleja topografía y su rica biodiversidad. La detección de estos micro-refugios en el PNOMP permite ahora encontrar especies florísticas “raras” en esta área, ya que suelen concentrarse en ambientes climáticamente

aislados dentro de la matriz climática general, y precisar si existe asociación entre el tipo de planta y el tipo de refugio en el que se localiza.

Por otro lado, la importante correlación obtenida entre los datos registrados por *iButton*® y por EuroLST, excepto en el caso de la cobertura nival, permitirían utilizar de forma más generalizada el sensor MODIS con algunos ajustes metodológicos, sustituyendo el costoso trabajo de campo que implica la colocación y descarga periódica de los sensores *iButton*®. Los datos diarios de la temperatura del suelo que ofrece este sensor facilitarían ahora el procesado a partir de nuevas herramientas de las TIG como *Google Earth Engine* (GEE), que permite el análisis multitemporal de grandes conjuntos de datos, ahorrando mucho tiempo en el procesamiento de datos al tiempo que se expande el territorio cubierto de forma efectiva. En este sentido, los continuos progresos en las TIG constituyen una gran ventaja para futuros trabajos de este tipo. La segunda cobertura de los datos LiDAR del PNOA, que cubre ya una gran parte del territorio nacional, permitirá aumentar el detalle de los modelos al poseer una mayor densidad de puntos y obtener variables con un grado de ajuste mayor, como el caso del CHM. El uso reciente de drones para estudios ambientales de carácter local que integran sensores LiDAR y cámaras fotogramétricas son también buenos candidatos para ser usados en estudios relacionados con la biodiversidad. De la misma manera, supone una oportunidad el aumento de la automatización del análisis geoespacial, concretamente en entorno R, cuya amplia comunidad de usuarios ofrece nuevos y renovados paquetes que permiten la mejora constante de los procesos.

6. Conclusiones

En este trabajo se han identificado refugios climáticos en el PNOMP a partir de datos de temperatura mínima y máxima procedentes de 73 puntos de muestreo monitorizados con mini-sensores de temperatura en campo, y de la generación de variables topográficas y ambientales potencialmente predictoras del clima. Gracias a ello se pudo elaborar un modelo topoclimático de alta resolución y calcular el *Refugia Index* para hipotéticos escenarios muy cálidos (por ejemplo, al que tendemos por cambio climático) y fríos (los pasados periodos glaciares). A partir de ellos se derivó un nuevo índice: el Índice de Refugio Combinado, que muestra la extensión espacial de estos refugios en cualquier escenario y detectar las localizaciones más resistentes a las oscilaciones climáticas.

En términos generales y a tenor de los resultados obtenidos en este estudio, se puede concluir que:

- Los modelos topoclimáticos con distintas variables topográficas explicaron mejor las temperaturas mínimas y máximas en todos los casos que los que sólo contaron con la componente altitud. Las variables topográficas más significativas fueron la altitud, el Modelo de Altura del Dosel Vegetal (CHM), el Índice Potencial de Radiación Solar (PISR), el Índice de Humedad Topográfica (TWI) y la orientación.
- La reducción en la escala o *downscaling* en la búsqueda de micro-refugios a 5 m fue muy satisfactoria ya que éstos pudieron ser identificados a una escala muy pequeña y ser validados satisfactoriamente en gabinete mediante registros florísticos.
- Los sensores de campo *iButton*® se mostraron como un instrumento capacitado para estudios microclimáticos en áreas de montaña, aun con las dificultades inherentes que conlleva un mini-sensor y su ubicación en zonas de escasa accesibilidad. No obstante, en la mayoría de los casos se pudieron generar series temporales diarias

suficientemente largas para reconstruir un año-tipo promedio y conocer el nicho térmico de muy variadas comunidades vegetales.

- La elevada correlación de los datos *iButton*® con EuroLST, derivado del sensor MODIS, permitió validar los registros de temperatura obtenidos en campo, con valores de temperaturas en suelo en ambos casos más extremos que los basados en estaciones climáticas. Estas diferencias se confirmaron con la comparación realizada entre los registros de *iButton*® y los procedentes de estaciones meteorológicas, tanto de CLIM'PY como de la prueba efectuada en la estación meteorológica situada dentro del PNOMP (Góriz).
- La programación de rutinas en R se mostró como un entorno claramente solvente para la identificación de los refugios al permitir organizar y operar con una gran cantidad de datos climáticos, SIG e información LiDAR; realizar el ajuste de modelos, espacializar los resultados y procesar capas ráster para el cálculo del *Refugia Index*. El progresivo aumento de paquetes orientados a los análisis geoespaciales y la integración en su entorno de los SIG y de datos de teledetección, hacen de ésta una herramienta muy válida para estudios de este tipo.
- La información LiDAR pudo ser procesada de manera satisfactoria mediante *scripting* y el uso de funciones automatizadas para generar el MDE de alta resolución del área de estudio que constituyó la base de las variables predictoras del modelo topoclimático.
- Se ha demostrado la capacidad de los modelos topoclimáticos de alta resolución espacial para identificar las variaciones microclimáticas en áreas topográficamente complejas y, en último término, encontrar refugios climáticos para escenarios fríos y cálidos.

Agradecimientos

Este trabajo constituye el resultado de la investigación realizada en el Departamento de Biodiversidad y Restauración del Instituto Pirenaico de Ecología (IPE), centro perteneciente del Consejo Superior de Investigaciones Científicas (CSIC) gracias a la concesión de una beca JAE de Introducción a la Investigación del CSIC (ref.: "JAEINT_18_01546"). El estudio fue desarrollado dentro del proyecto VULBIMON (CGL2017-90040-R – Vulnerabilidad de la biodiversidad en montañas del sur de Europa frente al cambio climático) cuyo primer objetivo es la detección de micro-refugios climáticos en el Pirineo a partir de la asociación entre la topografía, basada en LiDAR, y datos topoclimáticos procedentes de sensores climáticos de campo, datos de teledetección satelital (MODIS) e imágenes térmicas, con el fin de asociar, más adelante, estos refugios a riqueza de especies, sus características biológicas y la abundancia o no de endemismos.

Agradecer a todas las personas implicadas en este proyecto:

- Personal del IPE-CSIC que ha ayudado con las descargas y organización de datos: Pablo Tejero, Pedro Bravo y Jesús Revilla. Daniel Gómez en la asignación de la corología y el límite de distribución de las especies de plantas.
- Agentes de Protección de la Naturaleza y SARGA, que han ayudado con las descargas de *iButton*® y su validación, especialmente Manuel Grasa, Javier Gómez, Carlos Benedé, Rafael Jiménez y Patricia Abadía.
- Personal del Parque Nacional de Ordesa y Monte Perdido: Manuel Montes (Director) y Elena Villagrasa, por los permisos para trabajar allí.
- Alcaldes de Torla y Fanlo, por los permisos para transitar por pistas de acceso restringido.
- Proyectos RECAMBIO y DYNBIO del OAPN, y VULBIMON del Plan Nacional, por la financiación de los *iButton*®.
- Roberto Serrano Notivoli y Miguel Ángel Saz Sánchez, del proyecto CLIM'PY, por los datos climáticos de la base de datos STEAD para las comprobaciones con las estaciones de muestreo.

A todas las personas que he podido conocer durante mi estancia en el IPE-CSIC, por haber hecho tan agradable mi estancia con vosotros.

A mis compañeros del Departamento de Biodiversidad del IPE-CSIC, José Luis Silva, Laura Matas y Héctor Miranda por la ayuda prestada en determinadas fases de este trabajo.

Y a mis directores en el IPE-CSIC, María Begoña García González y Manuel Pizarro Gavilán, por vuestra plena disposición, apoyo, confianza y amabilidad. Habéis sido unos guías formidables y he aprendido muchísimo de vosotros.

Bibliografía

- Abeli, T.; Vamosi, J.C.; Orsenigo, S. (2018): *The importance of marginal population hotspots of cold-adapted species for research on climate change and conservation*. Journal of Biogeography 45 (5), 977-985. doi: 10.1111/jbi.13196.
- Araújo, M.B.; Anderson, R.P.; Márcia-Barbosa, A.; Beale, C.M.; Dormann, C.F.; Farly, R.; García, R.A.; Guisan, A.; Majorano, L.; Naimi, B.; O'Hara, R.B.; Zimmermann, N.E.; Rahbek, C. (2019): *Standards for distribution models in biodiversity assessments*. Sci Adv 5, eaat4858. doi: 10.1126/sciadv.aat4858.
- Ashcroft, M.B.; Chisholm, L.A.; French, K.O. (2009): *Climate change at the landscape scale: predicting fine-grained spatial heterogeneity in warming and potential refugia for vegetation*. Global Change Biology 15 (3), 656-667.
- Ashcroft, M.B. (2010): *Identifying refugia from climate change*. Journal of Biogeography 37, 1407-1413.
- Ashcroft, M.B.; Gollan, J.R.; Warton, D.I.; Ramp, D. (2012): *A novel approach to quantify and locate potential microrefugia using topoclimate, climate stability and isolation from the matrix*. Global Change Biology 18, 1866-1879. doi: 10.1111/j.1365-2486.2012.02661.x.
- Ashcroft, M.B.; Gollan, J.R. (2012): *Fine-resolution (25 m) topoclimatic grids of near-surface (5 cm) extreme temperatures and humidities across various habitats in a large (200 x 300 km) and diverse region*. International Journal of Climatology 32, 2134-2148. doi: 10.1002/joc.2428.
- Balice, R.G.; Miller, J.D.; Oswald, B.P.; Edminster, C.; Yool, S.R. (2000): *Forest surveys and wildfire assessment in the Los Alamos Region, 1998-1999*. Los Alamos National Laboratory. University of California for the United States Department of Energy.
- Balzotti, C.S.; Asner, G.P.; Taylor, P.G.; Cleveland, C.C.; Cole, R.; Martin, R.E.; Nasto, M.; Osborne, B.B.; Porder, S.; Townsend, A.R. (2016): *Environmental controls on canopy foliar nitrogen distributions in a Neotropical lowland forest*. Ecological Applications 26 (8), 2449-2462. doi: 10.5061/dryad.ck585.
- Batalla, M.; Ninyerola, M.; Catalán, J. (2018): *Pyrenean Digital Climate Atlas (PDCA) (version 1.0.0)*. [Data-set]. Zenodo. doi: 10.5281/zenodo.1186639.
- Bátori, Z.; Vojtkó, A.; Farkas, T.; Szabó, A.; Havadtöi, K.; Vojtkó, A.E.; Tölgyesi, C.; Cseh, V.; Erdős, L.; Maák, I.E.; Keppel, G. (2017): *Large- and small-scale environmental factors drive distributions of cool-adapted plants in karstic microrefugia*. Annals of Botany 119, 301-309. doi: 10.1093/aob/mcw223.
- Benito Alonso, J.L. (2018): *Mapa de vegetación actual, a escala 1:10.000, del Parque Nacional de Ordesa y Monte Perdido y su zona periférica de protección*. Red de Parques Nacional. ISBN-digital: 978-84-947985-6-6.
- Bennie, J.; Huntley, B.; Wiltshire, A.; Hill, M.O.; Baxter, R. (2008): *Slope, aspect and climate: Spatially explicit and implicit models of topographic microclimate in chalk grassland*. Ecological Modelling 216, 47-59.

- Beven, K.J.; Kirkby, M.J. (1979): *A physically-based variable contributing area model of basin hidrology*. Hydrology Science Bulletin 24 (1), 43-69.
- Blanco-Pastor, J.L.; Fernández-Mazuecos, M.; Coello, A.J.; Pastor, J.; Vargas, P. (2018): *Topography explains the distributions of genetic diversity in one of the most fragile European hotspots*. Diversity and Distributions 25, 74-89. doi: 10.1111/ddi.12836.
- Boehner, J.; Selige, T. (2006): Spatial prediction of soil attributes using terrain analysis and climate regionalization. En Boehner, J.; McCloy, K.R.; Strbol, J.: *SAGA – Analysis and Modelling Applications*. Goettinger Geographische Abhandlungen 115, 13-27.
- Boehner, J.; Antonic, O. (2009): Land-surface parameters specific to topo-climatology. En Hengl, T.; Reuter, H. (Eds.): *Geomorphometry – Concepts, Software, Applications*. Developments in Soil Science 33, 195-226. Elsevier.
- Bolstand, P.V.; Lillesand, T.M. (1992): *Improved classification of forest vegetation in northern Wisconsin through a rule-based combination of soils, terrain and Landsat TM data*. Forest Science 38 (1), 5-20.
- Daly, C. (2006): *Guidelines for assessing the suitability of spatial climate data sets*. International Journal of Climatology 26, 707-721. doi: 10.1002/joc.1322.
- Dawson, T.P.; Jackson, T.P.; House, J.I.; Pretince, I. C.; Mace, G.M. (2011): Beyond Predictions: Biodiversity Conservation in a Changing Climate. Science 332, 53–58.
- Dobrowski, S.Z., Abatzoglou, J.T., Greenberg, J.A., Schladow, S.G., 2009. How much influence does landscape-scale physiography have on air temperature in a mountain environment? *Agricultural and Forest Meteorology* 149, 1751–1758. doi:10.1016/j.agrformet.2009.06.006
- Dobrowski, S.Z. (2011): *A climatic basis for microrefugia: the influence of terrain on climate*. Global Change Biology 17, 1022-1035. doi: 10.1111/j.1365-2486.2010.02263.x.
- Dobrowski, S.Z.; Parks, S.A. (2016): *Climate change velocity underestimates climate change exposure in mountainous regions*. Nature Communications 7:12349. doi: 10.1038/ncomms12349.
- Dubinin, V.; Svoray, T.; Dorman, M.; Perevolotsky, A. (2018): *Detecting biodiversity refugia using remotely sensed data*. Landscape Ecol 33, 1815-1830. doi: 10.1007/s10980-018-0705-1.
- Engler, R., Randin, C.F., Thuiller, W., Dullinger, S., Zimmermann, N.E., Araújo, M.B. (2011): *21st century climate change threatens mountain flora unequally across Europe*. Global Change Biology, 17 (7), 2330–2341. Doi:10.1111/j.1365-2486.2010.02393.x.
- Fick, S.E.; R.J. Hijmans (2017): *WorldClim 2: new 1-km spatial resolution climate surfaces for global land areas*. International Journal of Climatology 37 (12), 4302-4315. doi: 10.1002/joc.5086.
- Fridley, J.D. (2009): *Downscaling climate over complex terrain: high finescale (<1000 m) spatial variation of near-ground temperatures in a montane forested landscape (Great Smoky Mountain)*. American Meteorological Society 48, 1033-1049. doi: 10.1175/2008JAMC2084.1.

- Font, X.; Rodríguez-Rojo, M.P.; Acedo, C.; Biurrun, I.; Fernández-González, F.; Lence, C.; Loidi, J.; Ninot, J.M. (2010): *SIVIM: an on-line database of Iberian and Macaronesian Vegetation*. Waldokologie Online.
- García, M.B.; Domingo, D.; Pizarro, M.; Font, X.; Gómez, D.; Ehrlén, J. (2019): *Rocky habitats as microclimatic refuges for biodiversity. A close-up thermal approach*. Environmental and Experimental Botany (aceptado).
- Gavin, D.G.; Fitzpatrick, M.C.; Gugger, P.F.; Heath, K.D.; Rodríguez-Sanchez, F.; Dobrowski, S.Z.; Hampe, A.; Hu, F.S.; Ashcroft, M.B.; Bartlein, P.J.; Bois, J.L.; Carstens, B.C.; Davis, E.B.; de Lafontaine, G.; Edwards, M.E.; Fernández, M.; Henne, P.D.; Herring, E.M.; Holden, Z.A.; Kong, W.S.; Liu, J.; Magri, D.; Matzke, N.J.; McGlone, M.S.; Saltré, F.; Stigall, A.L.; Tsai, Y.H.E.; Williams, J.W. (2014): *Climate refugia: joint inference from fossil records, species distribution models and phylogeography*. New Phytol 204, 37-54. doi: 10.1111/nph.12929.
- Gerlitz, L.; Conrad, O.; Boehner, J. (2015): *Large scale atmospheric forcing and topographic modification of precipitation rates over High Asia – a neural network based approach*. Earth System Dynamics 6, 1-21. doi: 10.5194/esd-6-1-2015.
- Gollan, J.R.; Ramp, D.; Ashcroft, M.B. (2015): *Contrasting topoclimate, long-term macroclimatic averages, and habitat variables for modelling ant biodiversity at landscape scales*. Insect Conservation and Diversity 8 (1), 43-53. doi: 10.1111/icad.12081.
- Gómez, D., García, M.B., Font Castell, X., Aizpuru Oiarbide, I., 2017. Distribución espacial y análisis ambiental de la flora vascular de los Pirineos. Pirineos 172, 028. doi:10.3989/pirineos.2017.172003
- Graae, B.J.; Vandvik, V.; Armbruster, W.S.; Eiserhardt, W.L.; Svenning, J.C.; Hylander, K.; Ehrlén, J.; Speed, J.D.M.; Klanderud, K.; Brathen, K.A.; Milbau, A.; Opedal, O.H.; Alsos, I.G.; Ejrnaes, R.; Bruun, H.H.; Birks, H.J.B.; Westergaard, K.B.; Birks, H.H.; Lenoir, J. (2018): *Stay or go – how topographic complexity influences alpine plant population and community responses to climate change*. Perspectives in Plant Ecology, Evolution and Systematics 30, 41-50. doi: 10.1016/j.ppees.2017.09.008.
- Greco, S.E.; Girvetz, E.H.; Larsen, E.W.; Mann, J.P.; Tuil, J.L.; Lowney, C. (2008): *Relative elevation topographic surface modelling of a large alluvial river floodplain and applications for the study and management of Riparian landscapes*. Landscape Research 33 (4), 461-486.
- Gubler, M.; Henne, P.D.; Schwörer, C.; Boltshauser-Kaltenrieder, P.; Lotter, A.F.; Brönnimann, S.; Tinner, W. (2018): *Microclimatic gradients provide evidence for a glacial refugium for temperate trees in a sheltered hilly landscape of Northern Italy*. Journal of Biogeography 45, 2564-2575. doi: 10.1111/jbi.13426.
- Gunton, R.M.; Polce, C.; Kunin, W.E. (2015): *Predicting ground temperatures across European landscapes*. Methods in Ecology and Evolution 6, 532-542. doi: 10.1111/2041-210X.12355.
- Hall, A. (2014): *Projecting regional change*. Science 346, 1461-1462. doi: 10.1126/science.aaa0629.

- Harris, A.; Baird, A.J. (2018): *Microtopographic drivers of vegetation patterning in blanket peatlands recovering from erosion*. *Ecosystems* 22, 1035-1054. doi: 10.1007/s10021-018-0321-6.
- Harrison, S.; Noss, R. (2017): *Endemism hotspots are linked to stable climatic refugia*. *Annals of Botany*, 119 (2), 207–214. doi: 10.1093/aob/mcw248.
- Hofierka, J.; Suri, M. (2002): *The solar radiation model for Open Source GIS: implementation and applications*. International GRASS users conference. Trento, Italy.
- Hojati, M.; Mokarram, M. (2016): *Determination of a Topographic Wetness Index using high resolution Digital Elevation Models*. *European Journal of Geography* vol. 7, 4, 41-56.
- Hylander, K.; Ehlén, J.; Luoto, M.; Meineri, E. (2015): *Microrefugia: Not for everyone*. *A Journal of the Human Environment* 44 (suppl. 1), 60-68. Doi: 10.1007/s13280-014-0599-3.
- Karger, D.N., Conrad, O., Böhner, J., Kawohl, T., Kreft, H., Soria-Auza, R.W., Zimmermann, N.E., Linder, H.P. & Kessler, M. (2017): *Climatologies at high resolution for the Earth's land surface areas*. *Scientific Data* 4, 170122.
- Keppel, G.; Van Niel, K.P.; Wardell-Johnson, G.W.; Yates, C.J.; Byrne, M.; Mucina, L.; Schut A.G.T.; Hopper, S.D.; Franklin, S.E. (2012): *Identifying and understanding safe havens for biodiversity under climate change*. *Global Ecology Biogeography* 21, 393-404. doi: 10.1111/j.1466-8238.2011.00686.x.
- Keppel, G.; Mokany, K.; Wardell-Johnson, G.W.; Phillips, B.L.; Welbergen, J.A.; Reside, A.E. (2015): *The capacity of refugia for conservation planning under climate change*. *Frontier Ecology Environment* 13 (2), 106-112. doi: 10.1890/140055.
- Khosravipour, A.; Skidmore, A.K.; Isenburg, M.; Wang, T.; Hussin, Y.A. (2014): *Generating pit-free canopy height models from airborne LiDAR*. *Photogrammetric Engineering & Remote Sensing*, 80 (9), 863-872.
- Kolbert, E. (2014): *The sixth extinction. An unnatural history*. Holt & Co., New York.
- Lundquist, J.D.; Pepin, N.; Rochford, C. (2008): *Automated algorithm for mapping regions of cold-air pooling in complex terrain*. *Journal of Geophysical Research* 113, D22107. doi: 10.1029/2008JD009879.
- Luoto, M.; Heikkinen, R.K. (2008): *Disregarding topographic heterogeneity biases species turnover assessments based on bioclimatic models*. *Global Change Biology* 14 (3), 483-494. doi: 10.1111/j.1365-2486-2007.01527.x.
- Macleán, I.M.D.; Suggitt, A.J.; Wilson, R.J.; Duffy, J.P.; Bennie, J.J. (2016): *Fine-scale climate change: modelling spatial variation in biologically meaningful rates of warming*. *Global Change Biology* (2016). doi: 10.1111/gcb.13343.
- Macleán, I.M.D.; Mosedale, J.R.; Bennie, J.J. (2019): *Microclima: An R package for modelling meso- and microclimate*. *Methods in Ecology and Evolution* 10, 280-290. doi: 10.1111/2041-210X.13093.
- Mas, J.F. (2013): *Análisis Espacial con R: Usa R como un Sistema de Información Geográfica*. European Scientific Institute Publishing. Konaci, North Macedonia.

- McNab, H.W. (1989): *Terrain shape index: quantifying effect of minor landforms on tree height*. *Forest Science* 35 (1), 91-104.
- McNab, H.W. (1993): *A topographic index to quantify the effect of mesoscale landform on site productivity*. *Can J, For. Res.* 23, 1100-1107.
- Medail, F.; Diadema, K. (2009): *Glacial refugia influence plant diversity patterns in the Mediterranean Basin*. *Journal of Biogeography* 36 (7), 1333–1345. doi: 10.1111/j.1365-2699.2008.02051.x.
- Meineri, E.; Hylander, K. (2017): *Fine-grain, large-domain climate models based on climate station and comprehensive topographic information improve microrefugia detection*. *Ecography* 40, 1003-1013. doi: 10.1111/ecog.02494.
- Metz, M.; Rocchini, D.; Neteler, M. (2014): *Surface temperatures at the continental scale: tracking changes with remote sensing at unprecedented detail*. *Remote Sensing*. 2014, 6 (5): 3822-3840.
- Moore, I.D.; Grayson, R.B.; Ladson, A.R. (1991): *Digital terrain modelling: a review of hydrological, geomorphological and biological applications*. *Hydrological Processes* vol. 5, no 1.
- Niederheiser, R.; Rutzinger, M.; Bremer, M.; Wichmann, V. (2018): *Dense image matching of terrestrial imagery for deriving high-resolution topographic properties of vegetation locations in alpine terrain*. *International Journal of Applied Earth Observation and Geoinformation*. 66, 146-148. doi: 10.1016/j.jag.2017.11.011.
- Niskanen, A.; Luoto, M.; Väre, H.; Heikkinen, R.K. (2016): *Models of Arctic-alpine refugia highlight importance of climatic and local topography*. *Polar Biology* 40, 489-502. doi: 10.1007/s00300-016-1973-3.
- Novick, K.A.; Oishi, A.C.; Miniati, C.F. (2016): *Cold air drainage flows subsidize montane valley ecosystem productivity*. *Global Change Biology* 22 (12), 4014-4027. doi: 10.1111/gcb.13320.
- Ohlemüller, R.; Anderson, B.J.; Araújo, M.B.; Butchart, S.H.M.; Kudma, O.; Ridgely, R.S.; Thomas, C.D. (2008): *The coincidence of climatic and species rarity: high risk to small-range species from climate change*.
- Olson, M.; Rupper, S. (2018): *Impacts of topographic shading on direct solar radiation for valley glaciers in complex topography*. *The Cryosphere* 13, 29-40. doi: 10.5194/tc-13-29-2019.
- Patsiou, T.S.; Conti, E.; Zimmermann, N.E.; Theodoridis, S.; Randin, C.F. (2014): *Topo-climatic microrefugia explain the persistence of a rare endemic plant in the Alps during the last 21 millenia*. *Global Change Biology* 20, 2286-2300. doi: 10.1111/gcb.12515.
- Peña, J.L.; Lozano, M.V. (2004): *Las unidades del relieve aragonés*. En Peña, J.L.; Longares, L.A.; Sánchez, M. (Eds.): *Geografía Física de Aragón. Aspectos generales y temáticos*. Universidad de Zaragoza. Institución Fernando el Católico. Zaragoza. ISBN: 87-96214-29-X.
- Potter, K.A.; Woods, H.A.; Pincebourde, S. (2013): *Microclimatic challenges in global change biology*. *Global Change Biology* 19, 2932-2939. doi: 10.1111/gcb.12257

- Pimm, S.L., Jenkins, C.N., Abell, R., Brooks, T.M., Gittleman, J.L., Joppa, L.N., Raven, P.H., Roberts, C.M., Sexton, J.O., 2014. The biodiversity of species and their rates of extinction, distribution, and protection. *SCIENCE* 344, 1246752–1246752. doi:10.1126/science.1246752
- Randin, C.F.; Engler, R.; Normand, S.; Zappa, M.; Zimmermann, N.E.; Pearman, P.B.; Vittoz, P.; Thuiller, W.; Guisan, A. (2009): *Climate change and plant distribution: local models predict high-elevation persistence*. *Global Change Biology* 15 (6), 1557-1569. doi: 10.1111/j.1365-2486.2008.01766.x.
- Riley, S.J.; DeGloria, S.D.; Elliot, R. (1999): *A Terrain Ruggedness Index that quantifies topographic heterogeneity*. *Intermountain Journal of Sciences* vol. 5, 1-4, 23-27.
- Rockström, J.; Steffen, W.; Noone, K.; Persson, A.; III Chapin, F.S.; Lambin, E.; Lenton, T.m; Scheffer, M.; Folke, C.; Schellnhuber, H.J.; Nykvist, B.; de Wit, C.A.; Hughes, T.; van der Leeuw, S.; Rodhe, H.; Sörlin, S.; Snyder, P.K.; Costanza, R.; Svedin, U.; Falkenmark, M.; Karlberg, L.; Corell, R.W.; Fabry, V.J.; Hansen, J.; Walker, B.; Liverman, D.; Richardson, K.; Crutzen, P.; Foley, J. (2009): *Planetary boundaries: exploring the safe operating space for humanity*. *Ecology and Society* 14(2) 32. [online] URL: <http://www.ecologyandsociety.org/vol14/iss2/art32/>.
- Sandel, B., Arge, L.; Dalsgaard, B.; Davies, R.G.; Gaston, K J.; Sutherland, W.J.; Svenning, J.C. (2011): *The influence of Late Quaternary climate-change velocity on species endemism*. *Science* 334 (6056), 660–664. doi: 10.1126/science.1210173.
- Scheffers, B.R.; De Meester, L.; Bridge, T.C.L.; Hoffmann, A.A.; Pandolfi, J.M.; Corlett, R.T.; Butchart, S.H.M.; Pearce-Kelly, P.; Kovacs, K.M.; Dudgeon, D.; Pacifici, M.; Rondinini, C.; Foden, W.B.; Martin, T.G.; Mora, C.; Bickford, D.; Watson, J.E.M. (2016): *The broad footprint of climate change from genes to biomes to people*. *Science* 354, aaf7671. doi:10.1126/science.aaf7671.
- Scherrer, D., Schmid, S., Körner, C., 2011. Elevational species shifts in a warmer climate are overestimated when based on weather station data. *Int J Biometeorol* 55, 645–654. doi:10.1007/s00484-010-0364-7
- Serrano-Notivoli, R. (2017): *Reconstrucción climática instrumental de la precipitación diaria en España: ensayo metodológico y aplicaciones (Tesis Doctoral)*. Departamento de Geografía y Ordenación del Territorio. Facultad de Filosofía y Letras. Universidad de Zaragoza.
- Serrano-Notivoli, R.; Beguería, S.; Saz, M.A.; Longares; L.A.; de Luis, M. (2017): *SPREAD: A high resolution daily gridded precipitation dataset for Spain – an extreme events frequency and intensity overview*. *Earth System Science Data* 9, 721-738. doi: 10.5194/essd-9-721-2017.
- Serrano-Notivoli, R.; Beguería, S.; de Luis, M. (2019): *STEAD: A high-resolution daily gridded temperature dataset for Spain*. *Earth System Science Data* 11, 1171-1188. doi: 10.5194/essd-11-1171-2019.
- Suggitt, A.J.; Wilson, R.J.; Isaac, N.J.B.; Beale, C.M.; Auffret, A.G.; August, T.; Bennie, J.J.; Crick, H.Q.P.; Duffield, S.; Fox, R.; Hopkins, J.J.; Macgregor, N.A.; Morecroft, M.D.; Walker, K.J.; Maclean, I.M.D. (2018): *Extinction risk from climate change is reduced by microclimatic buffering*. *Nature Climate Change*. doi: 10.1038/s41558-018-0231-9.

- Thuiller, W.; Lavorel, S.; Araújo, M.B.; Sykes, M.T., Prentice I.C. (2005): *Climate change threats to plant diversity in Europe*. Proc Natl Acad Sci USA 2005 Jun 7; 102 (23), 8245-50.
- Tile, P.O.; Bemmels, J.B. (2018): *ENVIREM: an expanded set of bioclimatic and topographic variables increases flexibility and improves performance of ecological niche modelling*. Ecography 41, 291-307.
- Urban, D.L.; Miller, C.; Stephenson N.L.; Halpin, P.N. (2000): *Forest pattern in Sierran landscapes: the physical template*. Landscape Ecology 15, 603-620.
- Vogeler, J.C.; Cohen, W.B. (2016): *A review of the role of active remote sensing and data fusion for characterizing forest in wildlife habitat models*. Spanish Association of Remote Sensing 45, Special Issue, 1-14. doi: 10.4995/raet.2016.3981.
- Wan, Z.; Hook, S.; Hulley, G. (2015). MOD11A1 MODIS/Terra Land Surface Temperature/Emissivity Daily L3 Global 1km SIN Grid V006. NASA EOSDIS Land Processes DAAC. doi: 10.5067/MODIS/MOD11A1.006 (Accessed August 16, 2019).

Índice de Tablas

Tabla 3.1.	Paquetes utilizados para el análisis de datos espaciales en R.....	13
Tabla 3.2.	Variables dependientes del modelo para la búsqueda de refugios mediante RI.....	18
Tabla 3.3.	Variables predictoras generadas para los modelos topoclimáticos.....	19
Tabla 3.4.	Predictoras seleccionadas para cada modelo topoclimático.....	25
Tabla 3.5.	Variables incluidas en el <i>Refugia Index</i>	27
Tabla 4.1.	Resumen de los valores registrados por los sensores en los puntos de muestreo.....	29
Tabla 4.2.	Correlación <i>pairwise</i> entre sensores de campo.....	31
Tabla 4.3.	Grado de ajuste de modelos (valor de R ²).....	34

Índice de Figuras

Figura 1.1.	Variaciones locales de temperatura detectados por sensor térmico en una zona topográficamente compleja.....	2
Figura 2.1.	Área de estudio.....	5
Figura 3.1.	Las múltiples combinaciones de datos de temperaturas para detectar micro-refugios.....	6
Figura 3.2.	Diagrama general del proceso metodológico del estudio.....	7
Figura 3.3.	Sensor DS1920 <i>iButton</i> ®.....	9
Figura 3.4.	Sensores <i>iButton</i> ® con protección de malla mosquitera.....	10
Figura 3.5.	Coberturas LiDAR-PNOA publicadas a junio de 2019.....	11
Figura 3.6.	Descarga de datos de un <i>iButton</i> ® en campo.....	14
Figura 3.7.	Diagrama de flujo de los controles de calidad realizados para las matrices generales de temperaturas máximas y mínimas.....	16
Figura 3.8.	Selección de la serie temporal para cada uno de los 73 puntos.....	17
Figura 3.9.	MDE de 5 m de resolución resultante de LiDAR con cuadrículas LiDAR-PNOA.....	21
Figura 3.10.	Variables topográfico-ambientales predictoras generadas.....	23
Figura 3.11.	Árbol de correlación de las variables predictoras.....	24
Figura 3.12.	Gráfico de comparación por pares de las variables predictoras.....	24
Figura 4.1.	Distribución de las temperaturas medias de febrero en el PNOMP según hábitat.....	29
Figura 4.2.	Rango altitudinal por tipo de hábitat.....	30
Figura 4.3.	Percentil 95 de las temperaturas máximas diarias según el tipo de hábitat.....	30
Figura 4.4.	Rango de temperaturas de las variables dependientes de los modelos topoclimáticos para la detección de los refugios.....	31
Figura 4.5.	Valores registrados en el Refugio de Góriz durante la semana del 14 de agosto de 2019.....	31
Figura 4.6.	Número de días concrecimiento vegetativo (GDD) por tipo de hábitat...	32
Figura 4.7.	Correlación de las mínimas de invierno con la altitud por hábitat.....	33
Figura 4.8.	Correlación de las máximas de verano con la altitud por hábitat.....	33
Figura 4.9.	Comparación múltiple de temperaturas medias anuales (BIO-01).....	35
Figura 4.10.	Comparación múltiple de temperaturas medias de verano (BIO-10).....	35
Figura 4.11.	Comparación múltiple de temperaturas medias de invierno (BIO-11)...	35

Figura 4.12.	Detalle de las diferencias en la resolución en función de la base de datos climática para una misma zona de estudio.....	36
Figura 4.13.	Cartografía de las temperaturas mínimas anuales.....	37
Figura 4.14.	Cartografía de las temperaturas máximas anuales.....	38
Figura 4.15.	Cartografía de la variabilidad climática de las temperaturas mínimas...	39
Figura 4.16.	Cartografía de la variabilidad climática de las temperaturas máximas..	39
Figura 4.17.	Cartografía del “aislamiento” de cada punto respecto al conjunto de valores del Parque para temperaturas mínimas.....	40
Figura 4.18	Cartografía del “aislamiento” de cada punto respecto al conjunto de valores del Parque para temperaturas máximas.....	41
Figura 4.19.	Cartografía del nº de días anuales con crecimiento vegetativo.....	42
Figura 4.20.	Cartografía de los refugios climáticos fríos y cálidos del PNOMP para un escenario cálido.....	43
Figura 4.21.	Cartografía de los refugios climáticos fríos y cálidos del PNOMP para un escenario frío.....	43
Figura 4.22.	Cartografía del Índice de Refugio Combinado del PNOMP para cualquier escenario climático.....	44
Figura 4.23.	Coefficiente de correlación de Pearson entre el <i>Refugia Index</i> combinado de cada UTM del PNOMP y la proporción de plantas adaptadas al calor.....	45
Figura 4.24.	Coefficiente de correlación de Pearson entre el <i>Refugia Index</i> combinado de cada UTM del PNOMP y la proporción de plantas adaptadas al frío.....	45
Figura 5.1.	Mapa de refugios climáticos en el valle de Ordesa para ambos escenarios (a partir del Índice de Refugio Combinado).....	48
Figura 5.2.	Vista aérea del valle de Ordesa en color real y en cámara térmica.....	48

