

ESCUELA TÉCNICA SUPERIOR DE INGENIEROS
INDUSTRIALES Y DE TELECOMUNICACIÓN

UNIVERSIDAD DE CANTABRIA



Trabajo Fin de Máster

**Análisis de series temporales climáticas
mediante técnicas de agrupamiento.
Implementación y aplicaciones
(Clustering-based analysis of climate time
series. Development and applications)**

Para acceder al Título de

***Máster Universitario en
Ingeniería de Telecomunicación***

Autor: Juan Antonio Fernández de la Granja

Co-directores: Ana Casanueva Vicente
Joaquín Bedia Jiménez

Julio - 2020

Agradecimientos

En primer lugar me gustaría expresar mi más sincero agradecimiento a mis tutores, Ana Casanueva y Joaquín Bedia, por haberme dado la oportunidad de realizar este trabajo que fusiona dos campos científicos de gran trascendencia en la sociedad de hoy en día, el *Big Data* y el estudio del clima. Durante todo un año de trabajo, han depositado toda su confianza en mí y han empleado una gran cantidad de horas en mi formación y tutorado desde que me incluyeron como parte del Grupo de Meteorología de Santander, en el que me han hecho sentir muy a gusto y como un compañero más.

Quiero dar las gracias a mi familia, especialmente a mis padres, que me han apoyado incondicionalmente todos estos años y han hecho posible que haya llegado a donde estoy ahora. También quiero agradecer a mis abuelos toda la ayuda y apoyo proporcionados estos 7 años de andadura universitaria de Grado y Máster, en la que me han acogido en su casa durante los primeros años. Y no con menos importancia, a mi pareja, hermanos y amigos, por poder contar siempre con ellos y ser un apoyo fundamental.

También agradecer a todas aquellas personas que de distinta manera me han ayudado a la realización de este Trabajo de Fin de Máster: A Tomás Fernández por ser ponente de este trabajo y guiarme en el camino durante el Máster de Telecomunicaciones. A Antonio Cofiño por concederme una beca de colaboración en el Grupo de Meteorología; Jesús, Álvaro y a los demás compañeros del Grupo. Al *Group on Coupled Modelling* del *World Climate Research Program's Working*, que es responsable de los experimentos de CMIP, y a los centros de simulación listados en la Tabla 1 por producir los datos utilizados en el trabajo. Y, finalmente, a los proyectos INDECIS (parte de ERA4CS, co-financiado por la Unión Europea, convenio 690462) y AfriCultuRes (del programa europeo H2020, convenio 774652), por la financiación proporcionada.

Índice general

Índice de Figuras	VII
Resumen	XIII
Abstract	XIV
1. Introducción	1
1.1. Información climática	3
1.1.1. Modelos Climáticos Globales	3
1.1.2. Regionalización del clima	5
1.1.3. Reanálisis	6
1.2. Herramientas de software. El entorno <code>climate4R</code>	7
1.3. Objetivos	8
2. Métodos de clustering: descripción e implementación	11
2.1. Técnicas de agrupamiento objetivas	12
2.1.1. K-medias	12
2.1.2. Jerárquico	13
2.1.3. Mapas auto-organizativos (SOM)	15
2.2. Técnicas de agrupamiento subjetivas: Tipos de tiempo de Lamb	16
2.3. Contribución a <code>climate4R</code>	17
2.3.1. Implementación de los métodos	17
2.3.2. Ejemplos de aplicación de los métodos	18
3. Caso de estudio: Evaluación de la circulación atmosférica	25
3.1. Datos	27

3.1.1.	Datos de Modelos Globales del Clima	28
3.1.2.	Datos de reanálisis	29
3.2.	Métodos de evaluación	29
3.2.1.	Sesgo Relativo	30
3.2.2.	Divergencia de Kullback–Leibler (KL)	30
3.2.3.	Test de Proporciones (<i>Z-Test</i>)	31
3.2.4.	Probabilidades de Transición	32
3.2.5.	Índice de Matriz de Probabilidades de Transición (TPMS)	32
3.3.	Resultados	33
3.3.1.	Tipos de tiempo observados	33
3.3.2.	Tipos de tiempo en los modelos climáticos	35
3.3.3.	Probabilidades de Transición de los Tipos de Tiempo	37
3.4.	Conclusiones	39
4.	Conclusiones generales y trabajo futuro	43
4.1.	Reproducibilidad e impacto del trabajo	45
	Bibliografía	47
	Anexo A: Resultados con diferentes reanálisis de referencia	61
	Divergencia de Kullback–Leibler y Sesgo relativo de los modelos de CMIP5, CMIP6 y reanálisis tomando como referencia diferentes reanálisis	61
	Referencia: NNRP	61
	Referencia: JRA	62
	Referencia: ERA-20C	63
	Probabilidades de transición	65
	Probabilidades de transición de los productos de reanálisis	65
	Probabilidades de transición de los modelos de CMIP5/CMIP6	67
	Anexo B: Artículo enviado a <i>Climate Dynamics</i>	71

Índice de Figuras

1.1. Representación de una división típica en malla del globo terráqueo utilizada en la resolución numérica de un GCM. Fuente: NOAA, http://celebrating200years.noaa.gov/breakthroughs/climate_model/AtmosphericModelSchematic.png	4
1.2. Representación del aumento de la resolución de la malla de un Modelo Climático Regional (RCMs). Fuente: WMO, https://www.wmo.int/pages/themes/climate/climate_models.php	6
1.3. Vista esquemática del entorno de trabajo <code>climate4R</code>	9
2.1. Representación de 10 Tipos de Circulación obtenidos aplicando el algoritmo K-medias a partir de datos de SLP del reanálisis NNRP de los meses de invierno en los años 1983-2002	19
2.2. Representación de 5 Tipos de Circulación (izquierda) y dendograma (derecha) obtenidos aplicando el algoritmo jerárquico a partir de datos de SLP del reanálisis NNRP de los meses de invierno en los años 1983-2002. En el dendograma se muestran con diferentes colores los datos pertenecientes a diferentes clusters.	20
2.3. Representación de 10 Tipos de Circulación obtenidos aplicando el algoritmo SOM a partir de datos de SLP del reanálisis NNRP de los meses de invierno en los años 1983-2002	21

- 2.4. Representación de 8 Tipos de Circulación obtenidos aplicando el método de Lamb a partir de datos de SLP del reanálisis ERA-Interim en los años 1981-2010 sobre Europa, centrando las 16 localizaciones de inicio sobre las Islas Británicas. Los LWTs mostrados son los más frecuentes dado el conjunto de datos, mostrando su nombre abreviado y la frecuencia del LWT en la parte superior del mismo. La leyenda está centrada en el valor medio de presión atmosférica a nivel del mar ($101300Pa$). 23
- 3.1. Comparativa de frecuencias relativas estacionales de *Lamb Weather Types* (LWTs) obtenidas de los cuatro reanálisis (ERA-Interim, JRA, NNRP y ERA-20C) siguiendo la definición de LWTs de Lamb 1972. Los LWTs están representados en orden decreciente en función de las frecuencias anuales en ERA-Interim, indicado dicho valor con una línea horizontal como referencia para cada tipo de tiempo. 33
- 3.2. Divergencia de Kullback–Leibler (KL) (valores por estaciones y anuales, por columnas) de los diferentes reanálisis (izquierda) y modelos por experimentos (derecha, CMIP5 y CMIP6). 35
- 3.3. Sesgo Relativo de las frecuencias de los LWTs de los diferentes reanálisis y GCMs respecto a ERA-Interim (en filas: reanálisis en negro, GCMs de CMIP5 en rojo, GCMs de CMIP6 en azul) en las 4 estaciones (DJF, MAM, JJA y SON en columnas). Las filas están ordenadas siguiendo la clasificación de modelos (de menor a mayor) dada por el valor anual de divergencia de KL de la Figura 3.2 (las clasificaciones estacionales se dan entre paréntesis). Las cruces indican valores estadísticamente significativos después de ejecutar el Z-Test (Sect.3). 36
- 3.4. Ejemplo de Matrices de Probabilidades de Transición (A) de los Tipos de Tiempo Lamb, considerando los modelos CMIP5 IPSL-CM5A-LR (**b**) y su versión de CMIP6 IPSL-CM6A-LR (**c**) para el período histórico 1981-2010. 41

3.5. Índice de matriz de probabilidades de transición (TPMS) alcanzadas por los modelos CMIP5/CMIP6 (símbolos rojo/azul), tomando como referencia diferentes reanálisis. Los resultados se presentan como pares de GCMs CMIP5-CMIP6, en orden ascendente de izquierda a derecha teniendo en cuenta el TPMS de los modelos CMIP5 con ERA-Interim como referencia (círculos con relleno sólido). Las gráficas de la derecha resumen los resultados de las gráficas de su izquierda para cada reanálisis individualmente (ver el símbolo de la leyenda que indica la mediana) y el proyecto del CMIP (color). 42

A1. Divergencia de Kullback–Leibler (KL) (valores por estaciones y anuales, por columnas) de los diferentes reanálisis (izquierda) y modelos por experimentos (derecha, CMIP5 y CMIP6) con NNRP. 61

A2. Sesgo Relativo de las frecuencias de los LWTs de los diferentes reanálisis y GCMs respecto a NNRP (en filas: reanálisis en negro, GCMs de CMIP5 en rojo, GCMs de CMIP6 en azul) en las 4 estaciones (DJF, MAM, JJA y SON en columnas). Las filas están ordenadas siguiendo la clasificación de modelos (de menor a mayor) dada por el valor anual de Divergencia de KL de la Figura A1 (las clasificaciones estacionales se dan entre paréntesis). Las cruces indican valores estadísticamente significativos después de ejecutar el Z-Test (Sec.3). 62

A3. Divergencia de Kullback–Leibler (KL) (valores por estaciones y anuales, por columnas) de los diferentes reanálisis (izquierda) y modelos por experimentos (derecha, CMIP5 y CMIP6) con JRA-55. 62

- A4. Sesgo Relativo de las frecuencias de los LWTs de los diferentes reanálisis y GCMs respecto a JRA-55 (en filas: reanálisis en negro, GCMs de CMIP5 en rojo, GCMs de CMIP6 en azul) en las 4 estaciones (DJF, MAM, JJA y SON en columnas). Las filas están ordenadas siguiendo la clasificación de modelos (de menor a mayor) dada por el valor anual de Divergencia de KL de la Figura A3 (las clasificaciones estacionales se dan entre paréntesis). Las cruces indican valores estadísticamente significativos después de ejecutar el Z-Test (Sec.3). 63
- A5. Divergencia de Kullback–Leibler (KL) (valores por estaciones y anuales, por columnas) de los diferentes reanálisis (izquierda) y modelos por experimentos (derecha, CMIP5 y CMIP6) con ERA-20C. 63
- A6. Sesgo Relativo de las frecuencias de los LWTs de los diferentes reanálisis y GCMs respecto a ERA-20C (en filas: reanálisis en negro, GCMs de CMIP5 en rojo, GCMs de CMIP6 en azul) en las 4 estaciones (DJF, MAM, JJA y SON en columnas). Las filas están ordenadas siguiendo la clasificación de modelos (de menor a mayor) dada por el valor anual de Divergencia de KL de la Figura A5 (las clasificaciones estacionales se dan entre paréntesis). Las cruces indican valores estadísticamente significativos después de ejecutar el Z-Test (Sec.3). 64
- A7. Matrices de probabilidades de transición (TPM) de los productos de reanálisis. Las transiciones que no ocurren se dejan en blanco para diferenciarlas de las transiciones con muy baja probabilidad. Las probabilidades de transición de cada reanálisis son comparadas con las de ERA-Interim, obteniendo así el TPMS. Las probabilidades de transición significativamente diferentes de las de ERA-Interim se indican con cruces. Por otro lado, las transiciones de LWTs presentes en cada reanálisis pero no observadas en ERA-Interim se indican con círculosm huecos. Asimismo, los círculos con relleno sólido indican transiciones de LWTs que no están presentes en cada reanálisis, pero sí en ERA-Interim. 65
- A8. Transiciones que no ocurren en los diferentes reanálisis 66

A9. Matrices de probabilidades de transición de EC-EARTH de CMIP5 y EC-EARTH3 de CMIP6.	67
A10. Matrices de probabilidades de transición de HadGEM2-ES de CMIP5 y UKESM1-0-LL de CMIP6.	67
A11. Matrices de probabilidades de transición de MIROC5 de CMIP5 y MIROC6 de CMIP6.	68
A12. Matrices de probabilidades de transición de CNRM-CM5 de CMIP5 y CNRM-CM6-1 de CMIP6.	68
A13. Matrices de probabilidades de transición de MPI-ESM-LR de CMIP5 y MPI-ESM1-2-LR de CMIP6.	69
A14. Matrices de probabilidades de transición de NORESM-M1 de CMIP5 y NORESM2-LM de CMIP6.	69
A15. Matrices de probabilidades de transición de CANESM2 de CMIP5 y CANESM5 de CMIP6.	70
A16. Matrices de probabilidades de transición de GFDL-ESM2M de CMIP5 y GFDL-ESM4 de CMIP6.	70

Resumen

La cantidad de datos climáticos aumenta continuamente en volumen y complejidad a la vez que lo hace el número de usuarios dentro de la comunidad científica y su público. En este contexto, las técnicas de procesamiento de señales permiten resumir el contenido y facilitan su utilización en múltiples aplicaciones. El objetivo de este trabajo está orientado al tratamiento de señales (en concreto series temporales de situaciones atmosféricas a escala sinóptica) y su clasificación y agrupamiento en conjuntos más sencillos que facilitan su análisis e interpretación.

Para ello se implementarán una serie de métodos estadísticos de tratamiento de datos relacionados con las técnicas de segmentación o *clustering*, las cuales se aplicarán a señales correspondientes a Modelos Climáticos Globales (GCMs) con el fin de crear patrones de tiempo (clusters), agrupando las señales más similares entre sí. La comparación de los clusters extraídos de los modelos con los de productos de reanálisis (pseudo-observaciones) permite evaluar la capacidad de los GCMs para representar de manera fidedigna la circulación atmosférica de larga escala. Esta validación resulta de gran interés para las aplicaciones del ámbito de las técnicas de regionalización del clima y de estudios de cambio climático, donde la elección de un GCM u otro tiene un gran impacto en los resultados finales.

Palabras clave: señales climáticas, técnicas de clustering, tipos de tiempo de Lamb, modelos climáticos globales, reanálisis.

Abstract

The amount of climate data is constantly expanding in volume and complexity as the number of users within the scientific community and its public increase. In this context, signal processing allows summarizing the data and facilitate its use in multiple applications. The aim of this work is oriented to the signal processing (in particular, climate time series of atmospheric situations at a synoptic scale) and their classification into simpler sets that facilitate their analysis and interpretation.

A series of statistical data processing methods related to clustering techniques will be implemented for this purpose. Clustering analysis will be applied to signals from Global Climate Models (GCMs) in order to create climate types, grouping the most similar signals among them. The comparison between the clusters extracted from the models with those from reanalysis products (pseudo-observations) allows to perform an evaluation of the capacity of GCMs to accurately represent large-scale atmospheric circulation patterns. This validation exercise is of paramount importance in climate science applications, such as the application of downscaling techniques in climate change studies, where the choice of the driving GCM has a great impact on the final results.

Keywords: climate signals, clustering techniques, Lamb Weather Types, Global Climate Models, reanalysis.

Introducción

En la actual era digital, el volumen de información y de datos se incrementa día a día desde diferentes fuentes y servicios que han ido apareciendo en las últimas décadas. El cada vez menos reciente concepto de *Big Data* hace referencia a este gran volumen de datos, que aumenta en complejidad a la vez que lo hace la diversidad de las fuentes y servicios que los generan. Las redes de sensores (como el novedoso IoT), las redes sociales o los servicios *Cloud* son algunos ejemplos de servicios que producen gran cantidad de datos y contribuyen a la expansión del *Big Data* (Fahad et al., 2014). Esta expansión conlleva evidentes deficiencias que se convierten en los retos de hoy de las ciencias de la computación: necesidad de altas capacidades de almacenamiento; alta potencia computacional en los equipos; gran volumen de operaciones analíticas, de procesado y de recuperación de los datos que resultan de alta complejidad y duración; etc. Resulta imprescindible idear técnicas que permitan resumir y facilitar la manipulación de la información con el fin de afrontar estos retos, y una de las formas existentes son las técnicas de agrupamiento (o *clustering analysis* en inglés).

El *clustering analysis* es un conjunto de técnicas que trata de clasificar las observaciones en un número determinado de grupos (llamados clusters) basándose en unas reglas de similitud, de manera no supervisada. Su objetivo es definir los clusters de forma que las observaciones dentro del cluster sean más parecidas entre ellas que a observaciones de otros clusters (Anderberg, 1973; Cherkassky y Mulier, 1998). Las técnicas de *clustering* han encontrado aplicabilidad en multitud de campos, como la ingeniería, las ciencias de computación, la medicina, las ciencias sociales y de la tierra e incluso la economía (Har-

tigan, 1975; Everitt et al., 2011). La diversidad de aplicaciones del *clustering* hace ver que éste ocupa una posición importante en la investigación científica. Sin embargo, por la misma razón, el término en sí puede cambiar ligeramente si se utiliza en una aplicación u otra. Según Rui Xu y Wunsch (2005), un determinado algoritmo de *clustering* pensado para resolver un problema concreto en una aplicación específica asume ciertas hipótesis en favor de la aplicación de interés, lo que da lugar a que existan multitud de técnicas de modelización de clusters donde este inevitable sesgo inicial afecta al rendimiento del algoritmo.

En el ámbito de las telecomunicaciones, las técnicas de *clustering* suponen una solución interesante para ciertos problemas de tratamiento de señales. Son utilizadas en aplicaciones de detección de señales, donde se buscan patrones que puedan ser correspondientes a información de la señal y otros correspondientes a ruido aleatorio (*pattern recognition*), como en la implementación de Gu et al. (2008); o en aplicaciones de *data mining* donde se clasifican las secuencias de datos recibidas en función de unas propiedades determinadas, como en Aggarwal et al. (2003). Otro uso popular del *clustering* en Telecomunicaciones está en el enrutamiento dentro de las *Wireless Sensor Networks* (WSNs). El enrutado condicionado a *clustering* proporciona una serie de ventajas para las WSNs, como mayor escalabilidad, agregación de datos, menor carga de datos, menor uso de recursos y energía, mayor robustez, etc. (Liu, 2012).

El uso de las diferentes técnicas de *clustering* es también frecuente en ciencias de la tierra, por ejemplo, en climatología, debido a la recopilación exhaustiva que se realiza cada día de datos meteorológicos en todo el mundo. Las técnicas de *clustering* son utilizadas sobretodo para definir los tipos de circulación (*Circulation Types*, CTs) y tipos de tiempo (*Weather Types*, WTs). Los CTs y WTs proporcionan una clasificación de los patrones de circulación atmosférica en el ámbito de la climatología sinóptica. En otras palabras, se clasifican los diferentes estados atmosféricos dados por la serie temporal de una o varias variables meteorológicas en grupos o clusters (donde cada uno de ellos se correspondería a un CT o WT) teniendo en cuenta su similitud. Más concretamente, los CTs hacen referencia a clusters de variables climáticas como la presión atmosférica en superficie y otras variables (geopotencial, humedad) en niveles altos de la atmósfera, y los WTs hacen referencia a clusters de variables climáticas a nivel de superficie (p. ej.: precipitación,

temperatura en superficie, etc.). Iniciativas internacionales previas (p. ej. Tveito et al., 2016) han definido y detallado estos CTs y WTs en numerosas investigaciones desde 2005.

La aplicación de los tipos de circulación y de tiempo ha proporcionado nuevas percepciones sobre las tendencias climatológicas y las proyecciones climáticas, contituyendo así un método de análisis práctico y significativo en este ámbito. Por ejemplo, Littmann (2000) utiliza los WTs/CTs para obtener una clasificación de la presión atmosférica sobre el dominio del Mar Mediterráneo en 20 grupos o clusters. La secuencia diaria de ocurrencia de estos clusters se usa para explicar la variación de la precipitación en esta región. Por otro lado, Huth et al. (1993) analiza la climatología a escala diaria en los meses de invierno (Diciembre-Febrero) en Praga, obteniendo 44 tipos de tiempo en su análisis. Se utilizan hasta 8 variables para caracterizar la climatología en dicho estudio (como la temperatura media diaria, humedad relativa, velocidad del viento, etc.), por lo que el volumen de datos se escala por un factor de 8. En un estudio posterior, Huth et al. (2008) analiza la evolución de estas técnicas en el marco de la Acción COST733 como una técnica de análisis climatológica y presenta tres tipos de aplicaciones potenciales para los CTs y WTs: en el análisis histórico de la climatología, en el análisis de variaciones presentes del clima y en la evaluación de Modelos Climáticos Globales (*Global Climate Models* o GCMs en inglés).

1.1. Información climática

1.1.1. Modelos Climáticos Globales

Los GCMs se desarrollan desde los años 60 (Manabe y Wetherald, 1967) y contituyen una avanzada y compleja herramienta *software* para la simulación del clima global tanto del pasado como del futuro. Dividen el globo terráqueo en una malla o *grid* tridimensional de datos con una resolución horizontal de unos 200 Km y de 10 a 20 capas atmosféricas en el eje vertical (Figura 1.1), por lo que la cantidad de volumen de datos que generan resulta elevada. Estos modelos se ciñen a una serie de ecuaciones que representan la iteración de los procesos físicos de las diferentes componentes del sistema climático (atmósfera, océano, criósfera y superficie terrestre). En 1995 comienza el *Coupled Model Intercomparison Project* (CMIP), bajo la supervisión del *Working Group on Coupled Modelling* (WGCM), con el fin de producir un *dataset* público constituido por un conjunto de modelos con un for-

mato estandarizado y que arroje información sobre las proyecciones de cambio climático. Desde la creación de CMIP, han tenido lugar múltiples fases de este proyecto: p. ej. la fase 5 o CMIP5 (Taylor et al., 2012) y muy recientemente ha salido a la luz la fase 6 o CMIP6 (Eyring et al., 2016), cuyas simulaciones aún se encuentran en fase de publicación, aunque ya existe una diversidad de modelos disponibles lo que ha permitido el desarrollo de este estudio.




Figura 1.1: Representación de una división típica en malla del globo terráqueo utilizada en la resolución numérica de un GCM. Fuente: NOAA, http://celebrating200years.noaa.gov/breakthroughs/climate_model/AtmosphericModelSchematic.png

Todos los modelos incluidos en los proyectos CMIP5 y CMIP6 contienen, por un lado, simulaciones de variables climáticas desde 1850 hasta 2005 en el caso de CMIP5 y hasta 2014 en el caso de CMIP6 (lo que se conoce como escenario histórico) y, a continuación, se extienden durante todo el siglo XXI (lo que se conoce como proyecciones climáticas futuras). Hablando de las simulaciones históricas, se usan habitualmente para evaluar los modelos, evaluar su capacidad de representar procesos y características del clima. Estas

simulaciones tienen en cuenta condiciones variables (consistentes con las observaciones reales) que incluyen influencia de actividad humana sobre el medio ambiente, actividad volcánica y la actividad solar; y proporcionan las condiciones iniciales para los experimentos de escenarios futuros. El informe más reciente del Panel Intergubernamental del Cambio Climático (IPCC, 2014) (*5th Assessment Report, AR5*) se basa en los resultados de CMIP5 y el próximo informe (AR6), que se publicará en 2022, se basará en CMIP6. El IPCC es el órgano internacional de referencia en la evaluación del cambio climático, fundado por el *United Nations Environment Programme* (UNEP) y el *World Meteorological Organization* (WMO) en 1988 para este fin. En su quinto informe (AR5), se definen un conjunto de escenarios caracterizados por diferentes cantidades de gases de efecto invernadero, variaciones en la concentración de aerosoles y suponiendo distintos cambios socio-económicos y demográficos. De esta forma, se da lugar a cuatro diferentes escenarios de cambio climático, los cuales son simulados por los GCMs y son derivados de forzar las condiciones iniciales dependientes de estos múltiples factores. Estos escenarios se denominan *Representative Concentration Pathways* (RCP) y dependen del forzamiento radiativo en el año 2100 con respecto al periodo preindustrial: RCP 2.6, RCP 4.5, RCP 6.0 and RCP 8.5. Cada uno de estos escenarios hace referencia a una existencia de menor a mayor, respectivamente, concentración de aerosoles, gases de efecto invernadero, etc., donde el escenario RCP 2.6 sería el más optimista y el RCP 8.5 el más pesimista.

1.1.2. Regionalización del clima

A pesar de la importancia de representar el sistema climático de forma global por parte de los GCMs, existen limitaciones en los mismos, como por ejemplo su resolución horizontal demasiado grosera (cientos de kilómetros) que impiden su aplicación a escala local. Con el fin de solucionar este problema, se han desarrollado técnicas de regionalización (*downscaling* en inglés) de dos tipos: dinámicas y estadísticas. Los métodos de regionalización dinámica se basan en los Modelos Climáticos Regionales (RCMs, Giorgi (2006); Feser et al. (2011)), que simulan las características físicas del clima, definidas por las condiciones iniciales y de frontera de los GCMs, con mayor resolución sobre un área concreta (Figura 1.2). Sin embargo, el resultado de estos RCMs contiene importantes sesgos regionales heredados de los GCMs de referencia y que, a día de hoy, no existe un método

que los corrija completamente (Christensen et al., 2008; Maraun, 2012). Por otra parte, las técnicas de regionalización estadística se basan en modelos estadísticos empíricos que relacionan las variables de gran escala o predictores (p.ej. presión a nivel del mar), con las variables en superficie medidas a escala local (p.ej. precipitación), que se convierten en la variable dependiente del modelo (ver, por ejemplo, Benestad et al., 2008). Ambas familias de técnicas se apoyan en gran medida en la circulación atmosférica dada por los GCMs, que proporcionan las condiciones iniciales y de frontera (regionalización dinámica) y los predictores (regionalización estadística) para generar proyecciones climáticas. El Coordinated Regional Downscaling Experiment (CORDEX, Giorgi et al. (2009); Jones et al. (2011) supone hoy en día el grupo de trabajo más amplio en cuanto a experimentos de interacción GCM-RCM. Es un proyecto del World Climate Research Programme (WRCP) y su objetivo es proporcionar proyecciones de regionalización en todo el mundo. La sección de EURO-CORDEX se encarga de obtener las proyecciones regionales en el continente europeo.




Figura 1.2: Representación del aumento de la resolución de la malla de un Modelo Climático Regional (RCMs). Fuente: WMO, https://www.wmo.int/pages/themes/climate/climate_models.php

1.1.3. Reanálisis

En otro orden de cosas, los reanálisis son modelos que asimilan datos de observaciones reales para simular la circulación atmosférica global para periodos de tiempo pasados, con el fin de aliviar la escasez de observaciones de ciertas variables atmosféricas en grandes zonas del globo. Por esto, son comúnmente referidos como pseudo-observaciones en el ámbito de la climatología. Pueden extenderse hasta varias décadas atrás en el tiempo, para

lo que asimilan observaciones de estaciones a nivel de superficie, de barcos, boyas, aeronaves y satélites. Proporcionan datos de carácter multivariable, físicamente coherentes entre sí, y difícilmente medibles por otros medios con la resolución temporal y espacial necesarias. El principal objetivo de este tipo de datos es producir un registro homogéneo de la evolución atmosférica pasada, libre de otras señales no climáticas espurias introducidas por cambios en la formulación del modelo, el sistema de asimilación, etc. Sin embargo, cambios en el sistema de observación y la presencia de sesgos temporales y espaciales en los modelos y las observaciones afectan inevitablemente a la representación de las señales climáticas entre los diferentes reanálisis existentes. En otras palabras, pueden existir diferencias entre un reanálisis y otro en ciertas regiones y periodos de tiempo (Brands et al., 2013). En este trabajo, los reanálisis sirven como referencia pseudo-observacional para evaluar GCMs, de forma que cuanto más fielmente reproduzca el modelo las situaciones atmosféricas a escala sinóptica del reanálisis, mejor será el modelo.

1.2. *Herramientas de software. El entorno climate4R*

Por lo tanto, los estudios de impactos del clima, de forma general requieren la utilización de diferentes tipos de datos climáticos (por ejemplo, observaciones, reanálisis, proyecciones de cambio climático), que deben ser obtenidos de diferentes fuentes, requiriendo un importante esfuerzo para su acceso, armonización y post-proceso por parte del usuario (por ejemplo, corrección de sesgos, geo-localización, ajuste temporal de las series etc.), las cuales son tareas propensas a errores que consumen mucho tiempo y requieren el desarrollo de código específico así como el uso de diferentes programas especializados, que involucran la utilización de herramientas diversas de software en cada etapa del flujo de trabajo, lo que a menudo dificulta la reproducibilidad y la comparabilidad de resultados.

Recientemente, `climate4R`¹ (Iturbide et al., 2019), desarrollado por el Grupo de Meteorología de la Universidad de Cantabria, se ha erigido como un entorno de trabajo de creciente utilización basado en lenguaje R (R Core Team, 2020), orientado a servicios climáticos, que busca aglutinar bajo un mismo paraguas los diferentes procedimientos necesarios en estudios de clima, desde el acceso a los datos hasta su procesamiento y

¹<https://github.com/SantanderMetGroup/climate4R>

visualización, pensando en las necesidades de un amplio abanico de usuarios de datos climáticos.

`Climate4R` implementa un modelo común de datos compatible con dos tipos de estructuras de datos climáticos básicas: en malla (o *grid-boxes* en inglés) y en estaciones meteorológicas o localizaciones puntuales. Todos los *datasets* o *grids* de observaciones, reanálisis, predicción estacional o proyecciones climáticas (a los cuales se puede tener acceso a través de `climate4R`) siguen una estructura de metadato compatible propia. Así, `climate4R` supone una herramienta de tratamiento de señales climáticas potente al contener cerca de 100 funciones software repartidas en 4 paquetes centrales: `loadR` (Cofiño et al., 2018; Iturbide et al., 2019), que contiene principalmente funciones de acceso a datos climáticos; `transformR` (Iturbide et al., 2019), que se centra en la transformación, manipulación y conversión de datos, entre otras funcionalidades; `downscaleR` (Bedia et al., 2020), que pone el foco en funciones que ejecutan técnicas de regionalización y corrección de sesgos; y `visualizeR` (Frías et al., 2018), para la visualización de datos climáticos.

Además, existen diversos paquetes adicionales completamente integrados con `climate4R` para tareas en sectores de estudio más específicos, tales como la modelización de distribuciones de especies en estudios de ecología (Iturbide et al., 2018), el cálculo de índices climáticos para el análisis de sequías o riesgo de incendios (p.ej. Bedia et al., 2018), así como un módulo especial para el registro del metadato asociado a productos climáticos (Bedia et al., 2019). La estructura del entorno `climate4R` se esquematiza en la Figura 1.3.

Para este Trabajo Fin de Máster se han implementado una serie de herramientas *software* en lenguaje de programación estadístico R que han servido además como contribución al conjunto de paquetes `climate4R`, extendiendo así sus funcionalidades al análisis de clustering.

1.3. Objetivos

El objetivo principal del trabajo es realizar un análisis estadístico de señales climáticas que sirva para evaluar la capacidad de los GCMs de reproducir la circulación atmosférica en el periodo histórico, analizando las variaciones de los CTs y WTs respecto a los obtenidos de reanálisis o pseudo-observaciones. Para conseguir este objetivo, se ponen en práctica

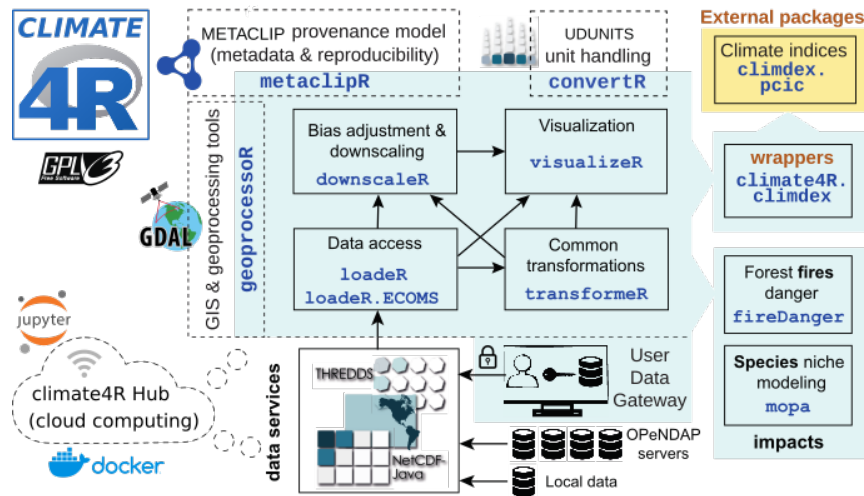


Figura 1.3: Vista esquemática del entorno de trabajo *climate4R*, que consta de tres capas: (a) Servicio de Datos climáticos basados en NetCDF-Java y THREDDS para cargar datos locales o remotos, y también conjuntos de datos del servicio de datos climáticos del Grupo de Meteorología de Santander (User Data Gateway, UDG); (b) Núcleo de paquetes básicos de R para acceso a datos y posproceso, formado por cuatro paquetes principales para la carga de datos, transformación, regionalización, ajuste de sesgos y visualización. Estos paquetes centrales son la base de otros paquetes específicos orientados a estudios de impacto sectoriales, que extienden así las funcionalidades de *climate4R* a aplicaciones concretas. (c) Paquetes externos, conectados mediante funciones adaptadas al modelo de datos de *climate4R*. (d) Paquetes climáticos adicionales que otorgan funcionalidad extendida, incluyendo registro de metadato (“provenance”) y control y transformación de unidades (basado en el software UDUNITS). Las flechas indican los posibles flujos de datos y el sombreado azul destaca los desarrollos internos. Todos los componentes se distribuyen bajo Licencia Pública General GNU. Los logotipos de THREDDS, NetCDF-Java y UDUNITS son cortesía de UCAR / Unidata. El logo R es ©2016 The R Foundation. El icono RDF utilizado por METACLIP es ©1994-2006 W3C. La figura ha sido tomada del repositorio oficial de *climate4R* en <https://github.com/SantanderMetGroup/climate4R>

dos aplicaciones de la utilización de técnicas de *clustering* en climatología. La primera es la obtención de CTs y WTs para una señal de un periodo histórico y la realización de un análisis climático de los mismos; y la segunda es la evaluación de los modelos o GCMs basándose en la comparación de clusters de modelos y reanálisis. Esta validación de los modelos es importante de cara a confiar en sus proyecciones o simulaciones del periodo futuro. Existen estudios previos que exploran esta aplicación de evaluación de los GCMs (Perez et al., 2014; Belda et al., 2015; Ahmadalipour et al., 2017; Otero et al., 2018; Cannon, 2020) donde la variedad de técnicas de *clustering* utilizadas es extensa. Sin embargo, a diferencia de los anteriores estudios, en este Trabajo de Fin de Máster se presenta un análisis más detallado a escala continental Europea, considerando un conjunto de modelos

de última generación, como paso previo al desarrollo de experimentos de regionalización que se encuentran actualmente en fase de diseño experimental (la nueva generación de EURO-CORDEX).

Este Trabajo de Fin de Máster se ha desarrollado en el Grupo de Meteorología de la Universidad de Cantabria (www.meteo.unican.es). La contribución de este trabajo a `climate4R` se basa en la implementación de funciones utilizadas para automatizar el tratamiento de series temporales climáticas aplicando técnicas de segmentación (*clustering*) y clasificación de situaciones meteorológicas, que constituyen la metodología de este trabajo.

Este trabajo se enmarca dentro del proyecto INDECIS, aunque también tiene relevancia dentro de las actividades del proyecto AfriCultuRes. INDECIS (*Integrated approach for the development across Europe of user oriented climate indicators for GFCS high-priority sectors*, <http://www.indecis.eu>), centra su investigación principalmente en la creación de indicadores climáticos (índices de circulación, de impacto, de teleconexión, etc.) sobre la región europea, que ayuden a terceros en sectores como la agricultura, la reducción de los riesgos de desastre, la energía, la salud, el agua y el turismo. En concreto, el trabajo de este Trabajo de Fin de Máster contribuye al Work Package 5 (WP5), que se centra en la relación de los índices con la circulación atmosférica y su evolución temporal. Para INDECIS, el desarrollo de clasificaciones de situaciones atmosféricas para el cálculo de índices y patrones de circulación es de gran relevancia. Encontrar relaciones entre la circulación atmosférica y los impactos locales (cuantificados mediante índices de impactos) permitiría mejorar la monitorización y predicción de dichos impactos. El proyecto AfriCultuRes *Enhancing Food Security in AFRICan AgriCULTUral Systems with the Support of REMote Sensing* (<http://www.africultures.eu>), dentro del programa europeo Horizonte 2020, tiene como objetivo diseñar, implementar y probar un sistema de monitorización agrícola y de alertas que pueda dar soporte en la toma de decisiones en cuanto a seguridad alimentaria, por lo que también se beneficia de los resultados de este trabajo.

La organización del Trabajo de Fin de Máster es la siguiente. En el capítulo 2 se define la metodología de clasificación de situaciones atmosféricas a seguir en los capítulos siguientes. En el capítulo 3, se obtienen los patrones de circulación (CTs y WTs) para un conjunto de GCMs y se procede a la evaluación de los mismos frente a datos de reanálisis. Finalmente, en el capítulo 4 se exponen las conclusiones y el trabajo futuro.

Métodos de clustering: descripción e implementación

Existe una gran variedad de tipos de técnicas de *clustering* las cuales se clasifican teniendo en cuenta multitud de criterios más allá del dominio o campo de aplicación. Por ejemplo, una forma general de clasificar las técnicas de agrupamiento en dos familias es teniendo en cuenta la naturaleza de sus reglas de “similitud”. Así, se clasifican las técnicas de agrupamiento en *objetivas* o *subjetivas*. Las técnicas *objetivas* se caracterizan en que sólo se basan en los propios datos para definir las normas que generan los clusters. Al contrario, las técnicas *subjetivas* se valen de conocimiento técnico específico sobre la aplicación concreta para establecer las normas de clasificación de los datos.

Otra forma general de clasificar las técnicas de agrupamiento es en técnicas de *aprendizaje supervisado* y *no-supervisado*. En el *aprendizaje no-supervisado* se intenta descubrir una estructura subyacente en los datos. Suelen ser procesos iterativos donde la estructura de clusters que se intenta descubrir va cambiando en el proceso. En el *aprendizaje supervisado* esta estructura ya es conocida *a priori*, es decir, se dan una estructura de clusters desde el inicio que permite clasificar los nuevos individuos en alguno de los subgrupos existentes. Una conocida clasificación de las técnicas *aprendizaje no-supervisado* se establece en base a su carácter jerárquico o particional, según las características del algoritmo seguido para contruir los clusters.

En este trabajo, se van a describir cuatro técnicas de agrupamiento populares en el campo de la climatología sinóptica, que son representativas de los tipos de familias de algoritmos objetivos y subjetivos, no-supervisados y jerárquicas o particionales: K-medias

(Hastie et al., 2001), jerárquico (Gordon, 1987), mapas auto-organizativos (Kohonen, 1982) y el método de Lamb (Lamb, 1972).

Se han implementado estas cuatro técnicas de *clustering* utilizando el lenguaje de programación estadístico de software libre R (R Core Team, 2020). La idea es automatizar el tratamiento de los datos (series temporales climáticas) y la obtención de los resultados gracias a una serie de herramientas *software* que ejecuten estos métodos y otras funciones auxiliares.

2.1. Técnicas de agrupamiento objetivas

2.1.1. K-medias

El algoritmo K-medias (*k-means* en inglés) (Hastie et al., 2001) pertenece a la familia de las técnicas de agrupamiento no-supervisado y de carácter particional, basada en centroides (“promedio de los elementos que componen cada grupo”). En el algoritmo K-medias conocemos de antemano el número de grupos que queremos obtener.

El objetivo del algoritmo K-medias es obtener un número de K grupos o clusters, dando previamente el número de grupos que queremos generar. Los grupos C_1, \dots, C_K contienen los índices de las observaciones pertenecientes a cada cluster. La idea detrás de K-medias es que un agrupamiento es bueno cuando la variabilidad intra-grupos $W(C_k)$ es lo más pequeña posible. Por otra parte, la variabilidad entre-grupos es una medida de cuánto difieren las observaciones pertenecientes a un grupo de las de otro. Con la ecuación 2.1 se representa el problema que K-medias resuelve:

$$\underset{C_1, \dots, C_k}{\text{minimize}} \left\{ \sum_{k=1}^K W(C_k) \right\} \quad (2.1)$$

Dicho de otro modo, la ecuación 2.1 indica que queremos dividir las observaciones en K grupos (*clusters*) de modo que se minimice la suma total de la variabilidad en cada cluster. Para resolver 2.1, debemos definir una medida de dicha variabilidad. La métrica más comúnmente utilizada es el cuadrado de la distancia Euclídea. Es decir, definimos la

siguiente métrica de variabilidad intra-grupo:

$$W(C_k) = \frac{1}{|C_k|} \sum_{i \in C_k} \sum_{i' \in C_k} d(x_i, x_{i'}), \quad (2.2)$$

donde $|C_k|$ denota el número de observaciones en el cluster 'k-ésimo'. Por tanto, la variabilidad intra-cluster es la suma de todas las distancias Euclídeas entre todos los pares de observaciones $d(x_i, x_{i'})$ dentro de ese cluster, dividido por el número total de observaciones dentro de ese cluster. La combinación de las ecuaciones (2.1) y (2.2) enuncia el problema de optimización que debe resolver el algoritmo K-medias:

$$\text{minimize}_{C_1, \dots, C_k} \left\{ \sum_{k=1}^K \frac{1}{|C_k|} \sum_{i \in C_k} \sum_{i' \in C_k} d(x_i, x_{i'}) \right\} \quad (2.3)$$

Este algoritmo se caracteriza por tener una inicialización aleatoria del proceso de obtención de los clusters. Esto implica que si se ejecuta el algoritmo repetidas veces, se obtendrán resultados diferentes en cada realización.

El mecanismo con el que opera K-medias para agrupar todas las observaciones satisface dos propiedades: Todas las observaciones están asignadas a un cluster; y dichos clusters nunca se solapan, es decir, ninguna observación puede pertenecer a más de un cluster.

Las principales ventajas que presenta esta técnica son su sencillez y su rapidez en la obtención de un resultado. Además, la representación de la solución con centroides proporciona una interpretación gráfica y estadística inmediata de la misma. Por otro lado, el inconveniente más importante del algoritmo K-medias es la propia necesidad de determinar *a priori* el número de clases, K , que se va a obtener, ya que puede no conocerse el número óptimo de clases con anterioridad. En Gutiérrez et al. (2004b) y Bermejo y Ancell (2009) se aplica el algoritmo K-medias en climatología.

2.1.2. Jerárquico

Las técnicas de agrupamiento jerárquico se corresponden con algoritmos iterativos que pueden ser de dos tipos: técnicas *aglomerativas*, que proceden uniendo individuos o pequeños clusters sucesivamente; y técnicas *divisivas*, que dividen grandes clusters en subgrupos cada vez más pequeños (Gutiérrez et al., 2004a).

A diferencia de K-medias, en este tipo de técnicas de agrupamiento no se requiere de antemano el número de grupos o clusters. En este caso se obtiene un diagrama con estructura de árbol, denominado “dendrograma”, que permite visualizar en un solo diagrama el agrupamiento obtenido para cada número posible de grupos, desde 1 hasta n , siendo n el número total de observaciones (Gordon, 1987).

Para el tipo de clustering jerárquico conocido como “aglomerativo” o “de abajo hacia arriba” (en referencia al hecho de que normalmente se representa como un árbol boca-abajo), se comienza a elaborar por las hojas y va combinando clusters para formar ramas de forma progresiva hasta llegar a un tronco común. En otras palabras, para cada paso se unen los individuos o clusters que estén más cerca entre sí. Existen varios tipos de métodos diferentes para esta técnica de agrupamiento: *Single linkage* (Sneath, 1957), *Complete linkage* (Sorensen, 1948) o *Centroid linkage* (Sokal, 1958), entre otros. La diferencia entre estos métodos reside en la forma de cómo se define el concepto de diferencia (o semejanza) entre los individuos y los clusters. Para *Single linkage*, la distancia entre clusters se entiende como la distancia más pequeña entre dos observaciones, una de un cluster y otra de un clusters diferente; en *Complete linkage* se tiene en cuenta la distancia más grande entre dos observaciones de dos clusters distintos; y en *Centroid linkage* se toma como distancia la media de todos los pares de observaciones.

En cuanto al tipo de agrupamiento jerárquico conocido como *divisivo*, se comienza con una única clase o cluster que contiene las n observaciones y en cada paso del algoritmo se divide el cluster existente en dos. Son varios los algoritmos que buscan esta división global de forma óptima, sin embargo, son bastante costosos y complicados computacionalmente. Esto supone la principal desventaja del tipo de técnicas divisivas con respecto a las aglomerativas, lo que las hace menos populares.

Para más información sobre ambos tipos de agrupamiento jerárquico se recomienda consultar Anderberg (1973); Gordon (1987) o Everitt et al. (2011). Además, en Kalkstein et al. (1987) se exploran las aplicaciones de los métodos jerárquicos aglomerativos en la clasificación climatológica sinóptica.

2.1.3. Mapas auto-organizativos (SOM)

El algoritmo de los mapas auto-organizativos o SOM (*Self-Organized Maps* en inglés) (Kohonen, 1982) es uno de los métodos de aprendizaje no supervisado más utilizados. En SOM no se conocen las clases o clusters *a priori* para luego asignar individuos a un cluster u otro, sino que se crea una “red” bidimensional de clusters siguiendo un conjunto de reglas internas en un proceso iterativo. Everitt et al. (2011) señalan que el procedimiento de SOM es comparable con el de otras técnicas de agrupamiento más convencionales, como K-medias, pero con una característica añadida importante: los centroides que forman la red bidimensional son forzados a reorganizarse en cada iteración, siguiendo una segunda regla de similitud.

La red regular 2D generada por SOM está formada por un número arbitrario de clases $k = s \times t$. El vector $\mathbf{p}_m = (i, j)$ representa la posición de la clase m sobre la red 2D, donde $1 \leq i \leq s$, $1 \leq j \leq t$. De forma similar a K-medias, cada una de las clases tiene asociado un vector de pesos, que representa la posición del centroide de la clase sobre el espacio de observaciones. Otra similitud con el algoritmo K-medias es que los vectores de la SOM se inicializan de manera aleatoria. El objetivo de SOM es adaptar iterativamente los vectores de pesos, para que el centroide final represente al conjunto de datos de la clase, es decir, los que están más cerca de ese centroide.

Lo que diferencia a SOM de otros algoritmos es que, en el resultado final, las clases o clusters más cercanos entre sí en el espacio 2D son también las que más se parecen en el espacio de los datos, mientras que las clases más alejadas en la red 2D son las que menos se parecen en el espacio de los datos. Esto supone una de las principales ventajas de SOM. Que la red 2D de clusters esté organizada facilita más el manejo de la clasificación final al conformar una representación visual del espacio de los datos, lo que hace a SOM una técnica competitiva especialmente indicada para trabajar en espacios de alta dimensionalidad.

Ripley (1996) hace referencia a este método dentro de su investigación sobre aplicaciones de técnicas de redes neuronales y lo incluye en dicho contexto a pesar de ser un método de aprendizaje no supervisado, en contraposición con otros métodos más convencionales de redes neuronales. Estudios como el de Cavazos (1997), Hewitson y Crane (2002)

o Gutiérrez et al. (2005) exploran la aplicación de SOM en el campo de la climatología sinóptica, utilizándose esta técnica para la obtención de CTs y WTs.

2.2. Técnicas de agrupamiento subjetivas: Tipos de tiempo de Lamb

Las técnicas de agrupamiento presentadas hasta ahora tienen en común que son métodos de aprendizaje objetivos, donde la clasificación en clusters tiene una componente aleatoria o estocástica. La clasificación en tipos de tiempo de Lamb (*Lamb Weather types en inglés*, LWTs) es un método subjetivo de *clustering* y se basa en reglas que derivan de un conocimiento técnico experto y específico de meteorología (Lamb, 1972). Como método de *clustering* específico para ser usado en climatología, su objetivo es sintetizar una serie de situaciones meteorológicas diarias en clases o clusters de circulación sinóptica. Estos LWTs suponen uno de los métodos de *clustering* más populares en climatología para la obtención de CTs y WTs debido a que sus fundamentos se establecen sobre una interpretación física determinista y bien definida de la atmósfera. El uso de LWTs frente a CTs obtenidos con otros métodos de *clustering* supone una ventaja para los objetivos de este trabajo. La interpretación de los resultados obtenidos aquí tendrá como trasfondo unas condiciones meteorológicas reales, eliminando así la incertidumbre inherente al uso de algoritmos estocásticos de agrupamiento, cuyo comportamiento depende de sus condiciones de inicialización.

De acuerdo con otros estudios que utilizan LWTs (Trigo y DaCamara, 2000; Brands et al., 2014; Ramos et al., 2014; Pereira et al., 2018), se clasifican todos los días de la serie temporal en 26 clases diferentes, donde cada una se corresponde con un tipo de circulación atmosférica o CT. A continuación se describe el modo en el que se obtienen los 26 LWTs. En primer lugar, se toma una malla de 16 localizaciones centrada bien en las Islas Británicas como en su definición original (Jones et al., 1993) (55°N, 5°W), o bien en la Península Ibérica sobre Portugal (Trigo y DaCamara, 2000) (40°N, 10°W) o sobre España (Brands et al., 2014) (40°N, 5°W) o bien sobre los países nórdicos (Chen, 2000) (60°N, 15°E). Entre los puntos de la malla adyacentes existe una separación de 5° de latitud y 10° de longitud (Jenkinson y Collison, 1977). A diferencia de las otras técnicas de clustering, con las que se pueden crear clusters aplicando distintas variables al mismo tiempo, LWTs exige

usar únicamente valores de presión atmosférica en superficie (*Sea Level Pressure*, SLP). Con estos datos se calculan 6 parámetros relacionados con las características del flujo del viento: flujo meridional, flujo occidental, flujo total, vorticidad de corte meridional, vorticidad de corte occidental y vorticidad de corte total. En función de sus valores, el SLP diario se clasifica en un tipo de tiempo determinado. Los 26 LWTs se denominan de la siguiente forma: se definen 10 clases “puras”, denominadas por los 8 puntos cardinales (NE, E, SE, S, SW, W, NW, N) más un tipo Ciclónico y otro Anticiclónico (C y A); y se definen 16 clases “híbridas”, 8 para C y otros 8 para A (ver Jones et al. (2013) para más detalles sobre esta definición).

2.3. Contribución a *climate4R*

2.3.1. Implementación de los métodos

Parte de la contribución de este Trabajo de Fin de Máster es la implementación de los métodos de clustering descritos en la sección 2.1 y 2.2 dentro del *software* de tratamiento de datos climáticos *climate4R*. De entre las funciones implementadas en este trabajo, destaca la función denominada `clusterGrid`, que supone el núcleo de la aplicación de las diferentes técnicas de *clustering* dentro de *climate4R* y se incluye dentro de paquete `transformer`. Esta función es un *wrapper* de otras funciones en R que implementan los algoritmos K-medias, jerárquico y SOM y de una implementación propia de Lamb WTs. Para el caso de K-medias y jerárquico se utilizan las funciones `kmeans` y `hclust` del paquete `stats` (v3.6.3, R Core Team, 2020). Para SOM, se usa la función `somgrid` disponible en el paquete `Kohonen`(v3.0, Wehrens y Kruisselbrink, 2018). Para Lamb, se crea un *script* propio dentro de `transformer` siguiendo el procedimiento descrito en Jones et al. (2013). El *input* principal de `clusterGrid` es un *grid* de formato *climate4R*, el cual puede contener una o varias variables climáticas (*multigrid*) e incluso varias realizaciones o miembros de un conjunto o *ensemble* de modelos. De entre las operaciones de pre-procesado (antes de ejecutar el *clustering*) destaca el “escalado” de las variables, operado internamente por la función `scaleGrid`, con el objetivo de estandarizar las variables y ser elegibles para crear clusters; y la extracción de los puntos que forman la malla de datos necesaria en Lamb (Sección 2.2) a partir de la cual se obtiene la clasificación. Se muestran ejemplos de la

aplicación de estos métodos en la Sección 2.3.2.

Además de crear clusters de un determinado *dataset* escogiendo un algoritmo determinado, `clusterGrid` tiene una segunda funcionalidad, predecir o proyectar tipos de tiempo para un nuevo *grid* a través del argumento `newdata` en base a una clasificación previa con otros datos de entrenamiento. Con esta funcionalidad se pretende cumplir con el objetivo de proyectar tipos de tiempo para datos meteorológicos de un periodo de tiempo diferente permitiendo la aplicación de `clusterGrid` en el contexto de predicción estacional y proyecciones de cambio climático. Para esto es necesario haber ejecutado primeramente un análisis de clustering para unos datos de referencia o entrenamiento. La salida de `clusterGrid` será un nuevo *grid* que contendrá información sobre los tipos de tiempo de “entrenamiento” obtenidos en un atributo llamado `wt.index`, que se usarán para asignar, por similitud, un cluster a cada elemento de `newdata`. De esta forma, es posible crear grupos o clusters a través de otra clasificación de referencia, lo cual tiene aplicación en la proyección o predicción de tipos de tiempo. Para más detalles sobre la función `clusterGrid`, ver <https://github.com/SantanderMetGroup/transformeR/wiki/Clustering>.

2.3.2. Ejemplos de aplicación de los métodos

A continuación, se proporciona un ejemplo de análisis de tipos de circulación y de tiempo a través de la función `clusterGrid`, demostrando el potencial de esta función *software* como herramienta de procesado de señales climáticas en el ámbito de la climatología sinóptica. Se utiliza presión atmosférica a nivel del mar del reanálisis *National Centers for Environmental Prediction / National Center for Atmospheric Research* (NCEP-NCAR) (en adelante NNRP, Kalnay et al., 1996) sobre el dominio espacial de la Península Ibérica (PI) en los años 1983-2002 como conjunto de datos para obtener 10 CTs (o clusters) aplicando las técnicas de agrupamiento K-medias, Jerárquico y SOM. Para más detalles sobre el procedimiento seguido y el código utilizado en estos ejemplos, ver <https://github.com/SantanderMetGroup/transformeR/wiki/Clustering-Algorithms>.

En la Figura 2.1 se observan los clusters obtenidos del conjunto de datos de NNRP tras aplicar el algoritmo K-medias. Cada uno de los sub-paneles representa uno de los 10 centroides resultantes. Se observan clusters con muestras de altas presiones en todo el dominio (predominan los colores rojo y naranja) y otros donde predominan las presiones

Clusters de SLP sobre Europa – NNRP (K-medias)




Figura 2.1: Representación de 10 Tipos de Circulación obtenidos aplicando el algoritmo K-medias a partir de datos de SLP del reanálisis NNRP de los meses de invierno en los años 1983-2002

bajas (clusters 9 y 10). Otros clusters, por ejemplo, muestran presiones bajas solo en el norte de la PI (cluster 2 y 8) o al este de la PI (cluster 3). En el caso de aplicar el algoritmo de agrupamiento jerárquico (Figura 2.2), se obtiene que la clasificación óptima por defecto está formada por 5 clusters. Mientras se utilice el algoritmo jerárquico, si el número de clusters no se proporciona (como en el ejemplo), éstos se establecen automáticamente y el dendograma se corta cuando la diferencia de altura entre dos clusters consecutivos (ordenadas en orden ascendente) es mayor que el rango intercuartílico del vector de alturas del dendograma (ver panel derecho de la Figura 2.2). A grandes rasgos, los clusters obtenidos concuerdan con la clasificación basada en K-medias. En el cluster 2 en la Figura 2.2 predominan las presiones altas y en el cluster 5 las presiones bajas, como en el cluster 1 y 10, respectivamente, de la Figura 2.1. Al centrarse en la Figura 2.3, que muestra los 10




Figura 2.2: Representación de 5 Tipos de Circulación (izquierda) y dendrograma (derecha) obtenidos aplicando el algoritmo jerárquico a partir de datos de SLP del reanálisis NNRP de los meses de invierno en los años 1983-2002. En el dendrograma se muestran con diferentes colores los datos pertenecientes a diferentes clusters.

clusters obtenidos con SOM para el subconjunto de NNRP, se observa que los centroides son muy similares a los obtenidos con K-medias (Figura 2.1), pero ordenados en el espacio. En otras palabras, en SOM, para cada cluster n , los clusters $n+1$ y $n-1$ son los que maximizan la similitud con n .

Los Tipos de Tiempo de Lamb se representan en la Figura 2.4. En este caso, se utiliza el reanálisis ERA-Interim (Dee et al., 2011) sobre Europa en los años 1981-2010 para calcular Tipos de tiempo de Lamb, como en el caso de estudio del capítulo 3. El uso de un dominio espacial diferente es necesario debido a las condiciones iniciales del algoritmo, que necesita tener las 16 localizaciones definidas en la Sección 2.2 como entrada. Las localizaciones se centran sobre las Islas Británicas. Los LWTs proporcionan resultados más interpretables desde el punto de vista climático que el resto de técnicas mencionadas, lo cual supone la principal ventaja del algoritmo. Además de que la propia técnica se basa en conocimiento técnico experto y bien definido sobre la atmósfera, en la Figura 2.4 se observan patrones de presión atmosférica sobre las Islas Británicas, representados por los centroides de los LWTs, y que están en relacionados con el nombre del propio cluster.

Clusters de SLP sobre Europa – NNRP (SOM)




Figura 2.3: Representación de 10 Tipos de Circulación obtenidos aplicando el algoritmo SOM a partir de datos de SLP del reanálisis NNRP de los meses de invierno en los años 1983-2002

En la Figura 2.4 se muestran los 8 LWTs con mayor frecuencia de ocurrencia obtenidos de ERA-Interim, suponiendo el 74 % de los días totales. De acuerdo con Trigo y DaCamara (2000); Brands et al. (2014); Fealy y Mills (2018), los LWTs más frecuentes para esta región son el Anticiclónico (A) y el Ciclónico (C), seguidos por tipos de flujo del Oeste (W, SW, NW y AW) y los tipos Sur (S) y Norte (N).

Hasta aquí se ha visto cómo la función `clusterGrid` supone una herramienta útil para el análisis de tipos de tiempo (WTs). Desde el inicio de este trabajo, se presentaba el objetivo de explorar más exhaustivamente las aplicaciones de análisis de WTs, en parti-

cular, en el estudio de la climatología sinóptica. A partir de ahora, se comienza un caso de estudio de validación de Modelos Climáticos Globales o *GCMs* a partir de WTs. La función `clusterGrid` es utilizada como principal herramienta de computo de los Tipos de Tiempo, por lo que cobra especial importancia para el desarrollo de este trabajo. El estudio se centra en analizar en profundidad los Tipos de Tiempo de Lamb, ya que proporcionan resultados más interpretables desde el punto de vista climático. Estos resultados se describen en el capítulo 3.

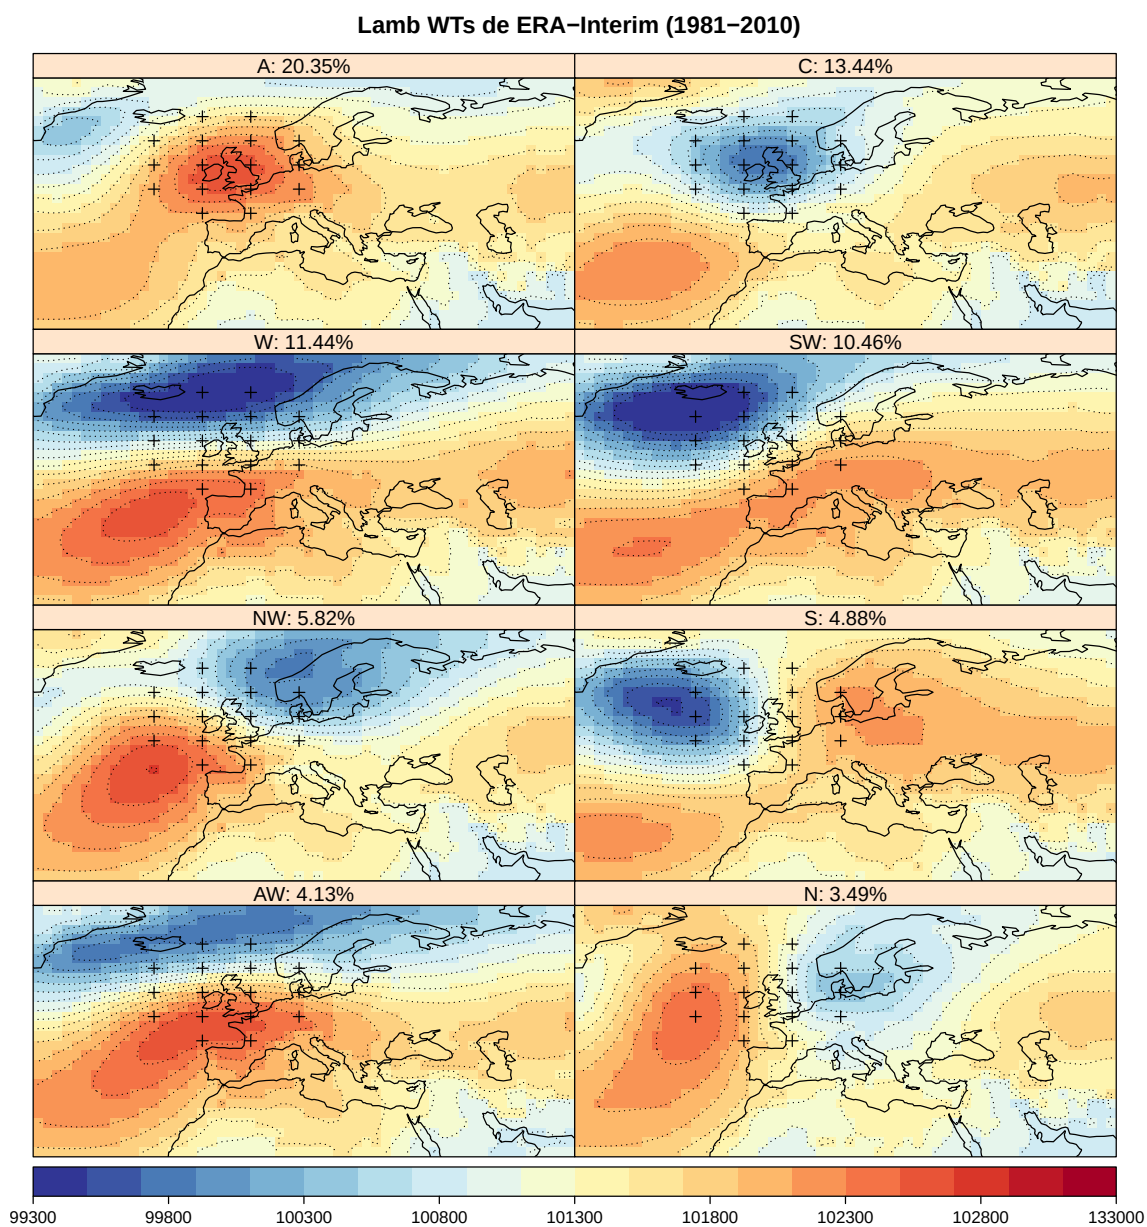


Figura 2.4: Representación de 8 Tipos de Circulación obtenidos aplicando el método de Lamb a partir de datos de SLP del reanálisis ERA-Interim en los años 1981-2010 sobre Europa, centrandolo las 16 localizaciones de inicio sobre las Islas Británicas. Los LWTs mostrados son los más frecuentes dado el conjunto de datos, mostrando su nombre abreviado y la frecuencia del LWT en la parte superior del mismo. La leyenda está centrada en el valor medio de presión atmosférica a nivel del mar (101300Pa).

Caso de estudio: Evaluación de la circulación atmosférica

La variabilidad estacional de los patrones a gran escala de presión atmosférica ejerce una influencia directa sobre el clima regional europeo. Por ejemplo, el patrón de la Oscilación del Atlántico Norte (NAO, Hurrell et al., 2003; Folland et al., 2009) y las situaciones de bloqueo provocados por la persistencia de sistemas de altas presiones (Jury et al., 2019) tienen influencia sobre los eventos de temperaturas extremas (Buehler et al., 2011; Barriopedro et al., 2011; Favà et al., 2015), precipitaciones intensas (Busuioc et al., 2001; Casanueva et al., 2014; Sousa et al., 2017) o sequías (Bladé et al., 2011). Esto se debe a su capacidad de alterar el flujo ciclónico predominante del oeste (Sillmann y Croci-Maspoli, 2009), que es el que fundamentalmente determina las condiciones climáticas del continente europeo. La representación adecuada de la circulación atmosférica y de la variabilidad de los sistemas de presiones es esencial para la reproducción apropiada de los principales eventos climáticos regionales. Los actuales Modelos Climáticos Globales (GCMs) muestran errores esenciales en esta representación (Vial y Osborn, 2012; Dawson et al., 2012; Masato et al., 2013).

Los sesgos en la circulación atmosférica simulada por los modelos afectan la frecuencia y duración de los eventos de bloqueo invernal del Atlántico y Europa (Vial y Osborn, 2012; Anstey et al., 2013), que son subestimados sistemáticamente por los modelos globales, en particular, por los modelos de CMIP5 (Taylor et al., 2012). La reproducción de las trayectorias de las borrascas en el hemisferio norte ha mejorado en los modelos de CMIP5 con respecto a los modelos de versiones anteriores de CMIP (Zappa et al., 2013), pero

todavía se subestima la intensidad de los ciclones y permanecen sesgos en la localización de los mismos (Chang et al., 2012; Colle et al., 2013). Del mismo modo, los modelos de CMIP5 son capaces de reproducir los patrones climáticos del Mediterráneo oriental, aunque de forma inexacta (Hochman et al., 2019). La reciente generación de modelos de CMIP6 (Eyring et al., 2016) muestra mejoras notables con respecto a CMIP5 en la reproducción de la frecuencia y la persistencia de los tipos de circulación en todo el mundo (Cannon, 2020), aunque todavía se necesitan análisis que se centren en evaluar adecuadamente las implicaciones que esto puede tener en el contexto de la regionalización del clima (Addor et al., 2016; Perez et al., 2014; Otero et al., 2018).

Las nuevas actividades de EURO-CORDEX (Jacob et al., 2014, 2020) se enmarcan en la regionalización dinámica de los modelos de CMIP6. Para ello es necesario diseñar un nuevo experimento que incluya una selección de los GCMs a regionalizar, ya que sería demasiado costoso computacionalmente producir simulaciones para el conjunto de modelos completo. La selección de GCMs para las actividades de regionalización es un proceso de dos pasos (McSweeney et al., 2015): en primer lugar, se requiere que el modelo ofrezca tendencias plausibles o razonables en variables de superficie, (como la temperatura y/o la precipitación); y, en segundo lugar, conseguir abarcar la mayor variabilidad que ofrecería el conjunto de modelos completo. Simular adecuadamente sólo las variables en superficie es insuficiente y puede dar lugar a una selección poco óptima de GCMs. Por ello es recomendable llevar a cabo una evaluación basada en procesos, considerando las variables climáticas sobre las que se apoya la posterior regionalización (Brands et al., 2013; McSweeney et al., 2015; Addor et al., 2016).

A pesar de que se pueden mejorar los modelos a través de una corrección de los sesgos en las variables de superficie (véase, por ejemplo, Dosio, 2016; Iturbide et al., 2020), resulta problemático eludir los errores fundamentales del modelo, es decir, errores en los procesos a gran escala (como la circulación atmosférica, sequías, trayectoria de borrascas, etc.) (Addor et al., 2016; Maraun et al., 2017). Incluso cuando los métodos de corrección de sesgos mejoran las simulaciones climáticas para aplicaciones concretas, en general, no solucionan la baja calidad del modelo, pudiendo incluso ocultar la falta de credibilidad cuando se aplican inadecuadamente las correcciones (Maraun et al., 2017), dando lugar a malas decisiones en la selección de modelos. En definitiva, la selección del GCM de referencia

tiene un gran efecto en la calidad de las simulaciones del RCM (como se demuestra, por ejemplo, por Prein et al., 2019, en América del Norte), y en las simulaciones de proyecciones climáticas (Turco et al., 2013). La elección del GCM es una cuestión de gran relevancia en los experimentos de interacción GCM-RCM.

En este caso de estudio, se agrupan los patrones de circulación en Europa de la nueva generación de GCMs de CMIP6, los de CMIP5 y los de varios reanálisis, siguiendo el algoritmo de clasificación de tipos de tiempo de Lamb (LWT) (Lamb, 1972). Se evalúan, en primer lugar, los patrones de todos los modelos de ambas generaciones comparándolos con los obtenidos de los reanálisis y, en segundo lugar, se compara el resultado de los nuevos modelos de CMIP6 con su homólogo de la generación anterior (CMIP5), para identificar posibles mejoras. Nos centramos en Europa para abordar el problema de selección de GCMs para aplicaciones de regionalización en el contexto de EURO-CORDEX. En particular, nos proponemos 1) evaluar la posible mejora de los modelos de CMIP6 con respecto a los de CMIP5, en lo que respecta a la reproducción de la frecuencia, la persistencia y la probabilidad de transición entre los tipos de tiempo y 2) proporcionar una clasificación cuantitativa de los modelos, con el fin de dar una solución al problema de selección de modelos sobre Europa. Este trabajo actualiza trabajos anteriores sobre la habilidad de los GCM para representar los tipos de circulación en esta región (Perez et al., 2014; Otero et al., 2018) e introduce las probabilidades de transición de un tipo de tiempo a otro como un método de cuantificación del comportamiento adecuado de los modelos.

3.1. Datos

Aplicamos la técnica de agrupamiento LWT para clasificar patrones de presión diaria atmosférica media a nivel del mar de un conjunto de GCMs correspondientes a los experimentos históricos de CMIP y a los reanálisis (como referencia pseudo-observacional). Para todos los *datasets*, consideramos el período de 30 años 1981-2010, siguiendo las directrices de la *World Meteorological Organization*, WMO, sobre el cálculo de las distribuciones climáticas (WMO, 2017). Este período contiene una muestra de unos 11000 días aproximadamente por conjunto de datos.

3.1.1. Datos de Modelos Globales del Clima

Se utilizan las simulaciones del periodo histórico de un conjunto de GCMs de CMIP5 y el CMIP6 para evaluar ambas generaciones de modelos. Se selecciona un conjunto de 9 pares de modelos aproximadamente equivalentes entre ambos experimentos (Tabla 3.1) para analizar específicamente la mejora de los modelos, primer objetivo de este trabajo. Cada par de GCMs se desarrolla en un centro de simulación diferente.

Dado que las simulaciones históricas de los modelos de CMIP5 terminan en 2005, utilizamos el periodo 2006-2010 del escenario RCP8.5 de cada modelo para completar el período de análisis común 1981-2010. Esto se ha hecho en estudios anteriores (p. ej. Casanueva et al., 2020) y no se espera un impacto en los resultados, ya que la diferencia en el forzamiento de las condiciones RCP de estos escenarios es muy pequeña para el periodo de relleno mencionado.

CMIP5	Grid (°)	CMIP6	Grid (°)	Centro de Simulación (CMIP5) CMIP6
CanESM2	2.81	CanESM5	2.81	Canadian Centre for Climate Modelling and Analysis
CNRM-CM5	1.41	CNRM-CM6-1	1.41	Centre National de Recherches Météorologiques - Centre Européen de Recherche et de Formation Avancée en Calcul Scientifique
EC-EARTH	1.13	EC-EARTH3	0.70	(Irish Centre for High-end Computing) EC-EARTH Consortium
GFDL-ESM2M	2.26	GFDL-ESM4	1.00	NOAA - Geophysical Fluid Dynamics Laboratory
HadGEM2-ES	1.59	UKESM1-0-LL	1.59	Met Office Hadley Centre
IPSL-CM5-LR	2.96	IPSL-CM6A-LR	1.98	Institut Pierre-Simon Laplace
MIROC5	1.41	MIROC6	1.41	(Japan Agency for Marine-Earth Science and Technology, JAMSTEC) JAMSTEC, AORI, NIES and R-CCS
MPI-ESM-LR	1.88	MPI-ESM1-2-LR	1.88	Max Planck Institute for Meteorology
NorESM1-M	2.21	NorESM2-LM	2.21	Norwegian Climate Center - Norwegian Meteorological Institute
		Reanalysis	Grid (°)	Centro de Simulación
		ERA-Interim	0.75	European Center for Medium Range Weather Forecasts
		JRA-55	0.56	Japanese Meteorological Agency
		NNRP	2.5	National Centers for Environmental Prediction / National Center for Atmospheric Research
		ERA-20C	1.13	European Center for Medium Range Weather Forecasts

Tabla 3.1: Conjuntos de pares de modelos de CMIP5 y CMIP6 utilizados en este trabajo, su resolución espacial nominal (Grid) en el Ecuador (en °) y su Centro de Simulación (arriba). Los reanálisis considerados (abajo). Nótese que 1° de resolución equivale aproximadamente a 100km.

3.1.2. Datos de reanálisis

Se utiliza el reanálisis ERA-Interim reanalysis (Dee et al., 2011) del Centro Europeo de Predicción a Medio Plazo (*European Center for Medium Range Weather Forecasts* en inglés, ECMWF) como la principal referencia pseudo-observacional para evaluar los modelos de CMIP. Este reanálisis de última generación es comúnmente utilizado en el contexto de CORDEX para evaluar el comportamiento de los modelos además de proporcionar condiciones de frontera inicial y lateral para las simulaciones de evaluación. Por lo tanto, es natural utilizar ERA-Interim en este caso para evaluar las condiciones de frontera de los GCMs.

Además, se consideran 3 productos adicionales de reanálisis (Tabla 3.1) para tener en cuenta la incertidumbre relacionada con la referencia utilizada en la evaluación (incertidumbre observacional): el reanálisis japonés desarrollado por la Agencia Meteorológica Japonesa *Japanese Meteorological Agency 55-year reanalysis* (JRA-55; Kobayashi et al., 2015; Harada et al., 2016), los productos de reanálisis estadounidense del *National Centers for Environmental Prediction / National Center for Atmospheric Research* (NCEP-NCAR) (NNRP, Kalnay et al., 1996), y el ERA-20C del Centro Europeo (Poli et al., 2016). Las mayores diferencias entre los distintos reanálisis se deben a la naturaleza de los datos observados que incorporan. El ERA-20C únicamente asimila observaciones de presión superficial y vientos marítimos, por lo que no es ciertamente comparable con los otros reanálisis que asimilan una gama más amplia de observaciones de superficie, aéreas y de satélites. Por otro lado, este reanálisis es el único que proporciona registros históricos que se remontan al S. XX, siendo de gran interés para la evaluación de tendencias a largo plazo de los modelos.

3.2. Métodos de evaluación

Con el objetivo de evaluar el grado de exactitud de reproducción de las variables climáticas por parte de los Modelos Globales del Clima o *GCMs*, se utilizarán medidas de validación como las Probabilidades de transición, el Sesgo o Bias Relativo, la divergencia de Kullback–Leibler (*KL*), el Test de Proporciones (*Two-proportions Z-Test* en inglés) y el Índice de Matriz de Probabilidades de Transición (en inglés *Transition Probability Matrix*

Score, *TPMS*). Gracias a la aplicación de estas medidas, se proporciona una comparación directa entre los modelos y datos de reanálisis al obtener un valor cuantitativo del grado de disparidad/ semejanza entre los mismos.

3.2.1. Sesgo Relativo

A partir de los LWTs obtenidos de las series históricas de los modelos con resolución diaria discreta X_1, X_2, \dots, X_T y T días, se calcula la frecuencia de ocurrencia del LWT ℓ por estación s y denotada $f(\ell, s)$ como el número de días con tipo de tiempo ℓ dividido por el total de días de la estación $s \in \{DJF, MAM, JJA, SON\}$. Las siglas *DJF*, *MAM*, *JJA* y *SON* denotan las estaciones de invierno, primavera, verano y otoño respectivamente, de manera que las siglas están formadas por la primera letra de los meses que forman la estación en inglés. Así, se considera el Bias Relativo ε para medir la desviación de la frecuencia de los LWTs de un *datasets* con respecto a los de un *dataset* de referencia:

$$\varepsilon_m(\ell, s) = \frac{f_m(\ell, s) - f_o(\ell, s)}{f_o(\ell, s)} \quad (3.1)$$

donde $f_m(\ell, s)$ se refiere a las frecuencias en el modelo m y $f_o(\ell, s)$ son las frecuencias obtenidas del modelo de referencia, que en este caso se tratará de un reanálisis o pseudo-observaciones.

3.2.2. Divergencia de Kullback–Leibler (KL)

La divergencia de Kullback–Leibler (Kullback y Leibler, 1951) o Entropía Relativa es un concepto de Teoría de la información (Cover y Thomas, 2006) y hace referencia al grado de disparidad o discordancia entre dos funciones de distribución de probabilidad $P(x)$ y $Q(x)$, ambas definidas en el mismo espacio de probabilidades X . Se define de la siguiente forma:

$$KL(P||Q) = \sum_{x \in X} P(x) \log \frac{P(x)}{Q(x)} \quad (3.2)$$

Esta disparidad entre distribuciones de probabilidad es siempre positiva, e igual a cero si y sólo si $P = Q$. En este trabajo, se utiliza la divergencia de KL con el objetivo de

comparar los LWTs obtenidos de un GCM con los obtenidos de varios reanálisis y así poder cuantificar el grado de disparidad de un modelo con respecto a las observaciones. De esta forma, se aplica directamente la divergencia de KL en el campo de la climatología, más concretamente en la evaluación del comportamiento de los GCMs. Para ello, análogamente a los trabajos de Jiang et al. (2011) y Sharma y Seal (2019), es necesario entender una clasificación en clusters obtenida de un algoritmo de *clustering* (en este caso, Lamb) como una función de probabilidad discreta. El número de clusters se corresponde con el número de muestras en el espacio X de la distribución, donde cada muestra lleva asociada una probabilidad que es la frecuencia relativa (en porcentaje) observada de cada cluster. $P(x)$ representa la función de probabilidad discreta de los LWTs obtenidos para los modelos y $Q(x)$ será la de referencia (reanálisis). Así, es posible comparar dos clasificaciones de clusters utilizando la divergencia de KL.

Esta aplicación de la divergencia de KL en climatología está presente en Weijjs et al. (2010) donde se utiliza esta métrica para cuantificar la calidad de las predicciones y proyecciones climáticas. En el mismo estudio se defiende la ventaja de utilizar la divergencia de KL en lugar de distancias euclídeas para esta aplicación, ya que en el caso de contar con probabilidades (frecuencias) extremas el resultado final puede quedar demasiado condicionado por dichos valores. La divergencia de KL ofrece una comparación de distribuciones independiente de las probabilidades de las muestras, lo que supone una ventaja en el caso de probabilidades extremas. Según Jiang et al. (2011), la divergencia de KL es necesaria en la comparación de dos distribuciones de probabilidad por el hecho de que se pueden estar comparando distribuciones diferentes, con elementos muestras de diferente tamaño o con diferentes centros geométricos. En este trabajo, se utiliza la implementación *software* disponible en la paquete en R `phylentropy` (v0.4.0, Drost, 2018).

3.2.3. Test de Proporciones (Z-Test)

El Test de proporciones o Z-Test se utiliza para evaluar la significancia estadística entre la diferencia de dos proporciones. En este caso, se aplica este test en dos ocasiones: en primer lugar, las dos proporciones a las que se les aplica el Z-Test son las frecuencias relativas de los LWTs de cada modelo y los de un reanálisis; y en segundo lugar, para las probabilidades de transición en de los LWTs de un modelo y las de un reanálisis. Se aplica

el Test para combinación de LWT ℓ , estación s y modelo m . En este trabajo, se utiliza la implementación *software* del Z-test disponible en la función `prop.test` del paquete de R `stats` (v3.6.3, R Core Team, 2020).

3.2.4. Probabilidades de Transición

Las probabilidades de transición entre LWTs suponen una medida temporal de gran utilidad para medir la capacidad de los modelos de reproducir los patrones de circulación atmosférica (Hochman et al., 2019). Sea la variable aleatoria discreta X_t que representa un LWT en el *time step* t , con valores posibles $x_t \in \{1, \dots, K\}$ y $K = 26$, el número de LWTs, se consideran los días consecutivos X_{t-1} y X_t para construir la Matriz de Probabilidades de Transición (TPM) A de dimensiones $K \times K$. $A_{ij} = p(X_t = j | X_{t-1} = i)$ representa la probabilidad de pasar de un LWT en la fila i a un LWT en la columna j . Por tanto, la suma de los valores de cada fila de la matriz es igual a 1: $\sum_j A_{ij} = 1$. La TPM supone así una referencia de cómo un modelo determinado reproduce la clasificación en LWTs, y esta puede compararse con la TPM de una referencia pseudo-observacional a través de alguna medida específica de validación (ver Sec. 3.2.5).

3.2.5. Índice de Matriz de Probabilidades de Transición (TPMS)

Con el objetivo de resumir la información obtenida en las Matrices de Probabilidades de Transición (Sec. 3.2.4), se presenta el TPM *Score*, *TPMS* como una métrica que permite ordenar los modelos en base a su comportamiento en las TPM, y se define de la siguiente forma:

$$TPMS = \sum_{p \in A^*} |p_m - p_o| \quad (3.3)$$

donde p_m y p_o son las probabilidades de transición en el modelo y en reanálisis o pseudo-observaciones, respectivamente, cuya diferencia (en valor absoluto) se calcula considerando el subconjunto de probabilidades de transición A^* de la matriz completa (A) que son significativamente diferentes a las del reanálisis, siguiendo los resultados del Z-Test o de Proporciones. Para incluir las transiciones “perdidas” en la puntuación (es decir, las transiciones que existen en el reanálisis pero que no tienen lugar en el modelo, o las

transiciones que son simuladas por el modelo pero que no se producen en el reanálisis), se les asigna una probabilidad cero (es decir, $p_m = 0$ o $p_o = 0$, respectivamente) y se incluyen en el subconjunto A^* . Como resultado, un *Score* igual a cero supone un acuerdo perfecto entre las TPM del modelo y del reanálisis. Cuanto más grande sea este *Score*, mayor será la disparidad de las TPM del modelo y del reanálisis.

3.3. Resultados

3.3.1. Tipos de tiempo observados




Figura 3.1: Comparativa de frecuencias relativas estacionales de Lamb Weather Types (LWTs) obtenidas de los cuatro reanálisis (ERA-Interim, JRA, NNRP y ERA-20C) siguiendo la definición de LWTs de Lamb 1972. Los LWTs están representados en orden decreciente en función de las frecuencias anuales en ERA-Interim, indicado dicho valor con una línea horizontal como referencia para cada tipo de tiempo.

En primer lugar, se analizan las frecuencias de los LWTs obtenidos de los reanálisis, representados por los cuatro productos de reanálisis. En la Fig. 3.1, se muestran las frecuencias estacionales de los LWT, representadas en orden decreciente según la ocurrencia anual de los LWTs de ERA-Interim (en la Fig. 2.4 se muestran los 8 LWTs con mayor frecuencia).

En general, se observan pequeñas diferencias entre los reanálisis en todas las estaciones. Por otro lado, el conjunto común de LWTs predominantes presenta frecuencias diferentes entre las estaciones. En los tipos de tiempo de invierno (DJF), el Oeste (*Westerly* en inglés, W) y Suroeste (*Southwesterly*, SW) son más frecuentes que el tipo ciclónico (*Cyclonic*, C), y ambos exceden la frecuencia anual. Los tipos de tiempo con flujo del oeste (*westerly types*) disminuyen en primavera y verano, y el tipo Anticiclónico (*Anticyclonic*, A) es más frecuente en verano. Los tipos A, C, W y SW son los cuatro LWTs más frecuentes en todas las estaciones. Los tipos S (*Southly*), NW (*Northwesterly*) y AW (*Anticyclonic Westerly*) están entre los 8 más dominantes en todas las estaciones. El tipo N (*Northly*) también está entre los 8 más frecuentes, excepto en invierno, cuando es menos frecuente que el tipo ASW (*Anticyclonic Southwesterly*). Además, el tipo N representa cerca del 5% de los días en todas las estaciones y también aparece entre los 8 principales LWTs para los tipos de tiempo anuales de ERA-Interim. Ante estos resultados, consideramos el siguiente subconjunto de LWTs en adelante para seguir con el análisis: A, C, W, SW, NW, S, AW y N.

En cuanto a la incertidumbre observacional de las frecuencias relativas de LWTs, se observa que es pequeña al obtener valores similares entre los diferentes reanálisis, con la excepción de ERA-20C. Este último reanálisis muestra frecuencias relativas de LWTs más bajas en comparación con ERA-Interim, JRA y NNRP, especialmente en los dos tipos más frecuentes (A y C), lo que se compensa principalmente por un aumento de la frecuencia en los tipos con flujo S y SW. Este hecho podría deberse a las diferentes fuentes de datos del reanálisis ERA-20C en comparación con los otros reanálisis disponibles (Sec. 3.1.2).

Asimismo, en la Figura 3.2 (panel izquierdo) se muestra el grado de semejanza entre los reanálisis (ERA-20C, JRA y NNRP) con respecto a ERA-Interim utilizando la divergencia de KL. Esto proporciona una nueva medida de similitud pero esta vez en un solo valor por reanálisis y se obtiene usando las frecuencias de los 26 LWTs. De nuevo, entre los reanálisis,




Figura 3.2: Divergencia de Kullback–Leibler (KL) (valores por estaciones y anuales, por columnas) de los diferentes reanálisis (izquierda) y modelos por experimentos (derecha, CMIP5 y CMIP6).

ERA-20C muestra las mayores diferencias con respecto a ERA-Interim ($KL = 0.008$) en comparación con los otros reanálisis (0.003 tanto para el JRA como para el NNRP). Esto concuerda con la figura 3.1, donde las frecuencias de LWTs de ERA-20C son las más dispares entre todos los reanálisis.

3.3.2. Tipos de tiempo en los modelos climáticos

A continuación, se evalúan las diferencias de los modelos con una referencia pseudo-observacional, que es ERA-Interim. En el Anexo A se incluyen más resultados considerando los reanálisis alternativos como referencia. En la Fig. 3.2 (paneles de la derecha) se obtiene el grado de semejanza de los modelos con ERA-Interim a través de la divergencia de KL . A primera vista, el dato de divergencia anual puede ocultar la compensación de grandes sesgos estacionales. En general, se observa una clara mejora de CMIP5 a CMIP6, aunque si nos fijamos en los valores más grandes de divergencia de KL en estaciones específicas de CMIP5, éstos sólo disminuyen ligeramente con respecto a CMIP6 o se mueven a otra estación en CMIP6. Se llega a una conclusión similar al utilizar como referencia los otros tres reanálisis (véanse las figuras A1, A3 y A5 del Anexo A). En cuanto a los valores anuales, el modelo de CMIP6 EC-EARTH3 muestra la menor desviación ($KL = 0.007$), seguido




Figura 3.3: Sesgo Relativo de las frecuencias de los LWTs de los diferentes reanálisis y GCMs respecto a ERA-Interim (en filas: reanálisis en negro, GCMs de CMIP5 en rojo, GCMs de CMIP6 en azul) en las 4 estaciones (DJF, MAM, JJA y SON en columnas). Las filas están ordenadas siguiendo la clasificación de modelos (de menor a mayor) dada por el valor anual de divergencia de KL de la Figura 3.2 (las clasificaciones estacionales se dan entre paréntesis). Las cruces indican valores estadísticamente significativos después de ejecutar el Z-Test (Sect.3).

por UKESM1-0-LL (0.009), HadGEM2 (0.009), EC-EARTH (0.022) e IPSL-CM6A-LR (0.026). EC-EARTH3 muestra también un comportamiento ligeramente mejor que ERA-20C en el valor anual, lo cual no ocurre en las divergencias estacionales (p. ej. $KL = 0.046$ en invierno, $KL = 0.031$ en primavera) probablemente debido a los sesgos temporales a lo largo de las estaciones del año y la persistencia de los tipos de tiempo. Las divergencias de KL más grandes se encuentran en invierno para la mayoría de los modelos CMIP5 y CMIP6, seguidos por el verano y la primavera. Para explicar estas diferencias, se analizan a continuación los Sesgos relativos estacionales de todos los GCMs y reanálisis con respecto a ERA-Interim para los 8 principales LWTs (A, C, W, SW, NW, S, AW y N). La divergencia de KL anual de los modelos CMIP5 y CMIP6 permite configurar una clasificación según su capacidad de reproducir las condiciones sinópticas con respecto al grado de acuerdo con ERA-Interim. La mejora general de CMIP6 considerando la divergencia

anual de KL (Figura 3.2) también es evidente al observar los Biases Relativos (Figura 3.3). En general, se encuentran Biases más pequeños en los modelos de CMIP6, exceptuando el IPSL-CM6A-LR en invierno, NorESM2-LM y CanESM5 en primavera, y NorESM2-LM en verano.

En general, según la Figura 3.3, todos los modelos presentan más dificultades para reproducir los dos LWTs más frecuentes (el anticiclónico y el ciclónico, con Bias de signo opuesto) en la estación invernal (DJF). En todas las estaciones, la mayoría de los modelos subestiman las frecuencias de tipo anticiclónico, mientras que simulan por exceso el tipo ciclónico. La sobreestimación de la frecuencia de ocurrencia del fenómeno de bloqueo invernal en Europa es un inconveniente conocido en los modelos de CMIP5 (véase, por ejemplo, Masato et al., 2013). En general, los GCMs de CMIP6 mejoran los Sesgos Relativos de los tipos A y C en comparación con sus modelos homólogos del CMIP5, especialmente el NorESM2-LM y el GFDL-ESM4, aunque se aprecian diferencias con ERA-Interim estadísticamente significativas.

Los resultados no son concluyentes para el resto de LWTs principales, donde se muestran sesgos de distinta magnitud y signo según el modelo. Se sobreestiman las frecuencias de los tipos W y SW en NorESM2-LM y CanESM5 en primavera (también por NorESM2-LM en verano), con un resultado peor que el de sus homólogos del CMIP5. Se subestima el tipo AW en la mayoría de los modelos en primavera, independientemente del experimento de CMIP. La mayoría de los GCMs no muestra diferencias significativas con ERA-Interim para los tipos de tiempo menos frecuentes, especialmente en primavera y otoño. La evaluación de los GCMs tomando como referencia los otros tres reanálisis conduce a conclusiones y clasificaciones similares (véase las figuras A2, A4, A6 en el Anexo A).

A pesar de la mejora de los modelos de CMIP6 respecto de sus homólogos en CMIP5, todavía quedan algunos Biases o sesgos, que bien pueden deberse a las limitaciones en la simulación de las condiciones más persistentes (como los tipos A y C) y las transiciones de un tipo de tiempo a otro.

3.3.3. Probabilidades de Transición de los Tipos de Tiempo

Con el fin de arrojar luz sobre los Biases Relativos obtenidos, analizamos las Probabilidades de Transición de un tipo a otro, lo que podría explicar la distorsión de las

condiciones sinópticas y sus frecuencias para la mayoría de los GCMs representados en la Fig. 3.3. La TPM de ERA-Interim (Fig. 3.4a) proporciona la referencia de las transiciones entre LWTs y la persistencia de un LWT dado. Por ejemplo, más del 60 % de los días que pertenecen al tipo A permanecen en el mismo LWT al día siguiente, y más del 50 % para el tipo C. Les siguen los tipos SW, W, SE y E (todos por encima del 30 %).

Las transiciones más frecuentes a un Tipo de Tiempo diferente son de ANE, AN y ANW a tipo A y de CSE, CS, CSW a tipo C, todos con probabilidades superiores al 40 %. ASE a SE y AS a S completan el conjunto de las transiciones más comunes. Este patrón es similar en el resto de los reanálisis utilizados como referencias alternativas, observando mayores diferencias para ERA-20C (ver Figuras A7 y A8 del Anexo A).

En general, la habilidad de los GCMs para reproducir cualitativamente la TPM de referencia, independientemente de la generación del CMIP, es notable (véase el ejemplo en las Figs. 3.4b-c y también A9-A16 en el Anexo). Todas las TPM de los CMIP son capaces de captar adecuadamente el patrón de ERA-Interim de referencia, aunque en algunos casos hay importantes desviaciones en la magnitud de sus probabilidades. Como resultado, la mayoría de los GCM no reproducen la alta persistencia de los LWTs ciclónico y anticiclónico. En particular, atendiendo a la significación estadística de sus probabilidades, la alta persistencia de las TPM ciclónicas y anticiclónicas sólo se reproduce adecuadamente en unos pocos modelos, como el EC-EARTH y HADGEM2-ES de CMIP5 (Figs. A9 y A10 del Anexo A), y los modelos IPSL-CM6A-LR (Fig. 3.4c) y UKESM1-0-LL (Fig. A10 del Anexo A) de CMIP6. Por otra parte, el LWT ciclónico (el segundo más frecuente en el registro histórico) es reproducido significativamente sólo por los modelos EC-EARTH, HADGEM2-ES y MPI-ESM-LR de CMIP5, así como por sus homólogos de CMIP6 (Figs. A9, A10 y A13 respectivamente, del Anexo A).

La información de las TPM de cada GCM y reanálisis se resume cuantitativamente con el TPMS en la Figura 3.5. Destaca la mejora del CMIP6 sobre el CMIP5 para los modelos IPSL-CM6A-LR y GFDL-ESM4. Ambos GCM son capaces de simular las altas probabilidad de persistencia de los tipos A, C y W mejor que sus homólogos de CMIP5 (Fig. 3.4 y Fig. A14 del Anexo A). Además, la dispersión del TPMS asociada con la incertidumbre observacional disminuye en el caso de los modelos de CMIP6, mostrando un mejor acuerdo general en su representación de la circulación atmosférica, a excepción

de dos modelos NORESM2-LM y CANESM5, que ofrecen un bajo comportamiento que empeora más aún en CMIP6 (Figura 3.5). Aunque NORESM2-LM mejora la persistencia del tipo ciclónico, las transiciones de CNE a C y de ASW a SW empeoran en CMIP6 (Fig. A14 del Anexo A), en consonancia con el sesgo negativo del tipo C en invierno y los grandes sesgos encontrados para el tipo SW en primavera y verano (Fig. 3.3). De manera similar, CANESM5 presenta un tipo C demasiado persistente y probabilidades de transición demasiado altas de AW y SW al tipo W (Fig. A15 del Anexo A), lo que puede estar relacionado con la sobreestimación de las frecuencias del tipo W en invierno y primavera (Fig 3.3).

En cuanto a la evaluación de la incertidumbre observacional utilizando el TPMS, se encuentran valores muy similares para JRA ($TPMS = 0.71$) y NNRP ($TPMS = 0.76$) en comparación con ERA-Interim, y un TPMS más grande para ERA-20C ($TPMS = 1.11$, ver la Fig. A7 del Anexo A). El mejor comportamiento de los modelos de CMIP6 que de CMIP5 es independiente del reanálisis usado como referencia (Figura 3.5), lo cual está en consonancia con los resultados de Cannon (2020). No se obtiene una diferencia relevante en los resultados de la evaluación de los modelos por el hecho de utilizar un reanálisis u otro. En general las diferencias producidas por la utilización de un reanálisis u otro (incertidumbre observacional) son más pequeñas que las propias diferencias entre modelos.

3.4. Conclusiones

Tras el análisis de todos los resultados y cumplir con los objetivos principales del estudio, se puede concluir que existe una mejora general de los modelos de CMIP6 respecto a los de CMIP5 en base a la aplicación de varias medidas de validación estadísticas, relacionadas con las frecuencias simuladas de los tipos de tiempo de los GCMs y sus secuencias temporales (persistencia y probabilidad de transición de un tipo a otro). Algunos GCMs con un buen comportamiento en CMIP5 (p. ej., EC-EARTH y HADGEM2-ES), también lo muestran en CMIP6. Se encuentran grandes mejoras en el modelo IPSL-CM5A-LR y el GFDL-ESM4. Por el contrario, siguen existiendo importantes desviaciones en otros GCM de CMIP6 (p.e. NORESM2-LM). Estos sesgos se relacionan con sus inexactitudes

en la representación de las probabilidades de transición, y en general, tienden a ocurrir en estaciones específicas. En general, los GCMs muestran una capacidad notable para reproducir las probabilidades de transición entre LWTs de los reanálisis, aunque existen algunas diferencias significativas en transiciones particulares. Además, estos resultados son independientes del reanálisis que se utilice como referencia (los resultados que consideran los reanálisis alternativos se incluyen en el Anexo A).

Los modelos de CMIP6 que experimentan una mejora sustancial son los que se han desarrollado una resolución espacial más alta en comparación con la de sus predecesores del CMIP5, p. ej. los modelos GFDL y IPSL (ver Tabla 3.1). Por el contrario, los modelos CANESM, MIROC y NORESM, que no se actualizan a una resolución más alta en CMIP6, son los que peor rendimiento ofrecen en esta comparativa. Además, otros trabajos anteriores también muestran que el aumento de la resolución horizontal de los GCMs lleva a una mejor representación de la frecuencia concreta del bloqueo invernal europeo (Matsueda et al., 2009; Berckmans et al., 2013; Davini et al., 2017).

Por último, también se muestra que la incertidumbre observacional es una fuente menor de sesgos en comparación con las desigualdades entre los propios modelos y experimentos. Teniendo esto en cuenta, nuestros resultados son robustos en lo que respecta al reanálisis de referencia elegido, y la mejora de CMIP6 con respecto a CMIP5 es independiente de esta elección (resultado consistente con lo descrito por Cannon, 2020).

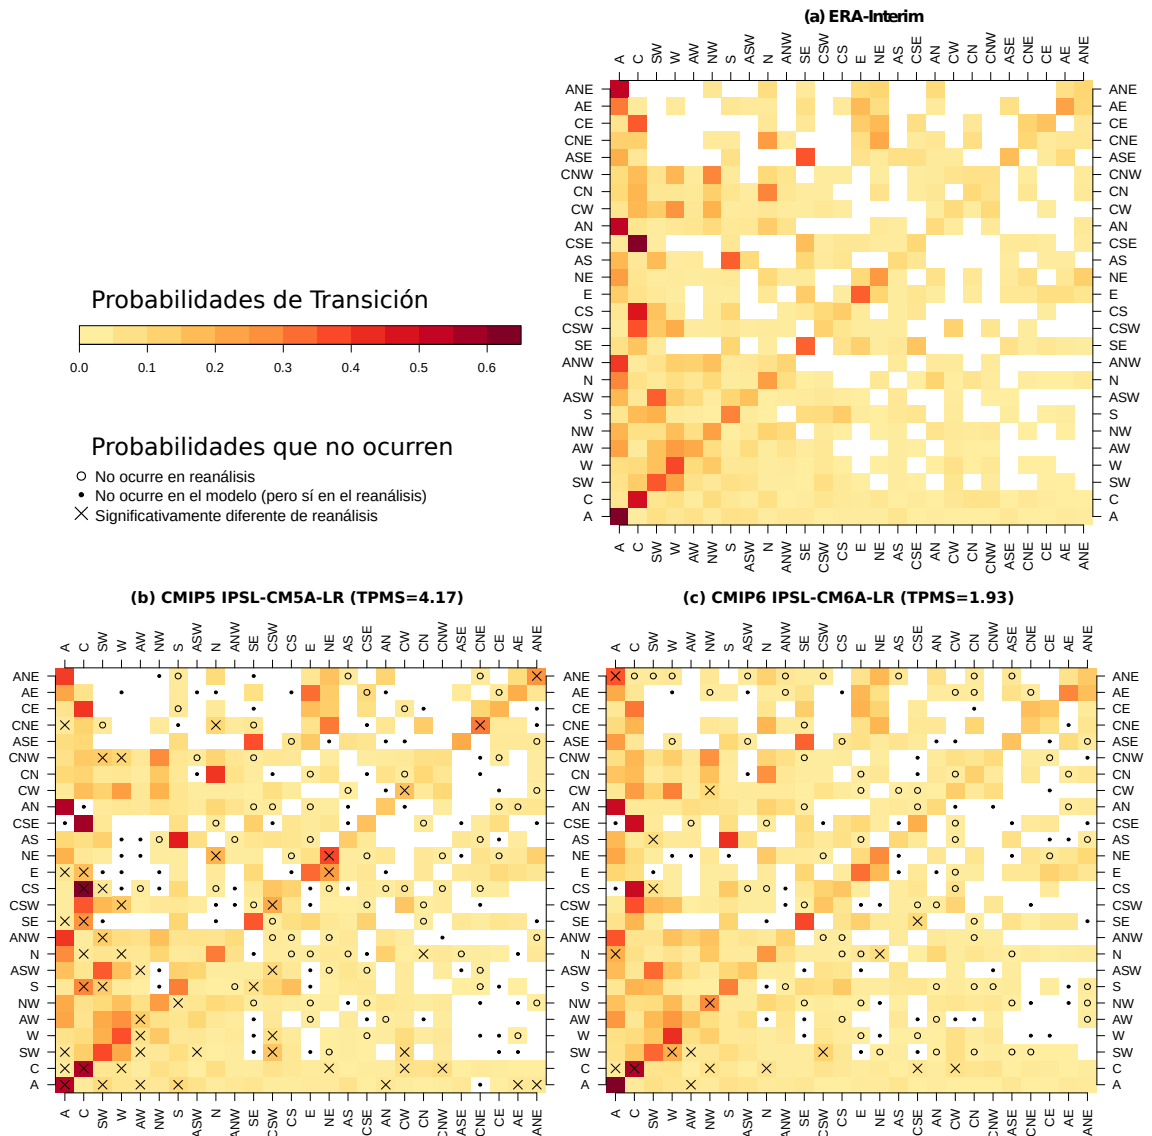


Figura 3.4: Ejemplo de Matrices de Probabilidades de Transición (A) de los Tipos de Tiempo Lamb, considerando los modelos CMIP5 IPSL-CM5A-LR (b) y su versión de CMIP6 IPSL-CM6A-LR (c) para el período histórico 1981-2010. $A_{ij} = p(X_t = j | X_{t-1} = i)$, que representa la probabilidad de pasar de un LWT en la fila i a un LWT en la columna j . Las transiciones no observadas se han dejado en blanco para diferenciarlas de las de baja probabilidad. Las probabilidades de transición significativamente diferentes de las observadas en ERA-Interim (a) se marcan con cruces. Además, las transiciones simuladas por el modelo pero no observadas en ERA-Interim se indican con círculos vacíos. Asimismo, los círculos sólidos indican transiciones de LWT no simuladas por el modelo, pero que se producen en ERA-Interim. Los correspondientes valores del TPMS obtenidos en los modelos se indican entre paréntesis en los títulos de los paneles (b) y (c).




Figura 3.5: Índice de matriz de probabilidades de transición (TPMS) alcanzadas por los modelos CMIP5/CMIP6 (símbolos rojo/azul), tomando como referencia diferentes reanálisis. Los resultados se presentan como pares de GCMs CMIP5-CMIP6, en orden ascendente de izquierda a derecha teniendo en cuenta el TPMS de los modelos CMIP5 con ERA-Interim como referencia (círculos con relleno sólido). Las gráficas de la derecha resumen los resultados de las gráficas de su izquierda para cada reanálisis individualmente (ver el símbolo de la leyenda que indica la mediana) y el proyecto del CMIP (color).

Conclusiones generales y trabajo futuro

En este Trabajo de Final de Máster se muestra un análisis estadístico de señales climáticas que sirve para evaluar la capacidad de los Modelos Globales del Clima (GCMs) de reproducir la circulación atmosférica sobre Europa en el periodo histórico. El análisis se basa en la comparación de tipos de tiempo de Lamb obtenidos de una batería de 9 parejas de modelos de CMIP5 y CMIP6 con los obtenidos de hasta cuatro reanálisis diferentes. Esta validación cualitativa de GCMs basada en tipos de circulación tiene por objeto ayudar en el diseño de futuros experimentos de regionalización o *downscaling*, que están sujetos a las condiciones de frontera proporcionadas por los GCMs. Se ha cumplido con los objetivos principales del estudio y se pueden esbozar las siguientes conclusiones:

- Se han desarrollado herramientas que permiten obtener tipos de tiempo a través de las funciones implementadas dentro del entorno `climate4R`, donde el núcleo de las operaciones es la función `clusterGrid` del paquete `transformer`. Esta función es capaz de ejecutar hasta cuatro técnicas de agrupamiento diferentes. El análisis se ha centrado en los LWTs ya que proporcionan resultados más interpretables desde el punto de vista climático y es popular en el ámbito de la climatología sinóptica basada en tipos de tiempo.
- A lo largo del capítulo 3 se muestra que, en general, los modelos de CMIP6 mejoran el comportamiento de sus respectivos homólogos de CMIP5. Cabe destacar el comportamiento de los modelos de CMIP6, EC-EARTH3 y UKESM1-0-LL, que son los que muestran menores sesgos a lo largo del análisis. Sus homólogos de CMIP5 también muestran un comportamiento relativamente bueno.

- Se concluye que los GCMs son capaces de reproducir notablemente el patrón de transiciones más probables del reanálisis, incluso los modelos que presentan mayores deficiencias.
- En cuarto lugar, se muestra que los modelos de CMIP6 que más han mejorado su comportamiento en la reproducción de los procesos a gran escala (circulación atmosférica) son los que se han desarrollado una resolución más alta que sus predecesores de CMIP5, dejando atrás a los modelos que no actualizan su resolución de CMIP5.
- Finalmente, se puede decir que estos resultados no se ven afectados al utilizar un reanálisis de referencia u otro (véase el Anexo A). La incertidumbre observacional es pequeña en comparación con las diferencias entre los modelos de ambos experimentos.

Tras estas conclusiones, hay que tener en cuenta que los resultados presentados son sensibles al algoritmo de clasificación utilizado, y, por lo tanto, las clasificaciones, el comportamiento del modelo e incluso las mejoras del CMIP6 mostradas son particulares para los Tipos de Tiempo de Lamb. En el estudio de Cannon (2020) se muestran resultados para dos algoritmos de clasificación objetivos, y se observa una mejora o degradación significativa en los modelos del CMIP6 dependiendo del método de clasificación utilizado. Por lo tanto, quedan otras fuentes de incertidumbre no exploradas relacionadas con la técnica de agrupamiento empleada, que puede servir como trabajo futuro. Además, para abordar esta propuesta, se puede emplear la función `clusterGrid` como núcleo de cómputo. Por otro lado, como se apunta en la sección 2.2, existen algunos estudios que, utilizando Lamb, centran la selección de los 16 puntos de *SLP* en localizaciones diferentes a la definición original. En un estudio futuro, resultaría interesante analizar la dependencia de los resultados a la variación de este centro, con el fin de determinar hasta qué punto es desplazable y si variaciones en su localización pueden explicar los sesgos encontrados en determinados tipos de tiempo.

4.1. *Reproducibilidad e impacto del trabajo*

Como se puede ver en el Anexo B, este trabajo se recoge en la publicación: *Fernandez-Granja, J.A., A. Casanueva, J. Bedia y J. Fernandez, 2020. Improved atmospheric circulation over Europe by the new generation of CMIP6 Earth System Models*, enviado a la revista *Climate Dynamics*, encontrándose en proceso de revisión en el momento de defensa del Trabajo de Fin de Máster.

Además de las contribuciones hechas a `climate4R`, se puede acceder a los datos y reproducir los resultados de este trabajo mediante el contenido facilitado en los hipervínculos del capítulo 2, un *notebook* disponible en un repositorio público en GitHub en <https://github.com/SantanderMetGroup/notebooks/tree/devel> (los ficheros de nombre `2020_Lamb_ClimDyn.*`), y un segundo repositorio que contiene los *scripts* en R utilizados para el caso de estudio del capítulo 3 en <https://github.com/juanferngran/TFM>.

Bibliografía

- Addor, N., M. Rohrer, R. Furrer, y J. Seibert, 2016: Propagation of biases in climate models from the synoptic to the regional scale: Implications for bias adjustment. *Journal of Geophysical Research: Atmospheres*, **121**, 2075–2089, doi:10.1002/2015JD024040.
- Aggarwal, C., J. Han, J. Wang, y P. Yu, 2003: A framework for clustering evolving data streams. 81–92.
- Ahmadalipour, A., A. Rana, H. Moradkhani, y A. Sharma, 2017: Multi-criteria evaluation of cmip5 gcms for climate change impact analysis. *Theoretical and Applied Climatology*, **128**, 71–87, doi:10.1007/s00704-015-1695-4.
- Anderberg, M. R., 1973: *Cluster Analysis for Applications*. Academic Press, New York.
- Anstey, J. A., P. Davini, L. J. Gray, T. J. Woollings, N. Butchart, C. Cagnazzo, B. Christiansen, S. C. Hardiman, S. M. Osprey, y S. Yang, 2013: Multi-model analysis of northern hemisphere winter blocking: Model biases and the role of resolution. *Journal of Geophysical Research: Atmospheres*, **118**, 3956–3971, doi:10.1002/jgrd.50231.
- Barriopedro, D., E. M. Fischer, J. Luterbacher, R. M. Trigo, y R. Garcia-Herrera, 2011: The Hot Summer of 2010: Redrawing the Temperature Record Map of Europe. *Science*, **332**, 220–224, doi:10.1126/science.1201224.
- Bedia, J., J. Baño-Medina, M. N. Legasa, M. Iturbide, R. Manzananas, S. Herrera, A. Casanueva, D. San-Martín, A. S. Cofiño, y J. M. Gutiérrez, 2020: Statistical downscaling with the downscaler package (v3.1.0): contribution to the VALUE intercomparison experiment. *Geoscientific Model Development*, **13**, 1711–1735, doi:<https://doi.org/10.5194/gmd-13-1711-2020>, publisher: Copernicus GmbH.
URL <https://gmd.copernicus.org/articles/13/1711/2020/>

- Bedia, J., N. Golding, A. Casanueva, M. Iturbide, C. Buontempo, y J. M. Gutiérrez, 2018: Seasonal predictions of Fire Weather Index: Paving the way for their operational applicability in Mediterranean Europe. *Climate Services*, **9**, 101–110, doi:10.1016/j.cliser.2017.04.001.
URL <http://linkinghub.elsevier.com/retrieve/pii/S2405880716300826>
- Bedia, J., D. San-Martín, M. Iturbide, S. Herrera, R. Manzananas, y J. M. Gutiérrez, 2019: The METACLIP semantic provenance framework for climate products. *Environmental Modelling & Software*, doi:10.1016/j.envsoft.2019.07.005.
URL <http://www.sciencedirect.com/science/article/pii/S1364815218305036>
- Belda, M., E. Holtanová, T. Halenka, J. Kalvová, y Z. Hlávka, 2015: Evaluation of cmip5 present climate simulations using the köppen-trewartha climate classification. *Climate Research*, **64**, 201–212, doi:10.3354/cr01316.
- Benestad, R. E., I. Hanssen-Bauer, y D. Chen, 2008: *Empirical-Statistical Downscaling*. World Scientific Publishing, Singapore, 1st edition.
- Berckmans, J., T. Woollings, M.-E. Demory, P.-L. Vidale, y M. Roberts, 2013: Atmospheric blocking in a high resolution climate model: influences of mean state, orography and eddy forcing. *Atmospheric Science Letters*, **14**, 34–40, doi:10.1002/asl2.412.
- Bermejo, M. y R. Ancell, 2009: Observed changes in extreme temperatures over spain during 1957–2002, using weather types. *Revista de climatología*, **9**, 45–61.
- Bladé, I., B. Liebmann, D. Fortuny, y G. J. v. Oldenborgh, 2011: Observed and simulated impacts of the summer NAO in Europe: implications for projected drying in the Mediterranean region. *Climate Dynamics*, **39**, 709–727, doi:10.1007/s00382-011-1195-x.
- Brands, S., S. Herrera, J. Fernández, y J. M. Gutiérrez, 2013: How well do CMIP5 Earth System Models simulate present climate conditions in Europe and Africa? *Climate Dynamics*, **41**, 803–817, doi:10.1007/s00382-013-1742-8.
URL <https://doi.org/10.1007/s00382-013-1742-8>
- Brands, S., S. Herrera, y J. Gutiérrez, 2014: Is Eurasian snow cover in October a reliable statistical predictor for the wintertime climate on the Iberian Peninsula?: Is the

- wintertime climate in Iberia driven by Eurasian snow cover? *International Journal of Climatology*, **34**, 1615–1627, doi:10.1002/joc.3788.
URL <http://doi.wiley.com/10.1002/joc.3788>
- Buehler, T., C. C. Raible, y T. F. Stocker, 2011: The relationship of winter season North Atlantic blocking frequencies to extreme cold or dry spells in the ERA-40. *Tellus A: Dynamic Meteorology and Oceanography*, **63**, 174–187, doi:10.1111/j.1600-0870.2010.00492.x.
- Busuioc, A., D. Chen, y C. Hellström, 2001: Performance of statistical downscaling models in GCM validation and regional climate change estimates: application for Swedish precipitation: STATISTICAL DOWNSCALING FOR SWEDISH PRECIPITATION. *International Journal of Climatology*, **21**, 557–578, doi:10.1002/joc.624.
- Cannon, A., 2020: Reductions in daily continental-scale atmospheric circulation biases between generations of Global Climate Models: CMIP5 to CMIP6. *Environmental Research Letters*, doi:10.1088/1748-9326/ab7e4f.
- Casanueva, A., S. Kotlarski, A. Fischer, A. Flouris, T. Kjellstrom, B. Lemke, L. Nybo, C. Schwierz, y M. Liniger, 2020: Escalating environmental summer heat exposure—a future threat for the European workforce. *Regional Environmental Change*, **20**, doi:10.1007/s10113-020-01625-6.
- Casanueva, A., C. Rodríguez-Puebla, M. D. Frías, y N. González-Reviriego, 2014: Variability of extreme precipitation over Europe and its relationships with teleconnection patterns. *Hydrol. Earth Syst. Sci.*, **18**, 709–725, doi:10.5194/hess-18-709-2014.
- Cavazos, T., 1997: Downscaling large-scale circulation to local winter rainfall in northeastern Mexico. *International Journal of Climatology*, **17**, 1069–1082.
- Chang, E. K. M., Y. Guo, y X. Xia, 2012: Cmp5 multimodel ensemble projection of storm track change under global warming. *Journal of Geophysical Research: Atmospheres*, **117**, doi:10.1029/2012JD018578.
- Chen, D., 2000: A monthly circulation climatology for Sweden and its application to a winter temperature case study. *International Journal of Climatology*, **20**, 1067–1076,

- doi:10.1002/1097-0088(200008)20:10<1067::AID-JOC528>3.0.CO;2-Q, 00187.
URL <https://rmets.onlinelibrary.wiley.com/doi/abs/10.1002/1097-0088%28200008%2920%3A10%3C1067%3A%3AAID-JOC528%3E3.0.CO%3B2-Q>
- Cherkassky, V. S. y F. Mulier, 1998: *Learning from Data: Concepts, Theory, and Methods*. Wiley, New York.
- Christensen, J., F. Boberg, O. Christensen, y P. Lucas-Picher, 2008: On the need for bias correction of regional climate change projections of temperature and precipitation. **35**, L20709, doi:10.1029/2008GL035694.
- Cofiño, A., J. Bedia, M. Iturbide, M. Vega, S. Herrera, J. Fernández, M. Frías, R. Manzanas, y J. Gutiérrez, 2018: The ECOMS User Data Gateway: Towards seasonal forecast data provision and research reproducibility in the era of Climate Services. *Climate Services*, **9**, 33–43, doi:10.1016/j.cliser.2017.07.001.
URL <http://linkinghub.elsevier.com/retrieve/pii/S2405880717300079>
- Colle, B. A., Z. Zhang, K. A. Lombardo, E. Chang, P. Liu, y M. Zhang, 2013: Historical Evaluation and Future Prediction of Eastern North American and Western Atlantic Extratropical Cyclones in the CMIP5 Models during the Cool Season. *Journal of Climate*, **26**, 6882–6903, doi:10.1175/JCLI-D-12-00498.1.
- Cover, T. M. y J. A. Thomas, 2006: *Elements of Information Theory*. John Wiley Sons.
- Davini, P., S. Corti, F. D’Andrea, G. Rivière, y J. von Hardenberg, 2017: Improved winter european atmospheric blocking frequencies in high-resolution global climate simulations. *Journal of Advances in Modeling Earth Systems*, **9**, 2615–2634, doi:10.1002/2017MS001082.
- Dawson, A., T. N. Palmer, y S. Corti, 2012: Simulating regime structures in weather and climate prediction models: REGIMES IN WEATHER AND CLIMATE MODELS. *Geophysical Research Letters*, **39**, n/a–n/a, doi:10.1029/2012GL053284.
- Dee, D. P., S. M. Uppala, A. J. Simmons, P. Berrisford, P. Poli, S. Kobayashi, U. Andrae, M. A. Balmaseda, G. Balsamo, P. Bauer, P. Bechtold, A. C. M. Beljaars, L. van de

- Berg, J. Bidlot, N. Bormann, C. Delsol, R. Dragani, M. Fuentes, A. J. Geer, L. Haimberger, S. B. Healy, H. Hersbach, E. V. Hólm, L. Isaksen, P. Kaallberg, M. Kohler, M. Matricardi, A. P. McNally, B. M. Monge-Sanz, J. Morcrette, B. Park, C. Peubey, P. de Rosnay, C. Tavalato, J.-N. Thépaut, y F. Vitart, 2011: The ERA-Interim reanalysis: configuration and performance of the data assimilation system. *Q J R Meteorol Soc*, **137**, 553–597, doi:10.1002/qj.828.
- Dosio, A., 2016: Projections of climate change indices of temperature and precipitation from an ensemble of bias-adjusted high-resolution EURO-CORDEX regional climate models: BIAS-ADJUSTED CLIMATE CHANGE INDICES. *Journal of Geophysical Research: Atmospheres*, **121**, 5488–5511, doi:10.1002/2015JD024411.
- Drost, H.-G., 2018: Philentropy: Information Theory and Distance Quantification with R. *Journal of Open Source Software*, **3**, 765, doi:10.21105/joss.00765.
- Everitt, B., S. Landau, M. Leese, y D. Stahl, 2011: *Cluster Analysis*. Wiley Series in Probability and Statistics, Wiley, New York, 5 edition.
- Eyring, V., S. Bony, G. A. Meehl, C. A. Senior, B. Stevens, R. J. Stouffer, y K. E. Taylor, 2016: Overview of the coupled model intercomparison project phase 6 (cmip6) experimental design and organization. *Geoscientific Model Development*, **9**, 1937–1958, doi:10.5194/gmd-9-1937-2016.
- Fahad, A., N. Alshatri, Z. Tari, A. Alamri, I. Khalil, A. Zomaya, S. Fofou, y A. Bouras, 2014: A survey of clustering algorithms for big data: Taxonomy and empirical analysis. *IEEE Transactions on Emerging Topics in Computing*, **2**, 267–279, doi:10.1109/TETC.2014.2330519.
- Favà, V., J. J. Curto, y M. C. Llasat, 2015: Relationship between the summer NAO and maximum temperatures for the Iberian Peninsula. *Theoretical and Applied Climatology*, 1–15, doi:10.1007/s00704-015-1547-2.
- Fealy, R. y G. Mills, 2018: Deriving Lamb weather types suited to regional climate studies: A case study on the synoptic origins of precipitation over Ireland. *International Journal of Climatology*, **38**, 3439–3448, doi:10.1002/joc.5495, 00000.

- Feser, F., B. Rockel, H. von Storch, J. Winterfeldt, y M. Zahn, 2011: Regional Climate Models Add Value to Global Model Data: A Review and Selected Examples: . *Bulletin of the American Meteorological Society*, **92**, 1181–1192, doi:10.1175/2011BAMS3061.1.
- Folland, C. K., J. Knight, H. W. Linderholm, D. Fereday, S. Ineson, y J. W. Hurrell, 2009: The Summer North Atlantic Oscillation: Past, Present, and Future. *Journal of Climate*, **22**, 1082–1103, doi:10.1175/2008JCLI2459.1.
- Frías, M., M. Iturbide, R. Manzananas, J. Bedia, J. Fernández, S. Herrera, A. Cofiño, y J. Gutiérrez, 2018: An r package to visualize and communicate uncertainty in seasonal climate prediction. *Environmental Modelling Software*, **99**, 101 – 110, doi:https://doi.org/10.1016/j.envsoft.2017.09.008.
URL <http://www.sciencedirect.com/science/article/pii/S1364815217305157>
- Giorgi, F., 2006: Regional climate modeling: Status and perspectives. *Journal de Physique IV (Proceedings)*, **139**, 101–118, doi:10.1051/jp4:2006139008.
- Giorgi, F., C. Jones, y G. Asrar, 2009: Addressing climate information needs at the regional level: the CORDEX framework. *WMO Bulletin*, **58**, 175–183.
- Gordon, A. D., 1987: A review of hierarchical classification. *Journal of the Royal Statistical Society: Series A (General)*, **150**, 119–137, doi:doi.org/10.2307/2981629.
- Gu, G., R. Perdisci, J. Zhang, y W. Lee, 2008: Botminer: Clustering analysis of network traffic for protocol- and structure-independent botnet detection. 139–154.
- Gutiérrez, J., A. Cofino, R. Cano, y S. C.M., 2004a: *Redes probabilísticas y neuronales en las ciencias atmosféricas*. Series Monográficas del Instituto Nacional de Meteorología.
URL <http://www.meteo.unican.es/files/pdfs/LibroINM.pdf>
- Gutiérrez, J., A. Cofino, R. Cano, y M. Rodríguez, 2004b: Clustering methods for statistical downscaling in short-range weather forecasts. *Monthly Weather Review*, **132**, 2169–2183, doi:10.1175/1520-0493(2004)132;2169:CMFSDIj2.0.CO;2.
- Gutiérrez, J. M., R. Cano, A. S. Cofiño, y C. Sordo, 2005: Analysis and downscaling multi-model seasonal forecasts in Peru using self-organizing maps. *Tellus A*, **57**, 435–

447, doi:10.1111/j.1600-0870.2005.00128.x, 00077.

URL <https://onlinelibrary.wiley.com/doi/abs/10.1111/j.1600-0870.2005.00128.x>

Harada, Y., H. Kamahori, C. Kobayashi, H. Endo, S. Kobayashi, Y. Ota, H. Onoda, K. Onogi, K. Miyaoka, y K. Takahashi, 2016: The jra-55 reanalysis: Representation of atmospheric circulation and climate variability. *Journal of the Meteorological Society of Japan. Ser. II*, **94**, 269–302, doi:10.2151/jmsj.2016-015.

Hartigan, J. A., 1975: *Clustering Algorithms*. Wiley Series in Probability and Statistics, Wiley, New York.

Hastie, T., R. Tibshirani, y J. Friedman, 2001: *The Elements of Statistical Learning*. Springer Series in Statistics, Springer, New York.

Hewitson, B. y R. Crane, 2002: Self-organizing maps: Applications to synoptic climatology. *Climate Research*, **22**, 13–26, doi:10.3354/cr022013.

Hochman, A., P. Alpert, T. Harpaz, H. Saaroni, y G. Messori, 2019: A new dynamical systems perspective on atmospheric predictability: Eastern mediterranean weather regimes as a case study. *Science Advances*, **5**, eaau0936, doi:10.1126/sciadv.aau0936.

Hurrell, J. W., Y. Kushnir, G. Ottersen, y M. Visbeck, 2003: An overview of the North Atlantic Oscillation. *Geophysical Monograph Series*, J. W. Hurrell, Y. Kushnir, G. Ottersen, y M. Visbeck, eds., American Geophysical Union, Washington, D. C., volume 134, 1–35.

Huth, R., C. Beck, A. Philipp, M. Demuzere, Z. Ustrnul, M. Cahynová, J. Kyselý, y O. Tveito, 2008: Classifications of atmospheric circulation patterns: Recent advances and applications. *Annals of the New York Academy of Sciences*, **1146**, 105–152, doi:10.1196/annals.1446.019.

Huth, R., I. Nemesova, y N. Klimperová, 1993: Weather categorization based on the average linkage clustering technique: An application to european mid-latitudes. *International Journal of Climatology*, **13**, 817–835, doi:10.1002/joc.3370130802.

IPCC, 2014: *Climate Change 2014: Synthesis Report. Contribution of Working Groups I, II and III to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change*. IPCC, Geneva, Switzerland, 151 pp.

Iturbide, M., J. Bedia, y J. M. Gutiérrez, 2018: Tackling Uncertainties of Species Distribution Model Projections with Package mopa. *The R Journal*, **10**, 18.

URL <https://journal.r-project.org/archive/2018/RJ-2018-019/index.html>

Iturbide, M., J. Bedia, S. Herrera, J. Baño-Medina, J. Fernández, M. Frías, R. Manzanas, D. San-Martín, E. Cimadevilla, A. Cofiño, y J. Gutiérrez, 2019: The R-based climate4R open framework for reproducible climate data access and post-processing. *Environmental Modelling & Software*, **111**, 42–54, doi:10.1016/j.envsoft.2018.09.009.

URL <https://linkinghub.elsevier.com/retrieve/pii/S1364815218303049>

Iturbide, M., A. Casanueva, J. Bedia, S. Herrera, J. Milovac, y J. Gutiérrez, 2020: On the need of bias adjustment for more plausible climate change projections of extreme heat. *Atmospheric Science Letters*, submitted.

Jacob, D., J. Petersen, B. Eggert, A. Alias, O. B. Christensen, L. M. Bouwer, A. Braun, A. Colette, M. Déqué, G. Georgievski, E. Georgopoulou, A. Gobiet, L. Menut, G. Nikulin, A. Haensler, N. Hempelmann, C. Jones, K. Keuler, S. Kovats, N. Kröner, S. Kotlarski, A. Kriegsmann, E. Martin, E. v. Meijgaard, C. Moseley, S. Pfeifer, S. Preuschmann, C. Radermacher, K. Radtke, D. Rechid, M. Rounsevell, P. Samuelsson, S. Somot, J.-F. Soussana, C. Teichmann, R. Valentini, R. Vautard, B. Weber, y P. Yiou, 2014: EURO-CORDEX: new high-resolution climate change projections for European impact research. *Regional Environmental Change*, **14**, 563–578, doi:10.1007/s10113-013-0499-2.

Jacob, D., C. Teichmann, S. Sobolowski, E. Katragkou, I. Anders, M. Belda, R. Benestad, F. Boberg, E. Buonomo, R. M. Cardoso, A. Casanueva, O. B. Christensen, J. H. Christensen, E. Coppola, L. De Cruz, E. L. Davin, A. Dobler, M. Domínguez, R. Fealy, J. Fernandez, M. A. Gaertner, M. García-Díez, F. Giorgi, A. Gobiet, K. Goergen, J. J. Gómez-Navarro, J. J. G. Alemán, C. Gutiérrez, J. M. Gutiérrez, I. Güttler, A. Haensler, T. Halenka, S. Jerez, P. Jiménez-Guerrero, R. G. Jones, K. Keuler, E. Kjellström, S. Knist, S. Kotlarski, D. Maraun, E. van Meijgaard, P. Mercogliano, J. P. Montávez,

- A. Navarra, G. Nikulin, N. de Noblet-Ducoudré, H.-J. Panitz, S. Pfeifer, M. Piazza, E. Pichelli, J.-P. Pietikäinen, A. F. Prein, S. Preuschmann, D. Rechid, B. Rockel, R. Romero, E. Sánchez, K. Sieck, P. M. M. Soares, S. Somot, L. Srnec, S. L. Sørland, P. Termolina, H. Truhetz, R. Vautard, K. Warrach-Sagi, y V. Wulfmeyer, 2020: Regional climate downscaling over europe: perspectives from the EURO-CORDEX community. *Regional Environmental Change*, **20**, 51, doi:10.1007/s10113-020-01606-9.
- Jenkinson, A. y F. Collison, 1977: An initial climatology of gales over the north sea. synoptic climatology branch memorandum. *Meteorol. Off*, 1–62.
- Jiang, B., J. Pei, Y. Tao, y X. Lin, 2011: Clustering uncertain data based on probability distribution similarity. *IEEE Transactions on Knowledge and Data Engineering*, **25**, 751–763.
- Jones, C., F. Giorgi, y G. Asrar, 2011: The Coordinated Regional Downscaling Experiment: CORDEX, An international downscaling link to CMIP5. *CLIVAR Exchanges*, **56-16(2)**, 34–40.
URL www.clivar.org/sites/default/files/imported/publications/exchanges/Exchanges_56.pdf
- Jones, P. D., C. Harpham, y K. R. Briffa, 2013: Lamb weather types derived from reanalysis products. *International Journal of Climatology*, **33**, 1129–1139, doi:10.1002/joc.3498.
URL <http://doi.wiley.com/10.1002/joc.3498>
- Jones, P. D., M. Hulme, y K. R. Briffa, 1993: A comparison of Lamb circulation types with an objective classification scheme. *International Journal of Climatology*, **13**, 655–663, doi:10.1002/joc.3370130606.
- Jury, M. W., S. Herrera, J. M. Gutiérrez, y D. Barriopedro, 2019: Blocking representation in the ERA-Interim driven EURO-CORDEX RCMs. *Climate Dynamics*, **52**, 3291–3306, doi:10.1007/s00382-018-4335-8.
- Kalkstein, L., G. Tan, y J. Skindlov, 1987: An evaluation of three clustering procedures for use in synoptic climatological classification. *Journal of Applied Meteorology*, **26**, 717–730, doi:10.1175/1520-0450(1987)026<0717:AEOTCP>2.0.CO;2.

- Kalnay, E., M. Kanamitsu, R. Kistler, W. Collins, D. Deaven, L. Gandin, M. Iredell, S. Saha, G. White, J. Woollen, Y. Zhu, M. Chelliah, W. Ebisuzaki, W. Higgins, J. Janowiak, K. C. Mo, C. Ropelewski, J. Wang, A. Leetmaa, R. Reynolds, R. Jenne, y D. Joseph, 1996: The NCEP/NCAR 40-Year Reanalysis Project. *Bulletin of the American Meteorological Society*, **77**, 437–472, doi:10.1175/1520-0477(1996)077<0437:TNYRP>2.0.CO;2, publisher: American Meteorological Society.
- Kobayashi, S., Y. Ota, Y. Harada, A. Ebita, M. Moriya, H. Onoda, K. Onogi, H. Kamahori, C. Kobayashi, H. Endo, K. Miyaoka, y K. Takahashi, 2015: The jra-55 reanalysis: General specifications and basic characteristics. *Journal of the Meteorological Society of Japan. Ser. II*, **93**, 5–48, doi:10.2151/jmsj.2015-001.
- Kohonen, T., 1982: Self-organized formation of topologically correct feature maps. *Biological cybernetics*, **43**, 59–69.
- Kullback, S. y R. A. Leibler, 1951: On information and sufficiency. *The annals of mathematical statistics*, **22**, 79–86.
- Lamb, H., 1972: British isles weather types and a register of the daily sequence of circulation patterns 1861-1971. *METEOROL. OFF., GEOPHYS. MEM.; G.B.; DA. 1972; NO 116; PP. 1-85; BIBL. 2P.1/2*.
- Littmann, T., 2000: An empirical classification of weather types in the mediterranean basin and their interrelation with rainfall. *Theoretical and Applied Climatology*, **66**, 161–171, doi:10.1007/s007040070022.
- Liu, X., 2012: A survey on clustering routing protocols in wireless sensor networks. *Sensors (Switzerland)*, **12**, 11113–11153, doi:10.3390/s120811113.
- Manabe, S. y R. T. Wetherald, 1967: Thermal equilibrium of the atmosphere with a given distribution of relative humidity. *Journal of the Atmospheric Sciences*, **24**, 241–259.
- Maraun, D., 2012: Nonstationarities of regional climate model biases in European seasonal mean temperature and precipitation sums. **39**, L06706, doi:10.1029/2012GL051210.

- Maraun, D., T. G. Shepherd, M. Widmann, G. Zappa, D. Walton, J. M. Gutiérrez, S. Hagemann, I. Richter, P. M. M. Soares, A. Hall, y L. O. Mearns, 2017: Towards process-informed bias correction of climate change simulations. *Nature Climate Change*, **7**, 664–773, doi:10.1038/nclimate3418.
- Masato, G., B. J. Hoskins, y T. Woollings, 2013: Winter and Summer Northern Hemisphere Blocking in CMIP5 Models. *Journal of Climate*, **26**, 7044–7059, doi:10.1175/JCLI-D-12-00466.1.
- Matsueda, M., R. Mizuta, y S. Kusunoki, 2009: Future change in wintertime atmospheric blocking simulated using a 20-km-mesh atmospheric global circulation model. *Journal of Geophysical Research: Atmospheres*, **114**, doi:10.1029/2009JD011919.
- McSweeney, C., R. Jones, R. W. Lee, y D. Rowell, 2015: Selecting CMIP5 GCMs for downscaling over multiple regions. *Climate Dynamics*, **44**, 3237–3260, doi:10.1007/s00382-014-2418-8.
- Otero, N., J. Sillmann, y T. Butler, 2018: Assessment of an extended version of the Jenkinson-Collison classification on CMIP5 models over Europe. *Climate Dynamics*, **50**, 1559–1579, doi:10.1007/s00382-017-3705-y.
- Pereira, S., A. Ramos, L. Rebelo, R. Trigo, y J. Zêzere, 2018: A centennial catalogue of hydro-geomorphological events and their atmospheric forcing. *Advances in Water Resources*, **122**, 98–112, doi:10.1016/j.advwatres.2018.10.001.
URL <http://www.sciencedirect.com/science/article/pii/S0309170818304056>
- Perez, J., M. Menendez, F. J. Mendez, y I. J. Losada, 2014: Evaluating the performance of CMIP3 and CMIP5 global climate models over the north-east Atlantic region. *Climate Dynamics*, **43**, 2663–2680, doi:10.1007/s00382-014-2078-8.
- Poli, P., H. Hersbach, D. P. Dee, P. Berrisford, A. J. Simmons, F. Vitart, P. Laloyaux, D. G. Tan, C. Peubey, J.-N. Thépaut, Y. Trémolet, E. V. Hólm, M. Bonavita, L. Isaksen, y M. Fisher, 2016: ERA-20C: An atmospheric reanalysis of the twentieth century. *Journal of Climate*, **29**, 4083–4097, doi:10.1175/JCLI-D-15-0556.1.

- Prein, A. F., M. S. Bukovsky, L. O. Mearns, C. L. Bruyère, y J. M. Done, 2019: Simulating North American Weather Types With Regional Climate Models. *Frontiers in Environmental Science*, **7**, 36, doi:10.3389/fenvs.2019.00036.
- R Core Team, 2020: *R: A Language and Environment for Statistical Computing*. R Foundation for Statistical Computing, Vienna, Austria.
URL <https://www.R-project.org/>
- Ramos, A. M., N. Cortesi, y R. M. Trigo, 2014: Circulation weather types and spatial variability of daily precipitation in the Iberian Peninsula. *Frontiers in Earth Science*, **2**, doi:10.3389/feart.2014.00025, 00037.
URL <https://www.frontiersin.org/articles/10.3389/feart.2014.00025/full>
- Ripley, B. D., 1996: *Pattern recognition and neural networks*. Cambridge university press.
- Rui Xu y D. Wunsch, 2005: Survey of clustering algorithms. *IEEE Transactions on Neural Networks*, **16**, 645–678.
- Sharma, K. K. y A. Seal, 2019: Modeling uncertain data using monte carlo integration method for clustering. *Expert Systems with Applications*, **137**, 100 – 116, doi:<https://doi.org/10.1016/j.eswa.2019.06.050>.
URL <http://www.sciencedirect.com/science/article/pii/S0957417419304506>
- Sillmann, J. y M. Croci-Maspoli, 2009: Present and future atmospheric blocking and its impact on European mean and extreme climate. *Geophysical Research Letters*, **36**, L10702, doi:10.1029/2009GL038259.
- Sneath, P. H., 1957: The application of computers to taxonomy. *Microbiology*, **17**, 201–226.
- Sokal, R. R., 1958: A statistical method for evaluating systematic relationships. *Univ. Kansas, Sci. Bull.*, **38**, 1409–1438.
- Sorensen, T. A., 1948: A method of establishing groups of equal amplitude in plant sociology based on similarity of species content and its application to analyses of the vegetation on danish commons. *Biol. Skar.*, **5**, 1–34.

- Sousa, P. M., R. M. Trigo, D. Barriopedro, P. M. M. Soares, A. M. Ramos, y M. L. R. Liberato, 2017: Responses of European precipitation distributions and regimes to different blocking locations. *Climate Dynamics*, **48**, 1141–1160, doi:10.1007/s00382-016-3132-5.
- Taylor, K. E., R. J. Stouffer, y G. A. Meehl, 2012: An overview of cmip5 and the experiment design. *Bulletin of the American Meteorological Society*, **93**, 485–498, doi:10.1175/BAMS-D-11-00094.1.
- Trigo, R. M. y C. C. DaCamara, 2000: Circulation weather types and their influence on the precipitation regime in Portugal. *Int. J. Climatol.*, **23**, doi:10.1002/1097-0088(20001115)20:13%3C1559::AID-JOC555%3E3.0.CO;2-5.
- Turco, M., A. Sanna, S. Herrera, M.-C. Llasat, y J. M. Gutiérrez, 2013: Large biases and inconsistent climate change signals in ENSEMBLES regional projections. *Climatic Change*, **120**, 859–869, doi:10.1007/s10584-013-0844-y.
- Tveito, O., R. Huth, A. Philipp, P. Post, M. Pasqui, P. Esteban, C. Beck, M. Demuzere, y C. Prudhomme, 2016: *Harmonization and Application of Weather Type Classifications for European Regions*. Final Scientific Report, COST Action 733, 422 pp.
- Vial, J. y T. Osborn, 2012: Assessment of atmosphere-ocean general circulation model simulations of winter northern hemisphere atmospheric blocking. *Climate Dynamics*, **39**, 95–112, doi:10.1007/s00382-011-1177-z.
- Wehrens, R. y J. Kruisselbrink, 2018: Flexible Self-Organizing Maps in kohonen 3.0. *Journal of Statistical Software*, **87**, 1–18, doi:10.18637/jss.v087.i07, number: 1.
URL <https://www.jstatsoft.org/index.php/jss/article/view/v087i07>
- Weijs, S. V., R. van Nooijen, y N. van de Giesen, 2010: Kullback–Leibler Divergence as a Forecast Skill Score with Classic Reliability–Resolution–Uncertainty Decomposition. *Monthly Weather Review*, **138**, 3387–3399, doi:10.1175/2010MWR3229.1.
URL <https://doi.org/10.1175/2010MWR3229.1>
- WMO, 2017: WMO Guidelines on the Calculation of Climate Normals. Technical Report WMO No. 1203, World Meteorological Organization, ISBN:978-92-63-11203-3.

Zappa, G., L. C. Shaffrey, y K. I. Hodges, 2013: The Ability of CMIP5 Models to Simulate North Atlantic Extratropical Cyclones*. *Journal of Climate*, **26**, 5379–5396, doi:10.1175/JCLI-D-12-00501.1.

Anexo A: Resultados con diferentes reanálisis de referencia

Divergencia de Kullback–Leibler y Sesgo relativo de los modelos de CMIP5, CMIP6 y reanálisis tomando como referencia diferentes reanálisis

Referencia: NNRP

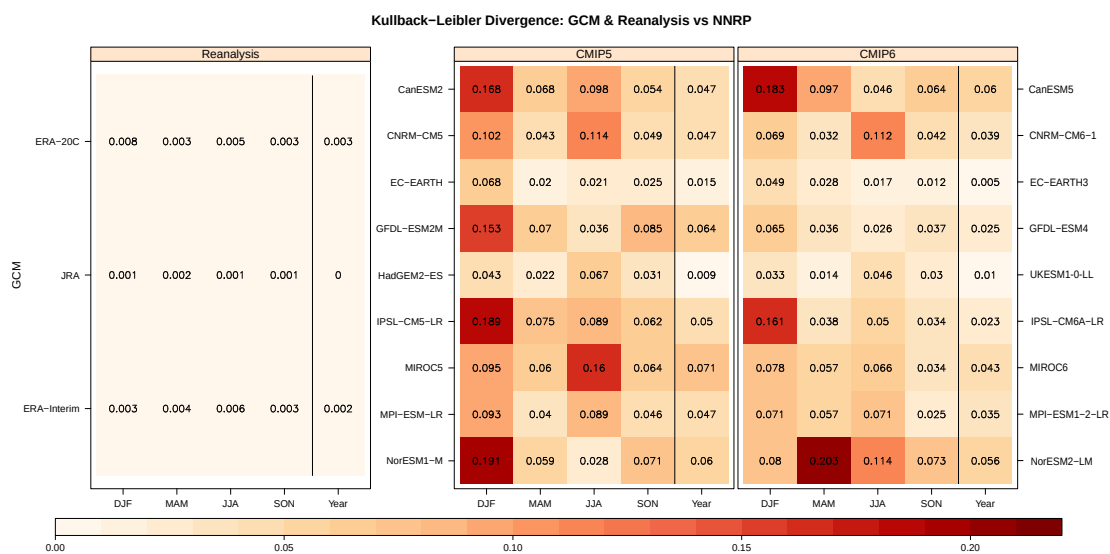


Figura A1: Divergencia de Kullback–Leibler (KL) (valores por estaciones y anuales, por columnas) de los diferentes reanálisis (izquierda) y modelos por experimentos (derecha, CMIP5 y CMIP6) con NNRP.

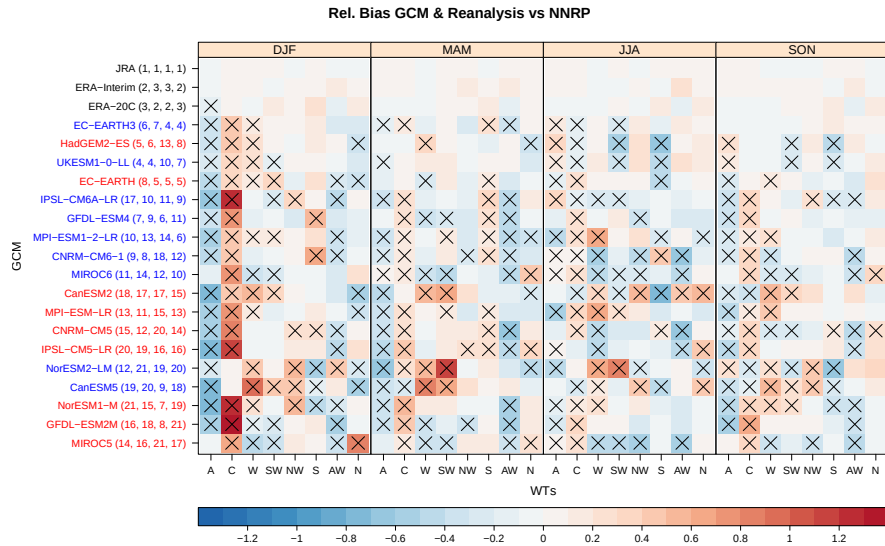


Figura A2: Sesgo Relativo de las frecuencias de los LWTs de los diferentes reanálisis y GCMs respecto a NNRP (en filas: reanálisis en negro, GCMs de CMIP5 en rojo, GCMs de CMIP6 en azul) en las 4 estaciones (DJF, MAM, JJA y SON en columnas). Las filas están ordenadas siguiendo la clasificación de modelos (de menor a mayor) dada por el valor anual de Divergencia de KL de la Figura A1 (las clasificaciones estacionales se dan entre paréntesis). Las cruces indican valores estadísticamente significativos después de ejecutar el Z-Test (Sec.3).

Referencia: JRA

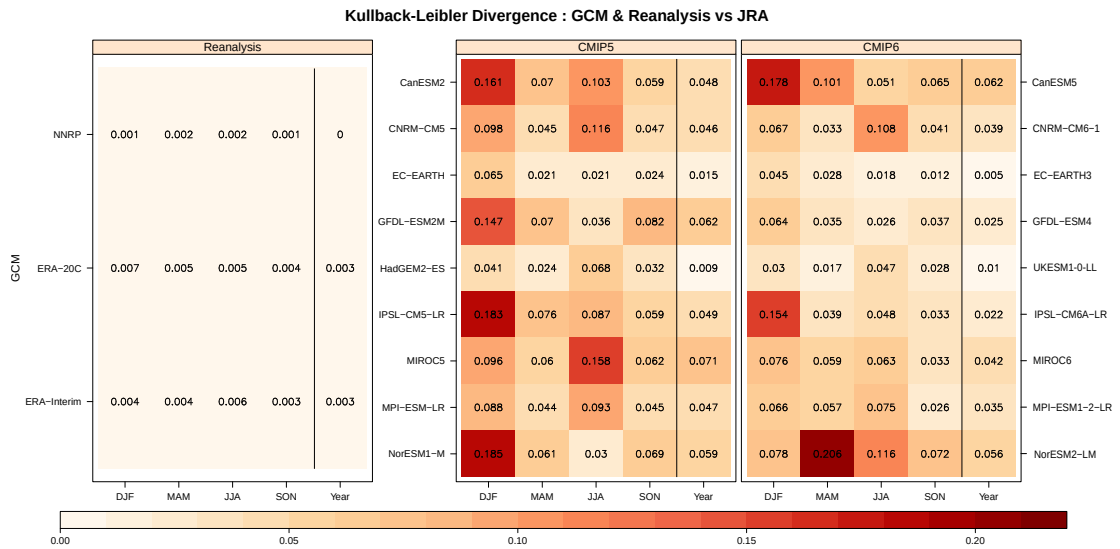


Figura A3: Divergencia de Kullback–Leibler (KL) (valores por estaciones y anuales, por columnas) de los diferentes reanálisis (izquierda) y modelos por experimentos (derecha, CMIP5 y CMIP6) con JRA-55.




Figura A4: Sesgo Relativo de las frecuencias de los LWTs de los diferentes reanálisis y GCMs respecto a JRA-55 (en filas: reanálisis en negro, GCMs de CMIP5 en rojo, GCMs de CMIP6 en azul) en las 4 estaciones (DJF, MAM, JJA y SON en columnas). Las filas están ordenadas siguiendo la clasificación de modelos (de menor a mayor) dada por el valor anual de Divergencia de KL de la Figura A3 (las clasificaciones estacionales se dan entre paréntesis). Las cruces indican valores estadísticamente significativos después de ejecutar el Z-Test (Sec.3).

Referencia: ERA-20C




Figura A5: Divergencia de Kullback-Leibler (KL) (valores por estaciones y anuales, por columnas) de los diferentes reanálisis (izquierda) y modelos por experimentos (derecha, CMIP5 y CMIP6) con ERA-20C.




Figura A6: Sesgo Relativo de las frecuencias de los LWTs de los diferentes reanálisis y GCMs respecto a ERA-20C (en filas: reanálisis en negro, GCMs de CMIP5 en rojo, GCMs de CMIP6 en azul) en las 4 estaciones (DJF, MAM, JJA y SON en columnas). Las filas están ordenadas siguiendo la clasificación de modelos (de menor a mayor) dada por el valor anual de Divergencia de KL de la Figura A5 (las clasificaciones estacionales se dan entre paréntesis). Las cruces indican valores estadísticamente significativos después de ejecutar el Z-Test (Sec.3).

Probabilidades de transición

Probabilidades de transición de los productos de reanálisis

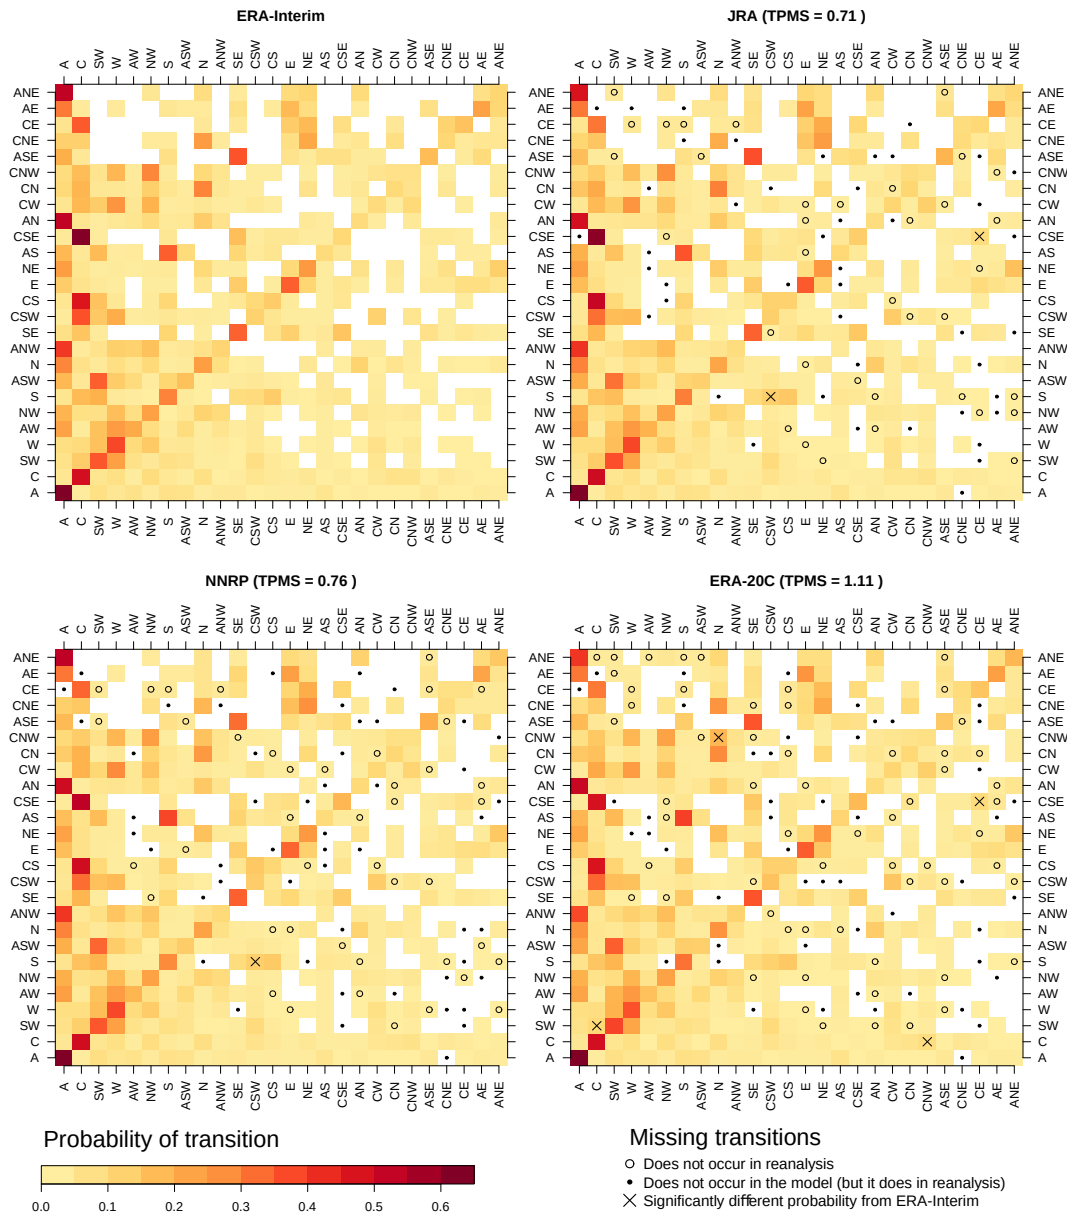



Figura A7: Matrices de probabilidades de transición (TPM) de los productos de reanálisis. Las transiciones que no ocurren se dejan en blanco para diferenciarlas de las transiciones con muy baja probabilidad. Las probabilidades de transición de cada reanálisis son comparadas con las de ERA-Interim, obteniendo así el TPMS. Las probabilidades de transición significativamente diferentes de las de ERA-Interim se indican con cruces. Por otro lado, las transiciones de LWTs presentes en cada reanálisis pero no observadas en ERA-Interim se indican con círculos huecos. Asimismo, los círculos con relleno sólido indican transiciones de LWTs que no están presentes en cada reanálisis, pero sí en ERA-Interim.

Non-observed transitions



- Does not occur in ERA-Interim (n=221)
- Does not occur in NCEP (n=229)
- Does not occur in JRA (n=230)
- ⊕ Does not occur in ERA-20C (n=211)

Figura A8: *Transiciones que no ocurren en los diferentes reanálisis*

Probabilidades de transición de los modelos de CMIP5/CMIP6

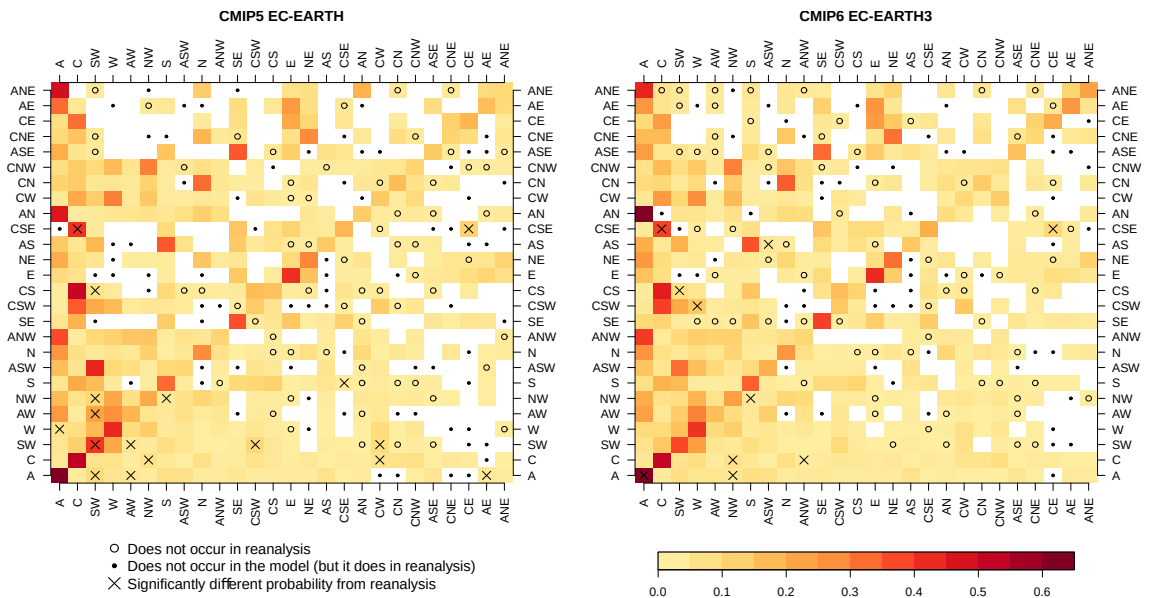


Figura A9: Matrices de probabilidades de transición de EC-EARTH de CMIP5 y EC-EARTH3 de CMIP6.




Figura A10: Matrices de probabilidades de transición de HadGEM2-ES de CMIP5 y UKESM1-0-LL de CMIP6.

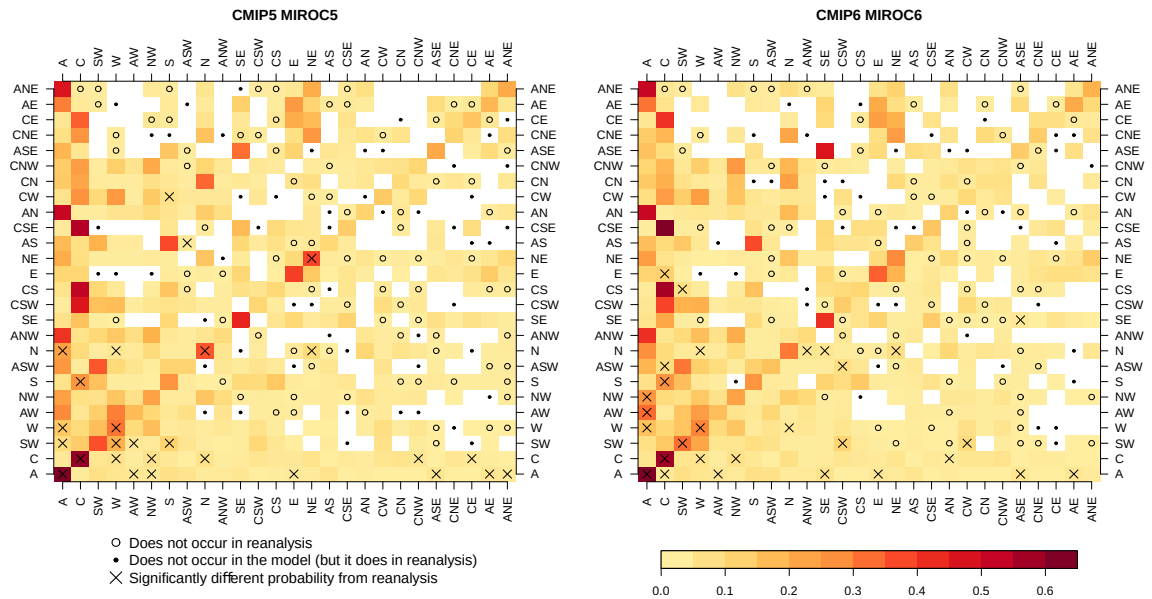


Figura A11: Matrices de probabilidades de transición de MIROC5 de CMIP5 y MIROC6 de CMIP6.

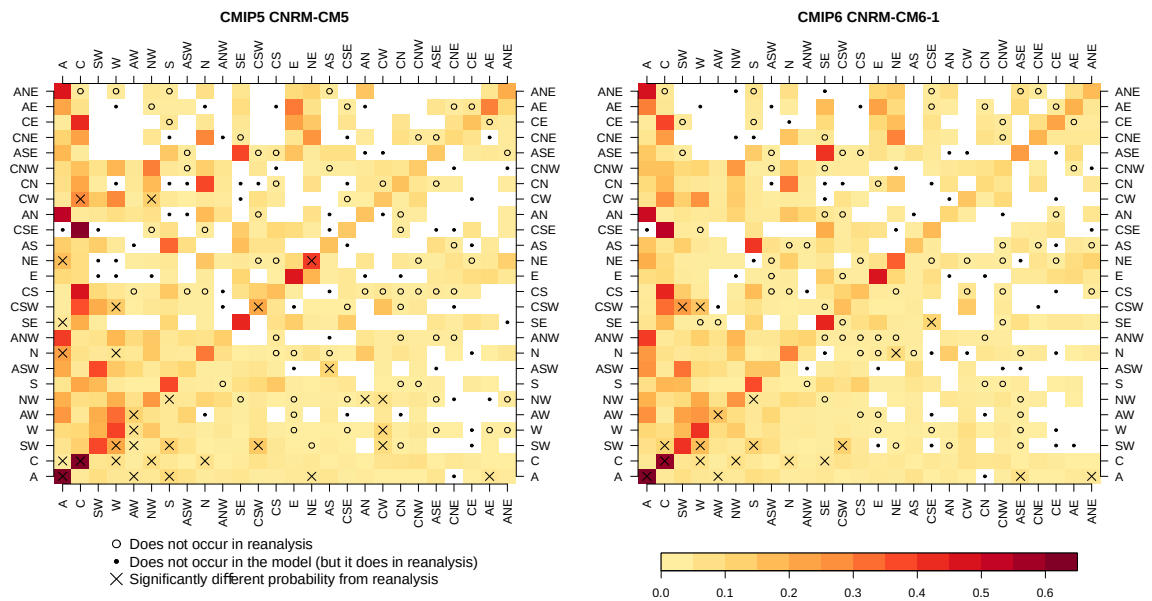


Figura A12: Matrices de probabilidades de transición de CNRM-CM5 de CMIP5 y CNRM-CM6-1 de CMIP6.




Figura A13: Matrices de probabilidades de transición de MPI-ESM-LR de CMIP5 y MPI-ESM1-2-LR de CMIP6.




Figura A14: Matrices de probabilidades de transición de NORESM-M1 de CMIP5 y NORESM2-LM de CMIP6.




Figura A15: Matrices de probabilidades de transición de CANESM2 de CMIP5 y CANESM5 de CMIP6.

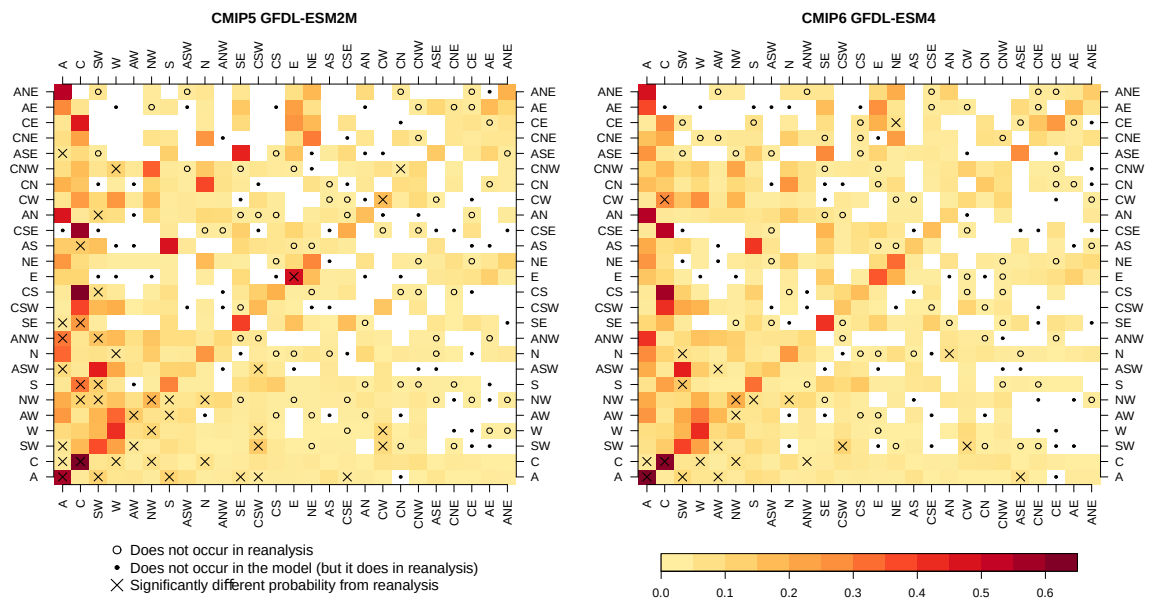


Figura A16: Matrices de probabilidades de transición de GFDL-ESM2M de CMIP5 y GFDL-ESM4 de CMIP6.

Anexo B: Artículo enviado a *Climate Dynamics*

Climate Dynamics

Improved atmospheric circulation over Europe by the new generation of CMIP6 Earth System Models --Manuscript Draft--

Manuscript Number:	CLDY-D-20-00516	
Full Title:	Improved atmospheric circulation over Europe by the new generation of CMIP6 Earth System Models	
Article Type:	Original Article	
Keywords:	weather typing; Lamb Classification; Global Climate Models; process-based validation	
Corresponding Author:	Juan Antonio Fernández-Granja, M.Sc Universidad de Cantabria Santander, Cantabria SPAIN	
Corresponding Author Secondary Information:		
Corresponding Author's Institution:	Universidad de Cantabria	
Corresponding Author's Secondary Institution:		
First Author:	Juan Antonio Fernández-Granja, M.Sc	
First Author Secondary Information:		
Order of Authors:	Juan Antonio Fernández-Granja, M.Sc Ana Casanueva, Ph.D Joaquín Bedia, Ph.D Jesús Fernández, Ph.D	
Order of Authors Secondary Information:		
Funding Information:	INDECIS	Ms. Ana Casanueva
	INSIGNIA	Mr. Jesús Fernández
Abstract:	<p>Global Climate Models (GCMs) generally exhibit significant biases in the representation of large-scale atmospheric circulation. Even after a sensible bias adjustment these errors remain and are inherited to some extent by the derived downscaling products, impairing the credibility of future regional projections. In this study we perform a process-based validation of state-of-the-art GCMs from CMIP5 and CMIP6, with a focus on the simulation of the synoptic climatological patterns having a most prominent effect on the European climate. To this aim, we use the Lamb Weather Type Classification (Lamb, 1972), a subjective classification of circulation weather types constructed upon historical simulations of daily mean sea-level pressure. Observational uncertainty has been taken into account by considering four different reanalysis products of varying characteristics. Our evaluation unveils an overall improvement of salient atmospheric circulation features consistent across observational references, although this is uneven across models and large frequency biases still remain for the main LWTs. Some CMIP6 models attain similar or even worse results than their CMIP5 counterparts, although in most cases consistent improvements have been found, demonstrating the ability of the new models to better capture key persistent synoptic conditions. In light of the large differences found across models, we advocate for a careful selection of driving GCMs in downscaling experiments with a special focus on large-scale atmospheric circulation aspects.</p>	
Suggested Reviewers:	Claas Teichmann Helmholtz-Zentrum Geesthacht Zentrum für Materialforschung und Küstenforschung Climate Service Center claas.teichmann@hzg.de	

Powered by Editorial Manager® and ProduXion Manager® from Aries Systems Corporation

	This reviewer is familiar with EURO-CORDEX topic.
	Martin Wolfgang Jury Karl-Franzens-Universitat Graz martin.jury@uni-graz.at This reviewer is familiar with EURO-CORDEX topic.
	Swen Brands MeteoGalicia swen.brands@gmail.com This reviewer is familiar with Lamb Weather Types topic.
	Pedro Sousa Universidade de Lisboa Faculdade de Ciencias ppsousa@fc.ul.pt This reviewer is familiar with Lamb Weather Types and process-based validation topics.
	Stefan Sobolowski stefan.sobolowski@uni.no This reviewer is familiar with EURO-CORDEX and GCMs/RCMs matrices topics
	Pedro M. M. Soares Universidade de Lisboa Faculdade de Ciencias pmsouares@fc.ul.pt This reviewer is familiar with EURO-CORDEX topic.