UNIVERSIDAD DE CANTABRIA



ESCUELA DE DOCTORADO DE LA UNIVERSIDAD DE CANTABRIA

DOCTORADO EN INGENIERÍA DE COSTAS, HIDROBIOLOGÍA Y GESTIÓN DE SISTEMAS ACUÁTICOS (IH2O)

TESIS DOCTORAL

PREDICCIÓN, DESAGREGACIÓN Y CAMBIO CLIMÁTICO EN LA PRECIPITACIÓN PARA APLICACIONES HIDROLÓGICAS

PhD THESIS

PREDICTION, DISAGGREGATION AND CLIMATE CHANGE IN PRECIPITATION FOR HYDROLOGICAL APPLICATIONS

Presentada por: JAVIER DÍEZ SIERRA

Dirigida por: Dr. MANUEL DEL JESUS PEÑIL

Santander, julio de 2019

Agradecimientos

Gracias a mi director de tesis, Manuel del Jesus, y a mi tutor, Íñigo Losada, por permitirme iniciar mi carrera investigadora; y gracias también a todas las personas que fueron partícipes de este proceso, ya sea de manera directa o indirecta.

Mi mayor agradecimiento es para mis padres, Yolanda Sierra y Ricardo Díez, que me han apoyado y me siguen apoyando en todas las decisiones de mi vida. GRACIAS MAMÁ, GRACIAS PAPÁ.

Gracias a mi hermano, Ricardo Díez, por abrirme las puertas del conocimiento y enseñarme que no todo vale, que hay cosas mejores que otras y que son precisamente esas cosas a las que merece la pena dedicar nuestro tiempo y esfuerzo.

Gracias a mi mujer, mi mejor amiga y el amor de mi vida, Sara Ortega, por hacer que todo parezca tan sencillo a tu lado. ¡La que nos viene encima Rubita!

Por último gracias a la Agencia Estatal de Investigación (AEI) del Ministerio de Economía, Industria y Competitividad, y a la *European Regional Development Fund* (ERDF) por la financiación recibida a través de subvención BIA2016-78397-P (AEI/FEDER, UE).

Resumen

Disponer de datos de precipitación es fundamental para caracterizar la ocurrencia y circulación del agua sobre la superficie terrestre. Cuanto mejor sea la calidad de los datos de precipitación menor será la incertidumbre de los resultados obtenidos en cualquier proyecto de gestión de recursos hídricos, prevención de avenidas, diseño de obras públicas o cálculo de erosión, entre otros.

Sin embargo, es frecuente que a la hora de abordar un proyecto hidrológico, la información disponible de precipitación sea escasa o no cumpla ciertos requerimientos específicos; lo que nos obliga en muchos casos a recurrir a técnicas estadísticas y matemáticas con el objetivo de mejorar su cobertura y resolución espacio-temporal.

En esta tesis vamos a tratar la precipitación en su dimensión temporal. Investigaremos nuevas metodologías y desarrollaremos nuevas herramientas que servirán para tratar las disciplinas de: la predicción temporal de la precipitación, la desagregación temporal, y la incorporación de los efectos del cambio climático a las series de precipitación.

Los resultados alcanzados en el presente documento son de gran utilidad para diferentes tipos de aplicaciones hidrológicas. Como por ejemplo, para aquellas en las que sea necesario conocer la precipitación en el pasado o en el futuro, en un contexto de cambio climático, con el objetivo de gestionar los recursos hídricos de una cuenca; también en aquellas situaciones en las que se requiera implementar un sistema operacional de corto plazo que sirva para predecir el riesgo asociado a determinados eventos extremos de precipitación; o en aquellos casos en los que no se disponga de datos de precipitación a una resolución temporal subdiaria, y no obstante sean requeridos para estudios de inundación o para diseñar el drenaje urbano de una ciudad.

Índice general

Ín	dice	genera	al	Ι					
Ín	ndice de figuras v								
Ín	Índice de tablas XIII								
Li	sta d	e acró	nimos	XVII					
Li	Lista de símbolos xx								
1.	Con 1.1. 1.2. 1.3.	texto, Contez Objeti Estruc	objetivos y estructura de la tesis xto vos etura de la tesis	1 . 1 . 4 . 5					
2.	Esta 2.1. 2.2. 2.3. 2.4.	ado de Bases Predic Desagn Evento	l arte de datos de precipitación: fortalezas y debilidades	7 . 7 . 12 . 15 . 18					
3.	Pree 3.1. 3.2. 3.3. 3.4. 3.5.	dicción Introd Área d Datos Predic 3.4.1. 3.4.2. 3.4.3. 3.4.4. 3.4.5. Predic aprenc 3.5.1.	a estadística de la precipitación ucción le estudio de partida	$\begin{array}{cccccccccccccccccccccccccccccccccccc$					
			I						

			3.5.1.5.	Evaluación de los modelos	59
		3.5.2.	Resultad	los	60
		3.5.3.	Selección	n del mejor modelo	60
		3.5.4.	Predicci	ón de la ocurrencia de la precipitación	65
		3.5.5.	Predicci	ón de la intensidad de lluvia	70
	3.6.	Conclu	usiones .		79
	_				
4.	$\mathbf{Des}_{4,1}$	agrega	ción ten	nporal de la precipitación es España	83 02
	4.1.	Ámaa a	luccion		· · 03
	4.2.	Area ('	00
	4.3.	Datos	de partio		
	4.4.	Desag:	regacion t	emporal de la precipitación en España para el clima prese:	nte 90
		4.4.1.	Metodos	5	
			4.4.1.1.	Leyes de escala	
			4.4.1.2.	Modelo de Beuchat	
			4.4.1.3.	Modelo <i>Random Forests</i>	
			4.4.1.4.	Evaluación de los modelos	96
			4.4.1.5.	Generación sintética de la precipitación	97
		4.4.2.	Resultad	los	99
			4.4.2.1.	Leyes de escala	99
			4.4.2.2.	Comparación de los modelos B y RFB	102
			4.4.2.3.	Resultados obtenidos con el modelo RFB	103
			4.4.2.4.	Simulación sintética de precipitación	108
			4.4.2.5.	Base de datos de estadísticos de precipitación para e	1
			~	clima presente	115
		4.4.3.	Conclus	ones	119
	4.5.	Desag	regación t o climótic	cemporal de la precipitación en España en un contexto de	e 191
		4 5 1	Mátodos	,	191
		4.9.1.	4 5 1 1	Métada dalta da cambia	102
			4.5.1.1.	Page de detes de estadísticos de precipitaciones en Es	123
			4.0.1.2.	base de datos de estadísticos de precipitaciones en Es	- 194
			1513	Análisis do incortidumbro	195
		159	4.0.1.0. Resultse		120
		4.0.2.	1591	Cambio on los estadísticos de precipitación	196
			4.5.2.1.	Análisis de incertidumbre	· · 120
			4.5.2.2.	Frate del incremente de la TAS en los eventos extremes	131
			4.0.2.0.	do precipitación	5 130
		153	Conclus		143 ·
		4.0.0.	Conclus		145
5.	Obs	ervaci	ones fina	lles	147
	5.1.	Conclu	usiones pr	rincipales	147
	5.2.	Contri	buciones	cientificas	156
		5.2.1.	Artículo	s	156
		5.2.2.	Congres	08	157
		5.2.3.	Proyecto	os $I+D+i$ y de transferencia	158
		5.2.4.	Software	e desarrollado	159

	5.2.5.	Bases de datos desarrollada	s.	•				•		 •				•	159
5.3.	Futura	as líneas de investigación .			•	•			•	 •		•	•	.]	160
Biblio	grafía													1	65
DISHO	Brana													-	.00

Índice de figuras

3.1.	Localización de la isla de Tenerife. Fuente: Diez-Sierra y del Jesus (2017).	27
3.2.	Localización de las estaciones pluviométricas disponibles en la isla de Tenerife que fueron utilizas en los diferentes análisis. Los puntos rojos, negros y azules corresponden a series con registros mensuales, diarios y subdiarios, respectivamente, a construction de con	29
33	Número de estaciones con registros de precipitación en el periodo 1900-2015	$\frac{-0}{30}$
3.4.	El cuadro negro corresponde al área seleccionada para los predictores atmosféricos. El cuadro rojo indica el zona donde se localizan las Islas Canarias, Fuente: Figura incluida en un artículo en revisión enviado a la	
	revista Journal of Hydrology Diez-Sierra y del Jesus 2019.	31
3.5.	Esquema metodológico del sistema operacional de predicción a corto plazo	22
3.6.	Gráfico de dispersión entre la precipitación media anual y la elevación para las estaciones con más de 30 años de información durante el periodo	00
	1950-2015	34
3.7.	Precipitación media anual para el periodo 1950-2015 calculada a partir de todas las estaciones pluviométricas con más de 30 años de información	
	disponibles durante dicho periodo.	34
3.8.	Resultados de validación cruzada para el periodo 1950-2015. Los pane- les muestran, de arriba a abajo, las métricas: sesgo estandarizado (Bia- s/Std), error medio cuadrático (BMSE) y correlación de Pearson (B) para	
	(prcp>0.1 mm/día).	36
3.9.	81 tipos de tiempo (WT) seleccionados para la variable presión a nivel del mar (SLP). Fuente: Figura adaptada a partir de los resultados obtenidos	
	en Diez-Sierra y del Jesus (2017)	38
3.10.	Distribución espacial de la probabilidad de lluvia para cada tipo de tor- menta. Fuente: Figura adaptada a partir del artículo Diez-Sierra y del	
	Jesus (2017)	38
3.11.	Distribución espacial de la intensidad de lluvia para cada tipo de tormen- ta. Fuente: Figura adaptada a partir del artículo Diez-Sierra y del Jesus	
	$(2017). \ldots \ldots$	39
3.12.	Pronóstico de GFS para la variable GH500 y para las fechas 2017-06-07, 2017-06-08 y 2017-06-09. Fuente: Figura adapatada a partir del artículo	
	Diez-Sierra y del Jesus (2017).	42
3.13.	Predicción de la probabilidad de lluvia (%) para los días 2017-06-07, 2017- 06-08 y 2017-06-09. El cuadro situado en la esquina inferior izquierda	
	muestra el número del WT correspondiente. Fuente: Figura adaptada a	40
	partir dei articulo Diez-Sierra y dei Jesus (2017)	42

3.14. Predicción de la intensidad de lluvia (mm/día) para los días 2017-06-07, 2017-06-08 y 2017-06-09. El cuadro situado en la esquina inferior izquierda	
muestra en número del WT correspondiente. Fuente: Figura adaptada a	
partir del artículo Diez-Sierra y del Jesus (2017)	43
3.15. Serie reconstruida (línea roja) mediante la técnica WT y observada (línea azul) para la estación "Santiago del Teide", ubicada en la parte noroeste de la isla para el año 2010. La serie reconstruida corresponde a una de las 100 simulaciones. El panel superior muestra la serie diaria mientras que	
el panel inferior corresponde a la media móvil 3-diaria. Fuente: Figura	
adaptada a partir del artículo Diez-Sierra y del Jesus (2017). \ldots	44
3.16. Resultados de <i>f-score</i> durante la validación cruzada para las 17 estacio- nes seleccionadas durante la validación cruzada. Fuente: Diez-Sierra y del	
Jesus (2017)	45
3.17. 35 eventos de lluvia con una intensidad superior a 200 mm/día en el período 1979-2015. Las barras azules y naranjas corresponden al número de eventos con una intensidad mayor 200 mm/día y a la probabilidad de ocurrencia asociada a cada WT, respectivamente. La línea horizontal negra corresponde a la probabilidad de ocurrencia media para los 81 WT.	4.6
 Fuente: Figura adaptada a partir del artículo Diez-Sierra y del Jesus (2017). 3.18. Vista satelital de Tenerife. Los puntos blancos representan la localización de las 17 estaciones seleccionadas para los diferentes análisis. En la imagen satelital se puede observar El Teide y Las Cañadas en el centro de la isla. Fuente: Figura incluida en el artículo en revisión enviado a la revista 	46
Journal of Hudrology Diez-Sierra v del Jesus 2019.	50
3.19. Esquema metodológico seguido para ajustar y evaluar los modelos. Fuen-	
te: Figura adaptada a partir del artículo en revisión enviado a la revista	
Journal of Hydrology Diez-Sierra y del Jesus 2019.	52
3.20. En el panel situado a la izquierda se muestra las funciones seno y coseno, para dos años cualquiera, que han sido utilizadas como predictores adi- cionales en los modelos de regresión. En el panel situado en la derecha se	
muestra el valor de índice NAO anual para lo meses de diciembre a marzo	
en el periodo 1979-2015	53
3.21. Distribución de resultados para las métricas <i>f-score</i> (panel situado a la izquierda) y R (panel situado a la derecha) durante la validación cruzada para toda la combinación completa de hiperparámetros. Cada columna corresponde a un método diferente y cada fila corresponde a una de las	
17 estaciones. Los histogramas y las funciones de densidad, representadas mediante el método Kernel, representan los resultados de <i>f-score</i> (panel de la izquierda) y R (panel de la derecha) para todos los clasificador y regresores, respectivamente. El eje X, de las abscisas, tiene un rango de 0 a 1. La línea discontinua vertical corresponde al valor de 0.5. Fuente: Figura incluida en un artículo en revisión enviado a la revista. <i>Leurnal</i> of	
Hudrology Diez-Sierra y del Jesus 2019	61
3.22. Distribución de probabilidad conjunta para número de días de lluvia al	01
mes mediante las series observadas y simuladas para los diferentes cla- sificadores. Cada panel muestra los resultados para las 17 estaciones al mismo tiempo. La línea discontinua indicaría un ajuste perfecto. Fuen-	
te: Figura adaptada a partir del artículo en revisión enviado a la revista	
Journal of Hydrology Diez-Sierra y del Jesus 2019.	69

3.23.	Distribución de probabilidad conjunta para número de días de lluvia al	
	año mediante las series observadas y simuladas para los diferentes cla-	
	sificadores. Cada panel muestra los resultados para las 17 estaciones al	
	mismo tiempo. La línea discontinua indicaría un ajuste perfecto. Fuen-	
	te: Figura adaptada a partir del artículo en revisión enviado a la revista	
	Journal of Hydrology Diez-Sierra y del Jesus 2019	59
3.24.	Distribución de probabilidad conjunta de la intensidad de lluvia observada	
	y simulada (prcp≤20mm/día) para todos los regresores. Cada panel mues-	
	tra los resultados para las 17 estaciones al mismo tiempo. Los hexágonos	
	con mayor número de datos presentan colores más intensos. Fuente: Figu-	

- ra adaptada a partir del artículo en revisión enviado a la revista Journal of Hydrology Diez-Sierra y del Jesus 2019. 743.25. Distribución de probabilidad conjunta de la intensidad de lluvia observada y simulada (prcp>20mm/día) para todos los regresores. Cada panel muestra los resultados para las 17 estaciones al mismo tiempo. La superficie sombreada en rojo muestra los valores que no están representados en los histogramas al ser estos inferiores a 20 mm/día. Fuente: Figura adaptada a partir del artículo en revisión enviado a la revista Journal of
- Hydrology Diez-Sierra y del Jesus 2019. 753.26. Distribución de probabilidad conjunta de la intensidad de lluvia acumulada mensual para las series observadas y simuladas por los diferentes regresores. Cada panel muestra los resultados para las 17 estaciones al mismo tiempo. La línea discontinua indicaría un ajuste perfecto. Fuente: Figura adaptada a partir del artículo en revisión enviado a la revista Journal of Hydrology Diez-Sierra y del Jesus 2019. 76
- 3.27. Distribución de probabilidad conjunta de la intensidad de lluvia acumulada anual para las series observadas y simuladas por los diferentes regresores. Cada panel muestra los resultados para las 17 estaciones al mismo tiempo. La línea discontinua indicaría un ajuste perfecto. Fuente: Figura adaptada a partir del artículo en revisión enviado a la revista Journal of
- 3.28. Los paneles localizados en la parte superior muestran la correlación espacial observada para todos los regresores y para las 17 estaciones. Los paneles localizados en la parte inferior muestran el ratio en la correlación espacial entre las series simuladas y observadas. De izquierda a derecha cada columna corresponde a una agregación diaria, mensual y anual, respectivamente. Fuente: Figura adaptada a partir del artículo en revisión enviado a la revista Journal of Hydrology Diez-Sierra y del Jesus 2019. . . 78
- 3.29. Precipitación media para las 17 estaciones observadas y simuladas mediante el método Neural Network (NN) a una agregación temporal diaria, mensual y anual, respectivamente. La banda de color rojo representa el área comprendido bajo el cuantil del 5% y del 95% para 100 simulaciones. 78

VII

4.1.	(Izquierda) Localización de las estaciones horarias (735, estrellas) y dia- rias (2896, puntos) utilizadas en el presente análisis y que disponen de información instrumental durante el periodo 1985-2015. (Derecha) Dis- tribución espacial de los tipos de climas existentes en España según la clasificación de Köppen-Geiger realizada por AEMeT (AEMeT, 2011). Los acrónimos mostrados en la leyenda corresponden a los siguientes sub- grupos climáticos: BWh (Árido cálido), BWk (Árido frío), BSh (Semiári- do cálido), BSk (Semiárido frío), Csa (Mediterráneo Típico), Csb (Medi- terráneo Oceánico), Csc (Mediterráneo subalpino con verano seco), Cfa (Subtropical húmedo o sin estación seca), Cfb (Oceánico templado), Dsb y Dfb (Climas hemiboreales), Dsc y Dfc (Climas subárticos) y ET (Tun- dra). Fuente: Figura adaptada a partir del artículo Diez-Sierra y del Jesus	
	$(2019). \ldots \ldots$. 87
4.2.	Esquema metodológico seguido para desagregar las series diarias de pre- cipitación. Primero se genera una base de datos de precipitación horaria para toda España a partir de la información proporcionada por las dis- tintas administraciones mostradas en la Tabla 4.1. Luego, la información horaria es agregada a una resolución diaria y, junto con la información atmosférica, a una resolución mensual, serán utilizadas como predictores para los modelos de regresión (desagregación). Finalmente, los métodos se validan comparando los estadísticos subdiarios observados y simula- dos mediante la técnica de validación cruzada. Fuente: Figura adaptada	
	a partir del artículo Diez-Sierra y del Jesus (2019)	. 91
4.3.	Esquema explicativo del funcionamiento del modelo Neyman-Scott Rec- tangular Pulse Model. El origen de las tormentas siguen un proceso de Poisson con parámetro λ . Asociado a cada tormenta hay un número alea- torio de celdas de lluvia (v) que presentan un retardo respecto al origen de la tormenta y siguen una distribución exponencial de parámetro β . La duración y la intensidad de cada celda de lluvia también sigue una distribución exponencial con parámetros ϵ y χ , respectivamente	. 98
4.4.	Porcentaje de estaciones que ajusta mejor para cada ley de escala según el tipo de clima. La varianza horaria se muestra en el panel superior izquierdo, la varianza 3-h en el panel superior derecho, la varianza 6-h en el panel inferior izquierdo y la varianza 12-h en el panel inferior derecho. Cada ley de escala se representa en el eje abscisas. La altura de las barras representa la proporción de estaciones que mejor ajusta para cada ley de	
	escala	. 100
4.5.	Varianza horaria (paneles superiores) y 12-horaria (paneles inferiores) pre- dicha mediante las leyes de escala. La predicción se realizó con la ley de escala que mejor ajusta para cada estación. Los paneles situados en el lado izquierdo de la figura muestran los diagramas de dispersión para la varianza observada y predicha. Los colores indican el tipo de clima para cada estación. La línea negra discontinua corresponden al ajuste lineal. Los paneles del lado derecho de la figura muestran la distribución de erro-	

4.6.	Resultados del modelo RFB de desagregación para la varianza, proporción de intermolog gange (Pdm), conficiente de esimetría (Skom) y autocorre
	de intervalos secos (Fdry), coenciente de asimetria (Skew) y autocorre-
	lación lag-1 (ACF-lag1) para una agregación temporal horaria (1-h). La
	primera y la tercera columnas muestran los gráficos de dispersión entre
	los valores observados y los predichos. Los colores indican el tipo de clima.
	La línea negra discontinua corresponde al ajuste de regresión lineal. La
	segunda y la cuarta columnas muestran las distribución de errores relati-
	vos (%) a través de funciones de densidad no paramétricas, representadas
	mediante el método Kernel $(err = (Obs^2 - Pred^2)/Obs^2)$. Fuente: Figura
	adaptada a partir del artículo Diez-Sierra y del Jesus (2019) 105
4.7.	Resultados del modelo RFB para predecir las probabilidades de transición

- 4.9. Rendimiento del modelo NSRPM para la varianza (var), proporción de intervalos secos (Pdry) y asimetría (Skew) a una agregación horaria. El color negro corresponde al "escenario exacto"; la línea y los cuadrados de ese mismo color representan, respectivamente, los estadísticos observados y simulados por el modelo NSRPM a una agregación horaria. El color rojo corresponde al "escenario objetivo"; la línea discontinua y los cuadrados de ese mismo color representan, respectivamente, los estadísticos horarios predichos por el modelo RFB y simuladas mediante el modelo NSRPM. El área sombreada en azul muestra el rango de estadísticos obtenido para las 10 simulaciones por modelo NSRPM para el "escenario simple". Cada fila corresponde a una de las 15 estaciones. Fuente: Diez-Sierra y del Jesus (2019).
 4.10. Los resultados se presentan en el mismo formato que los de la Figura 4.9
- - cipitación observadas y simuladas mediante el modelo NSRPM a una agregación horaria. Los puntos negros corresponde a la probabilidad de excedencia de la serie de lluvia observada. Las líneas negras y rojas corresponden a la probabilidad de excedencia para las series sintéticas simuladas por el modelo NSRPM para el "escenario exacto" y para "escenario objetivo", respectivamente. El área de color azul representa el rango de valores de probabilidad de excedencia para las 10 simulaciones para el "escenario simple". Cada panel corresponde a una de las 15 estaciones de precipitación seleccionadas. Fuente: Figura adaptada a partir del artículo Diez-Sierra y del Jesus (2019).

4.12. Esquema metodológico seguido para generar la base de datos de estadísti- cos de precipitación en España. Primero se construye una base de datos de precipitación que combina las series originales diarias con las horarias agregadas a una resolución diaria. La base de datos horaria original, jun- to con la información atmosférica, será utilizada para calibrar el modelo	
RFB y extender la metodología a todas las estaciones con información diaria disponibles. Los estadísticos a una agregación diaria o supradiaria	
son calculados directamente mediante las series instrumentales	. 116
4.13. Estadísticos horarios (1-h) predichos para el mes de enero mediante el modelo RFB para las estaciones diarias y horarias disponibles para el pariado 1086 2005	117
4 14 Estadísticos horarios (1-h) predichos para el mes de julio mediante el	. 117
modelo RFB para las estaciones diarias y horarias disponibles para el	
periodo 1986-2005	. 117
4.15. Esquema metodológico seguido para generar la base de datos de estadísti- cos de precipitación en España para el clima futuro. La metodología es muy simular a la utilizada para el periodo presente (ver Sección 4.4.2.5), con la única diferencia de que en este caso los predictores utilizados en el método RFB para predecir lo estadísticos subdiarios de precipitación,	
fueron previamente actualizados para los diferentes escenarios de cambio	
climático mediante el método delta de corrección de sesgo	. 122
4.16. Los paneles muestran las distribuciones de los estadísticos de precipitación para el clima presente (línea negra discontinua) y para los escenarios RCP 4.5 (línea verde continua) y RCP 8.5 (línea roja continua) a una agrega- ción temporal diaria. Cada una de las funciones densidad, representadas mediante el método Kernel, corresponde a los valores de los estadísticos de precipitación para todas las estaciones (horarias y diarias) calculados de manera independiente para cada mes del año y para todos los RCMs incluidos en la Tabla 4.2. Cada columna corresponde al periodo horizonte de corto-plazo (2016-2035), de medio-plazo (2046-2065) y de largo plazo (2081-2100), respectivamente, y cada fila corresponde a los estadísticos de precipitación: media (μ), varianza (σ), asimetría (γ), proporción de inter- valos secos (Pdry) y probabilidades de transición (ϕ^{DD} y ϕ^{WW}). La línea negra discontinua corresponde a la distribución para el clima presente	
	. 127
4.17.Los resultados se presentan en el mismo formato que los de la Figura 4.16	
pero para una agregación temporal horaria.	. 128
4.18. Varianza horaria (σ_{1-h}) para los cuantiles superiores al percentil 80. La línea negra discontinua corresponde al clima presente (1986-2005), mientras que las líneas de color verde y rojo corresponden a los escenarios RCP	
4.5 y RCP 8.5, respectivamente.	. 129

4.19.	Porcentaje de estaciones con significancia en el cambio (Sgl>1 o Sgl<-1)	
	para el clima BSh (Semiárido cálido) a una agregación diaria y horaria	
	para los escenarios RCP 4.5 y RCP 8.5. Las barras de colores indican el	
	porcentaje de estaciones con valores de Sgl mayores a 1 o menores a -1 para	
	cada uno de los meses del año y para los tres periodos analizados (2016-	
	2035, 2046-2065 y 2081-2100) respecto al periodo de referencia 1986-2005.	
	El color azul indica cambios positivos (Sgl>1) y el rojo negativos (Sgl<-	
	1). Cada color (azul y rojo) se divide a su vez en tres tonalidades: la más	
	clara corresponde al periodo de corto plazo, la que presente una tonalidad	
	intermedia corresponde periodo medio plazo y la de color más intenso	
	corresponde al periodo de largo plazo. Una barra que alcanza un valor	
	de 300 o de -300 indicaría que todas las estaciones muestran significancia	
	en el cambio para ese mes concreto y para los tres periodos temporales	
	analizados. Cada panel muestra el cambio en la media (μ), varianza (σ),	
	asimetría (γ), proporción de intervalos secos (Pdry) y probabilidades de	
	transición $(\phi^{DD} \ge \phi^{WW})$ a una agregación diaria y horaria	. 133
4.20.	La figura presenta la misma información que la Figura 4.19 pero para el	
	clima BSk (Semiárido Cálido).	. 134
4.21.	La figura presenta la misma información que la Figura 4.19 pero para el	
	clima BWh (Árido cálido)	. 135
4.22.	La figura presenta la misma información que la Figura 4.19 pero para el	
	clima Cfa (Subtropical húmedo o sin estación seca). \ldots	. 136
4.23.	La figura presenta la misma información que la Figura 4.19 pero para el	
	clima Cfb (Oceánico Templado).	. 137
4.24.	La figura presenta la misma información que la Figura 4.19 pero para el	
	clima Csa (Mediterráneo Típico)	. 138
4.25.	La figura presenta la misma información que la Figura 4.19 pero para el	
	clima Csb (Mediterráneo Oceánico).	. 139
4.26.	Efecto del incremento en la temperatura superficial del aire (TAS) en la	
	varianza horaria ($\%)$ para cada tipo de clima. Cada panel corresponde	
	a un tipo de clima diferente. El panel situado en la esquina superior	
	izquierda muestra el efecto del aumento en la TAS en todas las estaciones	
	y climas al mismo tiempo	. 140
4.27.	Gráfico de dispersión entre la varianza horaria y el percentil del 99 $\%$ para	
	la precipitación horaria (R99). La figura muestra el resultado para todas	
	las estaciones horarias con información instrumental disponibles. $\ . \ . \ .$. 141
4.28.	Incremento del percentil del 99 ($\%),$ para una varianza horaria dada, en	
	función del aumento de la temperatura superficial del aire (TAS). Cada	
	curva corresponde a un incremento en la TAS de 0.5, 1, 1.5, 2, 2.5, 3, 3.5 $$	
	y 4 °C, respectivamente.	. 142

Índice de tablas

- 2.1. Tabla resumen con los diferentes tipos de bases de datos de precipitación. 11
- 3.1. La tabla muestra el identificador (ID), la elevación (Elev., M), el porcentaje de datos faltantes (% huecos) y la ubicación dentro de la isla (Norte, N; Sur, S; otro, O) de las 17 estaciones utilizadas para realizar los diferentes análisis. Fuente: Tabla adaptada a partir del artículo en revisión enviado a la revista *Journal of Hydrology* Diez-Sierra y del Jesus 2019. . . 51

3.2.	Métodos estadísticos y de aprendizaje automatizados utilizados durante	
	los diferentes análisis. Los nombres de los métodos aparecen en la pri-	
	mera columna; la segunda columna corresponde a las abreviatura de los	
	mismos (Abr.); en la tercera columna se muestra si el método se utiliza	
	como clasificador (C), regresor (R) o ambos (C / R); la cuarta y la quin-	
	ta columna recogen los hiperparámetros y los rangos establecidos para	
	la búsqueda de los hiperparámetros óptimos. Fuente: Tabla adaptada a	
	partir del artículo en revisión enviado a la revista Journal of Hydrology	
	Diez-Sierra y del Jesus 2019.	55
3.3.	Hiperparámetros óptimos para la ocurrencia de la lluvia. Fuente: Tabla adaptada a partir del artículo en revisión enviado a la revista <i>Journal of</i>	
	Hydrology Diez-Sierra y del Jesus 2019.	62
3.3.	Hiperparámetros óptimos para la ocurrencia de la lluvia. (<i>Continuación</i>).	62
3.4.	Hiperparámetros óptimos para la intensidad de la lluvia. Fuente: Tabla	
	adaptada a partir del artículo en revisión enviado a la revista Journal of	
	Hydrology Diez-Sierra y del Jesus 2019.	63
3.4.	Hiperparámetros óptimos para la intensidad de la lluvia. (<i>Continuación</i>).	63
3.5.	Valor de <i>f-score</i> promediado para las 17 estaciones sobre el subconjunto	
	de entrenamiento $(train)$ y prueba $(test)$. Fuente: Tabla incluida en un artículo en revisión enviado a la revista Journal of Hydrology Diez-Sierra	
	y del Jesus 2019.	65
3.6.	Valor de R promediado para las 17 estaciones sobre el subconjunto de en-	
	trenamiento $(train)$ y prueba $(test)$. Fuente: Tabla incluida en un artículo	
	en revisión enviado a la revista Journal of Hydrology Diez-Sierra y del	
	Jesus 2019	65
3.7.	Resultado de <i>f-score</i> para todos los clasificadores y estaciones a una agre-	
	gacion temporar diaria. Fuente: Tabla incluida en un artículo en revision	66
	enviado a la revisia <i>Journal of Hydrology</i> Diez-Sierra y del Jesus 2019	00

XIV		

 Sierra y del Jesus 2019. 3.9. Valor promediado de exhaustividad para las 17 estaciones y para los umbrales de intensidad de precipitación de 0.1, 5, 20 y 40 mm/día. Fuente: Tabla adaptada a partir del artículo en revisión enviado a la revista Journal of Hydrology Diez-Sierra y del Jesus 2019. 3.10. Probabilidades de transición observadas y simuladas (φ^{DD} y φ^{WW}) para todos los clasificadores y estaciones analizadas. Fuente: Tabla incluida en un artículo en revisión enviado a la revista Journal of Hydrology Diez-Sierra y del Jesus 2019. 3.11. Valores de R y RMSE obtenidos entre las series observadas y simuladas mediante los modelos de regresión mostrados en la Tabla 3.2 para las 17 estaciones. Fuente: Tabla incluida en un artículo en revisión enviado a la revista Journal of Hydrology Diez-Sierra y del Jesus 2019. 3.12. Resultados de la prueba t de Student para la métrica RMSE. La letra S indica que hay una diferencia significativa entre los resultados de ambos modelos, mientras que la letra N indica que no. Fuente: Tabla incluida en un artículo en revisión enviado a la revista Journal of Hydrology Diez-Sierra y del Jesus 2019. 3.13. Valores observados y simulados para los estadísticos: media diaria (μ), varianza diaria (σ²), R20 (número de días con precipitaciones superiores a 20 mm) y RX1 (máximo valor de precipitación). Fuente: Tabla incluida en el artículo en revisión enviado a la revista Journal of Hydrology Diez-Sierra y del Jesus 2019. 4.1. La tabla muestra las instituciones que han facilitado la información de precipitación. En la columna N° estaciones, la letra d y la h indican el número de estaciones con información diaria y horaria, respectivamente. Fuente: Tabla adaptada a partir del artículo Diez-Sierra y del Jesus (2019) 4.2. La tabla muestra la institución, el nombre del modelo climático global (GCM) y regional (RCM), la versión, la inicialización, y el dominio para cada uno de los modelos. Los escenarios RCP 4.5 y 8.5 fu	
 Tabla adaptada a partir del artículo en revisión enviado a la revista Journal of Hydrology Diez-Sierra y del Jesus 2019	66
 3.10. Probabilidades de transición observadas y simuladas (φ^{DD} y φ^{WW}) para todos los clasificadores y estaciones analizadas. Fuente: Tabla incluida en un artículo en revisión enviado a la revista Journal of Hydrology Diez-Sierra y del Jesus 2019. 3.11. Valores de R y RMSE obtenidos entre las series observadas y simuladas mediante los modelos de regresión mostrados en la Tabla 3.2 para las 17 estaciones. Fuente: Tabla incluida en un artículo en revisión enviado a la revista Journal of Hydrology Diez-Sierra y del Jesus 2019. 3.12. Resultados de la prueba t de Student para la métrica RMSE. La letra S indica que hay una diferencia significativa entre los resultados de ambos modelos, mientras que la letra N indica que no. Fuente: Tabla incluida en un artículo en revisión enviado a la revista Journal of Hydrology Diez-Sierra y del Jesus 2019. 3.13. Valores observados y simulados para los estadísticos: media diaria (μ), varianza diaria (σ²), R20 (número de días con precipitaciones superiores a 20 mm) y RX1 (máximo valor de precipitación). Fuente: Tabla incluida en el artículo en revisión enviado a la revista Journal of Hydrology Diez-Sierra y del Jesus 2019. 4.1. La tabla muestra las instituciones que han facilitado la información de precipitación. En la columna N° estaciones, la letra d y la h indican el número de estaciones con información diaria y horaria, respectivamente. Fuente: Tabla adaptada a partir del artículo Diez-Sierra y del Jesus (2019) 4.2. La tabla muestra la institución, el nombre del modelo climático global (GCM) y regional (RCM), la versión, la inicialización, y el dominio para cada uno de los modelos. 4.3. Resultados de coeficiente de determinación (R²) calculados mediante la técnica de validación cruzada para la varianza, proporción de intervalos secos (Pdry), asimetría y coeficiente de autocorrelación para los modelos secos (Pdry), asimetría y coeficiente de autocorrelación para los modelos secos (Pdry), asimetría y coeficien	67
 Sierra y del Jesus 2019	
 estaciones. Fuente: Tabla incluida en un artículo en revisión enviado a la revista Journal of Hydrology Diez-Sierra y del Jesus 2019	68
 3.12. Resultados de la prueba t de Student para la métrica RMSE. La letra S indica que hay una diferencia significativa entre los resultados de ambos modelos, mientras que la letra N indica que no. Fuente: Tabla incluida en un artículo en revisión enviado a la revista Journal of Hydrology Diez-Sierra y del Jesus 2019	70
 Sierra y del Jesus 2019. 3.13. Valores observados y simulados para los estadísticos: media diaria (μ), varianza diaria (σ²), R20 (número de días con precipitaciones superiores a 20 mm) y RX1 (máximo valor de precipitación). Fuente: Tabla incluida en el artículo en revisión enviado a la revista Journal of Hydrology Diez-Sierra y del Jesus 2019. 4.1. La tabla muestra las instituciones que han facilitado la información de precipitación. En la columna N° estaciones, la letra d y la h indican el número de estaciones con información diaria y horaria, respectivamente. Fuente: Tabla adaptada a partir del artículo Diez-Sierra y del Jesus (2019) 4.2. La tabla muestra la institución, el nombre del modelo climático global (GCM) y regional (RCM), la versión, la inicialización, y el dominio para cada uno de los modelos utilizados. Los escenarios RCP 4.5 y 8.5 fueron analizados para cada modelo. 4.3. Resultados de coeficiente de determinación (R²) calculados mediante la técnica de validación cruzada para la varianza, proporción de intervalos secos (Pdry), asimetría y coeficiente de autocorrelación para los modelos B w PEB. Las latras an nagrita corresponde al meior recultado para cada 	
 4.1. La tabla muestra las instituciones que han facilitado la información de precipitación. En la columna N° estaciones, la letra d y la h indican el número de estaciones con información diaria y horaria, respectivamente. Fuente: Tabla adaptada a partir del artículo Diez-Sierra y del Jesus (2019) 4.2. La tabla muestra la institución, el nombre del modelo climático global (GCM) y regional (RCM), la versión, la inicialización, y el dominio para cada uno de los modelos utilizados. Los escenarios RCP 4.5 y 8.5 fueron analizados para cada modelo. 4.3. Resultados de coeficiente de determinación (R²) calculados mediante la técnica de validación cruzada para la varianza, proporción de intervalos secos (Pdry), asimetría y coeficiente de autocorrelación para los modelos R v REB. Las latras en negrita corresponde al maior regultado para cada 	71
 precipitación. En la columna N° estaciones, la letra d y la h indican el número de estaciones con información diaria y horaria, respectivamente. Fuente: Tabla adaptada a partir del artículo Diez-Sierra y del Jesus (2019) 4.2. La tabla muestra la institución, el nombre del modelo climático global (GCM) y regional (RCM), la versión, la inicialización, y el dominio para cada uno de los modelos utilizados. Los escenarios RCP 4.5 y 8.5 fueron analizados para cada modelo	12
 4.2. La tabla muestra la institución, el nombre del modelo climático global (GCM) y regional (RCM), la versión, la inicialización, y el dominio para cada uno de los modelos utilizados. Los escenarios RCP 4.5 y 8.5 fueron analizados para cada modelo	88
 analizados para cada modelo. 4.3. Resultados de coeficiente de determinación (R²) calculados mediante la técnica de validación cruzada para la varianza, proporción de intervalos secos (Pdry), asimetría y coeficiente de autocorrelación para los modelos B v BEB. Las latras en negrita corresponde al major regultado para cada 	
4.3. Resultados de coeficiente de determinación (R^2) calculados mediante la técnica de validación cruzada para la varianza, proporción de intervalos secos (Pdry), asimetría y coeficiente de autocorrelación para los modelos B v BEB. Las latras en negrita corresponde al meior regultado para cada	89
clima y estadístico. Las agregaciones 1-h y 12-h son analizadas en la tabla.	109

4.4.	Predictores utilizados (primera columna) por los modelos B y RFB (en-	
	cabezado) para predecir los estadísticos subdiarios de precipitación. Los	
	predictores son: precipitación media diaria (μ_{24}), varianza diaria (σ_{24}),	
	proporción de días secos (ϕ_{24}) , proporción de dos días secos (ϕ_{48}) , asi-	
	metría diaria (γ_{24}), coeficiente de autocorrelación diaria lag-1 (ρ_{24}^1), pro-	
	babilidad de dos días húmedos consecutivos (ϕ_{24}^{WW}) , probabilidad de dos	
	días secos consecutivos (ϕ_{24}^{DD}) , promedio mensual de la temperatura su-	
	perficial del aire (TAS), varianza de la temperatura superficial del aire	
	(σ_{TAS}) , humedad relativa del aire (HUR) y elevación. Los predictandos	
	son: varianza (σ_T), proporción de intervalos secos (ϕ_T), asimetría (γ_T),	
	coeficiente de autocorrelación temporal lag-1 (ρ_T^1) , probabilidad de dos	
	intervalos húmedos consecutivos (ϕ_T^{WW}) y la probabilidad de dos inter-	
	valos secos consecutivos (ϕ_T^{DD}) para las agregaciones temporales T=[1-h,	
	2-h, 3-h, 6-h, 12-h]. Las celdas con color indican que esa variable ha sido	
	utilizada como predictor para predecir un predictando determinado. El	
	color rojo hace referencia al modelo B v el color verde hace referencia al	
	modelo RFB. Fuente: Figura adaptada a partir del artículo Diez-Sierra v	
	del Jesus (2019). \ldots	. 104
4.5.	Coeficiente de determinación (R^2) calculado mediante la técnica de valida-	
	ción cruzada 10-fold cross-validation para las probabilidades de transición	
	a una resolución temporal horaria (1-h) y 12-horaria (12-h) mediante el	
	modelo RFB. Fuente: Tabla adaptada a partir del artículo Diez-Sierra y	
	del Jesus (2019).	. 108
4.6.	Conjunto de estadísticos utilizados para ajustar el modelo NSRPM y sus	
	pesos asociados. Las letras d y h indican una agregación diaria y horaria,	
	respectivamente. Fuente: Tabla adaptada a partir del artículo Diez-Sierra	
	y del Jesus (2019).	. 109
4.7.	Predictores utilizados (primera columna) por el modelo RFB para la pre-	
	decir la precipitación subdiaria para el clima futuro. Los predictores son:	
	precipitación media diaria (μ_{24}) , varianza diaria (σ_{24}) , proporción de días	
	secos (ϕ_{24}), proporción de dos días secos (ϕ_{48}), asimetría diaria (γ_{24}), pro-	
	babilidad de dos días húmedos consecutivos (ϕ_{24}^{WW}), probabilidad de dos	
	días secos consecutivos (ϕ_{24}^{DD}) , promedio mensual de la temperatura su-	
	perficial del aire (TAS). Los predictandos son: varianza (σ_T), proporción	
	de intervalos secos (ϕ_T) , asimetría (γ_T) , probabilidad de dos intervalos	
	húmedos advacentes (ϕ_{WW}^{WW}) y la probabilidad de dos intervalos secos ad-	
	vacentes (ϕ_{T}^{DD}) para las agregaciones temporales T=[1-h, 2-h, 3-h, 6-h,	
	12-h]. Las celdas sombreadas indican que la variable ha sido utilizada	
	como predictor para predecir un estadístico determinado.	. 125
48	Cambio porcentual en los estadísticos de precipitación promediado para	0
1.0.	todas las estaciones y RCMs respecto al periodo de referencia 1986-2005	
	Los estadísticos analizados son: media (μ) varianza (σ) asimetría (γ)	
	proporción de intervalos secos (ϕ) y probabilidades de transición (ϕ^{DD}	
	$v \phi^{WW}$). Los resultados han sido analizados a una agregación diaria v	
	horaria, respectivamente.	. 132
		. 102

XV

Lista de acrónimos

AEMeT	Agencia Estatal de Meteorología
\mathbf{AMSU}	Advanced Microwave Sounding Unit
AR4	IPCC Fourth Assessment Report
AR5	IPCC Fifth Assessment Report
\mathbf{BSh}	Semiárido cálido
\mathbf{BSk}	Semiárido frío
\mathbf{BWh}	Árido cálido
\mathbf{BWk}	Árido frío
ECC	Ecuación de Clausius-Clapeyron
\mathbf{CFSR}	Climate Forecast System Reanalysis
CIATE	Consejo Insular de Aguas de Tenerife
CMIP3	Coupled Model Intercomparison Project phase 3
CMIP5	Coupled Model Intercomparison Project phase 5
Cfa	Subtropical húmedo o sin estación seca
$\mathbf{Cfb}\ \ldots\ \ldots\ \ldots$	Oceánico templado
Csa	Mediterráneo típico
Csb	Mediterráneo oceánico
\mathbf{Csc}	Mediterráneo subalpino con verano seco
D	Clima de montaña
EOS	Earth Observing System
ET	Tundra
$\mathbf{GCM} \ldots \ldots$	Global Climático Model (Modelo Climático Global)
\mathbf{GCV}	Generalized Cross Validation
GFS	Global Forecast System

$GH \ . \ . \ . \ . \ .$	Geopotential Height (Altura Geopotencial)
GHCN	Global Historical Climatology Network
$\mathbf{GLM}\ .\ .\ .\ .$	Generalized Linear Model (Modelo Lineal Generalizado)
GPCP	Global Precipitation Climatology Project
$\mathbf{GPM}\ .\ .\ .\ .$	Global Precipitation Measurement
$\mathbf{HUR}\ .\ .\ .\ .$	Humedad Relativa
$\mathbf{IDW} \ . \ . \ . \ .$	Inverse Distance Weighting (Distancia Inversa Ponderada)
IPCC	Intergovernmental Panel on Climate Change (Panel Interguberna- mental de Cambio Climático)
JAXA	Japan Aerospace Exploration Agency
k-NN	k-nearest neighbors
$\mathbf{LR} \ldots \ldots \ldots$	Logistic Regression (Regressión Logística)
MARS	Multivariate Adaptive Regression Splines
$\mathbf{ML}\ \ldots\ \ldots\ \ldots$	Machine Learning (Máquinas de Aprendizaje Automatizado)
NAO	North Atlantic Oscillation (Oscilación del Atlántico Norte)
NASA	National Aeronautics and Space Administration
NCEP	National Centers for Environmental Prediction
NN	Neural Network (Red Neuronal Artificial)
NOAA	National Oceanic and Atmospheric Administration
\mathbf{NSRPM}	Neyman-Scott Rectangular Pulse Model
ОК	Ordinary Kriging
$\mathbf{PC} \ldots \ldots \ldots$	Poisson Cluster
PCA	Principal Component Analysis (Análisis de Componentes Principales)
PRCP	Precipitación
\mathbf{Sgl}	Signal to noise Ratio
SLP	Sea Level Pressure (Presión a Nivel del Mar)
STNSRP	Spatial-Temporal Neyman-Scott Rectangular Pulses
\mathbf{SVM}	Support Vector Machine (Máquinas de Vectores Soporte)
RCM	Regional Climatic Model (Modelo Climático Regional)
RCP	Representative Concentration Pathways (Vía de Concentración Representativa)

\mathbf{RF}	Random Forests
RMSE	Root Mean Square Error (Error Cuadrático Medio)
TRMM	Tropical Rainfall Measuring Mission
TAS	Surface Air Temperature (Temperatura Superficial del Aire)
UK	Universal Kriging
Uwnd	Zonal wind speed component (Componente Zonal de la Velocidad del Viento)
Vwnd	Meridional wind speed component (Componente Meridional de la Velocidad del Viento)
WG	Weather Generator (Generadores de Tiempo)
WRCP	World Climate Research Programme
WRF	Weather Research and Forecasting model
WT	Weather Type (Tipo de Tiempo)

Lista de símbolos

μ	Media o momento central
σ	Varianza
ACF-lag h	Autocorrelación temporal lag-h
$ ho_h$	Autocorrelación temporal lag-h
Skew \ldots .	Asimetría
γ	Asimetría
Mo	Moda
R	Correlación de Pearson
R^2	Coeficiente de determinación
R20	Número de días con precipitaciones superiores a 20 mm
RX1	Máximo valor de precipitación
ϕ	Proporción de intervalos secos
$\mathbf{Pdry} \ \ldots \ \ldots \ .$	Proporción de intervalos secos
ϕ^{WW}	Probabilidad de ocurrencia de dos períodos consecutivos de lluvia
ϕ^{DD}	Probabilidad de ocurrencia de dos períodos consecutivos de sequía
1-h	Agregación temporal horaria
1-d	Agregación temporal diaria

Capítulo 1

Contexto, objetivos y estructura de la tesis

1.1. Contexto

La precipitación en cualquiera de sus formas, lluvia, llovizna, nieve, aguanieve y granizo, es el principal aporte de agua dulce a la superficie terrestre, y se considera, desde el punto de vista de la ingeniería hidrológica, la variable hidrometeorológica más importante ya que constituye generalmente la única entrada de agua a una cuenca. Su medición y tratamiento es el punto de partida de la mayoría de estudios concernientes al uso y control del agua; ya sea para cuantificar los recursos hídricos, prevenir avenidas, diseñar obras públicas o acometer estudios de erosión, es necesario disponer de datos de precipitación para caracterizar adecuadamente la ocurrencia y circulación del agua sobre la superficie terrestre.

Independientemente de su origen¹, la información de precipitación se puede obtener de diversas fuentes, siendo la más común y fiable la que procede de su medición directa por medio de estaciones meteorológicas situadas en el terreno (pluviómetros). Sin embargo, en muchas ocasiones dicha información es escasa en el espacio y en el tiempo y presenta una resolución temporal muy grosera debido principalmente al elevado coste de instrumentación y a la falta de medios de automatización existentes en el pasado. Existen otras fuentes de información o bases de datos de precipitación con cobertura global,

¹En relación a su origen, pueden distinguirse principalmente tres tipos de precipitación: ciclónica, asociada a una borrasca o un ciclón, convectiva, producida por el ascenso de masas de aire caliente, y orográfica, presente cuando una masa de aire húmedo se ve obligada a ascender por una cadena montañosa.

como aquellas procedentes de modelos climáticos y de mediciones satelitales. No obstante, estas fuentes de información deben ser utilizadas con cautela ya que generalmente presentan grandes sesgos.

La escasez de información de precipitación disponible a la hora de abordar la mayoría de estudios hidrológicos nos obliga a recurrir en muchos casos a técnicas estadísticas y modelos matemáticos con el objetivo de mejorar su cobertura y resolución espaciotemporal. Sin embargo, caracterizar la precipitación para una área determinada o tratar de estimar su magnitud para una localización e instante concreto puede resultar una tarea muy compleja ya que es una variable que presenta una elevada variabilidad espaciotemporal; pudiendo variar su magnitud significativamente en un centenar de metros y en unos pocos segundos.

Debido a la necesidad de disponer de datos de precipitación que cumplan unos requerimientos específicos, y también debido a que es una variable que presenta un comportamiento estadístico muy complejo, muchos expertos han dedicado y siguen dedicando gran parte de su tiempo a la caracterización de la precipitación. Esta disciplina es muy extensa y sería imposible tratar de abordarla desde una perspectiva holística. Sin embargo, pueden diferenciarse una serie de ramas de conocimiento o disciplinas que han sido ampliamente estudiadas en las últimas décadas. Las más importantes serían la homogeneización y el control de calidad de las series de precipitación, la estimación areal de la precipitación a partir de datos puntuales, la interpolación espacial, la predicción temporal, la generación sintética de series de precipitación, la desagregación temporal, el modelado numérico y toda la rama del conocimiento que está relacionada con el cambio climático y la precipitación. La mayor parte de estas disciplinas podrían ser aplicadas a otras variables hidrometeorológicas, como por ejemplo la temperatura superficial del aire o la velocidad del viento; sin embargo, el comportamiento estadístico tan característico de la precipitación (intermitencia², elevada asimetría y baja correlación espacio-temporal, entre otras) hace que muchas de las técnicas y metodologías asociadas a cada una de las disciplinas estén desarrolladas específicamente para tratar dicha variable. En definitiva, el propósito de todas estas disciplinas es el mismo, tratar de obtener los mejores datos de precipitación para resolver un problema específico.

Por otro lado, la capacidad computacional de los ordenadores disponible a día de hoy, la incorporación de técnicas basadas en algoritmos de aprendizaje automatizado, la aparición de nuevas fuentes de información procedentes de modelos climáticos, de satélites y de radares, así como la incertidumbre asociada a los efectos del cambio climático sobre

 $^{^{2}}$ A diferencia de la mayoría de variables hidrometeorológicas, como por ejemplo la temperatura superficial del aire o la humedad, la precipitación tiene un comportamiento estadístico intermitente, o lo que es lo mismo se interrumpe y luego aparece de nuevo. Esta característica hace que tenga que ser tratada de manera diferente al resto de variables.

la disponibilidad de recursos hídricos en el futuro; ponen de manifiesto la necesidad de investigar nuevos métodos capaces de mejorar los ya existentes y de aportar las herramientas necesarias para que puedan ser aplicados sin necesidad de comprender todos los aspectos matemáticos y estadísticos a los que están sujetos.

En esta tesis se tratará en profundidad la precipitación en su dimensión temporal. Se investigará principalmente la disciplina de la predicción temporal, de la desagregación y de la precipitación en un contexto de cambio climático.

La predicción temporal tiene como objetivo estimar la precipitación en el pasado o en el futuro usando generalmente para ello la información de precipitación disponible en el presente. En este contexto se analizará la capacidad de diferentes modelos estocásticos y algoritmos de aprendizaje automatizado para realizar dos tipos de predicciones claramente diferenciadas. Una predicción a corto plazo, para una ventana temporal de 1 a 3 días vista, y una predicción a largo plazo, cuyo objetivo es reconstruir la precipitación en el pasado durante varias décadas. La predicción a corto plazo es fundamental para prever eventos extremos de precipitación y reducir su riesgo asociado. Además este tipo de predicción es el que normalmente se utiliza para dar el pronóstico del tiempo. Por otro lado, la predicción a largo plazo es muy útil en la gestión de los recursos hídricos así como para detectar posibles tendencias existentes en los datos y comprender el origen de eventos con una probabilidad de ocurrencia muy baja, como las sequías o los eventos más extremos de precipitación.

La desagregación temporal tiene como objetivo aumentar la resolución temporal de las series de precipitación disponibles. Los datos de precipitaciones a una agregación temporal horaria o minutal, son esenciales para aplicaciones en muchos campos, como la hidrología urbana, el diseño de infraestructuras y los estudios de evaluación de riesgos, entre otros campos. En este contexto, se desarrollará una metodología para generar series de precipitación horarias en cualquier localización a partir de información diaria. La metodología ha sido aplicada en España aprovechando la extensa red de estaciones meteorológicas con datos diarios disponibles. Los resultados alcanzados son muy interesantes para estudios de extremos o para acometer estudios de inundación en aquellas cuencas donde no se disponga de información subdiaria de precipitación y además donde los caudales picos de avenida vengan determinados por eventos de muy corta duración.

Por último, se analizará la precipitación en un contexto de cambio climático; investigaremos su efecto desde un punto de vista estadístico y analizaremos los resultados para diferentes escenarios de cambio climático en el territorio español. Los resultados muestran que es probable que para mediados y finales del siglo XXI los eventos más extremos de precipitación se vuelvan más frecuentes como efecto del aumento de la temperatura superficial del aire. Sin embargo, únicamente encontramos resultados significativos a agregaciones temporales por debajo del día y para algunos tipos de clima y meses del año determinados.

La elección de las disciplinas tratadas en la presente tesis (predicción temporal, desagregación y cambio climático) no ha sido trivial. Está motivada porque son ramas del conocimiento que tratan de resolver una serie de cuestiones a las que cualquier técnico podría tener que enfrentarse en un momento determinado. ¿Qué probabilidad hay de tener un evento extremo de precipitación en los próximos tres días?, ¿es posible conocer la lluvia que tuvo lugar en el pasado si no se dispone de registros instrumentales para esas fechas?, ¿cómo se podría aumentar la resolución temporal de la series diarias de precipitación?, y ¿cuál será el efecto del cambio climático sobre los regímenes de precipitación a distintas escalas temporales de agregación en España?.

1.2. Objetivos

En base a las problemáticas anteriormente mencionadas, la tesis tiene como objetivo general investigar nuevas metodologías y desarrollar nuevas técnicas que sirvan para caracterizar la precipitación y poner a disposición pública datos de precipitación con la mayor calidad posible para aplicaciones hidrológicas. Dentro de este objetivo general es posible distinguir cuatro objetivos específicos:

Objetivo 1: Implementar una herramienta de fácil manejo que sirva para evaluar el riesgo asociado a eventos extremos de precipitación en un marco temporal de corto plazo (de 1 a 3 días vista).

Objetivo 2: Investigar el potencial de diferentes técnicas estadísticas y algoritmos de aprendizaje automatizado (*Machine Learning* o ML, por sus siglas en inglés) para realizar predicciones a largo plazo con el objetivo de reconstruir varias décadas de precipitación diaria en el pasado.

Objetivo 3: Investigar una metodología que permita generar series de precipitación horarias en cualquier estación pluviométrica de España con información diaria.

Objetivo 4: Ampliar el objetivo número 3 en una contexto de cambio climático y desarrollar una metodología que permita generar series de precipitación horarias para diferentes escenarios de cambio climático en cualquier estación de España con información diaria.

Cada uno de los 4 objetivos específicos coincide con una sección principal de la tesis. Estas secciones conforman el grueso del documento y son: Sección 3.4 "Predicción probabilística a corto plazo basada en tipos de tiempo", Sección 3.5 "Predicción a largo plazo mediante modelos estadísticos y máquinas de aprendizaje automatizado", Sección 4.4 "Desagregación temporal de la precipitación en España para el clima presente", y Sección 4.5 "Desagregación temporal de la precipitación en España en un contexto de cambio climático".

1.3. Estructura de la tesis

El documento de tesis se organiza en 5 bloques o capítulos principales: (1) Contexto, objetivos y estructura de la tesis (capítulo en el que el lector se encuentra ahora mismo), (2) Estado del arte, (3) Predicción estadística de la precipitación, (4) Desagregación temporal de la precipitación y (5) Observaciones finales. En esta sección se presenta cada uno de los capítulos que definen el documento de tesis que son:

Capítulo 1 - Contexto, objetivos y estructura de la tesis

Es el capítulo en el que nos encontramos ahora mismo. En el se presentan las principales motivaciones del autor para realizar la tesis, se pone en contexto la misma, se presentan los principales objetivos y se define la estructura del documento.

Capítulo 2 - Estado del arte

Proporciona una revisión general de los conocimientos actuales sobre las diferentes bases de datos de precipitación disponibles a día de hoy, sobre los métodos de predicción espacial y temporal de la precipitación, sobre las técnicas de desagregación temporal de la precipitación y sobre el efecto del cambio climático sobre los regímenes de precipitación en España.

Capítulo 3 – Predicción estadística de la precipitación

Este capítulo recoge los objetivos específicos 1 y 2. Por un lado se presenta una herramienta que ha sido implementada en el Consejo Insular de Aguas de Tenerife (CIATF) para la evaluación de riesgos asociados a la ocurrencia de extremos de precipitación. Y por el otro, se evalúan la capacidad predictiva de un conjunto de modelos estadísticos y de algoritmos de aprendizaje automatizado para reconstruir varias décadas de precipitación en el pasado (precipitación a largo plazo).

Capítulo 4 – Desagregación temporal de la precipitación en España

Este capítulo recoge los objetivos específicos 3 y 4. En el se presenta una metodología que sirve para generar series sintéticas horarias de precipitación en cualquier estación de España con información diaria para el clima presente y para diferentes escenarios de cambio climático. También se analiza el efecto del aumento de la temperatura superficial del aire en los eventos más extremos de precipitación en España.

Capítulo 5 – Observaciones finales

Se presentan las principales conclusiones de la tesis, se revisan los principales resultados y contribuciones derivadas de la misma (artículos, comunicaciones en congresos, participación en proyectos de transferencia, bases de datos generadas y software desarrollados). Por último introduce también las futuras líneas de investigación.

Capítulo 2

Estado del arte

2.1. Bases de datos de precipitación: fortalezas y debilidades

Existen a día de hoy principalmente cuatro tipos de bases de datos de precipitación. Las redes de estaciones meteorológicas, las bases de datos satelitales, las observaciones de radares terrestres y las bases de datos de precipitación generadas a partir de modelos climáticos. Cada una tiene un origen completamente diferente y están sujetas a una serie de incertidumbres y limitaciones que se describen a continuación.

Las redes de estaciones para la recogida y medición de la precipitación están formadas por instrumentos de medida distribuidos a lo largo de un territorio determinado. Hoy en día los más utilizados son los pluviómetros digitales, que nos permiten medir la precipitación total y al mismo tiempo también su intensidad. Pueden ser pluviómetros asociados a estaciones meteorológicas automáticas o bien instrumentales instalados de forma individual y conectada eléctricamente o inalámbricamente a una central receptora. La estaciones automáticas o pluviómetros automáticos miden la intensidad de precipitación (mm/h) en intervalos de minutos u horaria, lo que es una mejora muy importante en comparación con otros instrumentos de medida como los pluviómetros tradicionales con una resolución temporal generalmente diaria. Este tipo de tecnología es sin embargo relativamente reciente, por lo que es bastante difícil encontrar series subdiarias con una cobertura temporal de varias décadas. Además, la densidad de este tipo de instrumentos en comparación con los pluviómetros tradicionales es muy inferior, lo que se debe principalmente al coste de instrumentación y a la falta de medios en el pasado para automatizar los procesos (Pui et al., 2012). Los registros instrumentales de precipitación son generalmente los más utilizados para cualquier estudio hidrológico ya que, al margen de los errores de medida y otros errores propios de este tipo de instrumentos¹, siguen siendo la fuente de información más fiable a día de hoy. Hay que tener en cuenta que son mediciones puntuales que en muchos casos no cubren adecuadamente nuestro área de interés, y que en el caso en el que fuera necesario conocer la precipitación en una zona en concreto donde no existen datos, habría que acudir a técnicas matemáticas o estadísticas de estimación areal y de interpolación (Tabios y Salas, 1985b). Generalmente cada país o región dispone de su propia red de pluviómetros que pueden estar disponibles o no para el público general. Podemos encontrar diferentes bases de datos con una cobertura global, como por ejemplo la base de datos GHCN-*Daily* (*Global Historical Climatology Network*) compuesta por registros climáticos diarios de numerosas fuentes y que contiene registros de más de 100.000 estaciones en 180 países y territorios con una cobertura temporal que varía desde 1 mes hasta 175 años (Menne et al., 2012).

También existen otras bases de datos que son el resultado de aplicar técnicas de interpolación a partir de registros instrumentales y que pueden tener una cobertura global o regional. Estas bases de datos reciben el nombre de bases de datos interpoladas o de cuadrícula (Gridded datasets en inglés). A nivel global podemos encontrar la base de dato interpolada GPCC (Global Precipitation Climatology Centre) con celdas regulares de 1° (1° \approx 100 km) y que cubre el periodo 1988-2013 (Schamm et al., 2016). A nivel regional existen también diferentes productos, como es el caso de la base de datos Spain02 para España que cubre el periodo 1950-2010 en celdas regulares de 0.1° de resolución (Herrera et al., 2012b). La calidad de estos productos derivados está sujeta a la densidad de estaciones disponibles y a la técnica de interpolación utilizadas para su realización; no tienen en cuenta muchos de los procesos de microescala² y no deben ser interpretados como estimaciones puntuales ya que están agregados (suavizados) para una área determinada (del Jesus et al., 2015). Además, otra de las limitaciones de este tipo de productos es que en el mejor de los casos presentan una resolución temporal diaria; por lo que no deberían ser utilizadas directamente para ciertos fines, como por ejemplo para estudios de inundaciones repentinas (Michaud y Sorooshian, 1994).

Las bases de datos satelitales de precipitación son un producto obtenido a partir de combinaciones de métodos basados en el análisis de la radiación visible e infrarroja, en la radiación de microondas y en la combinación de la visible, infrarroja y microondas.

¹Estos errores puede tener diferentes orígenes: errores aislados, debidos a errores de lectura o transcripción y errores puntuales en los sensores de estaciones automáticas; saltos en las series, atribuibles a cambios de instrumentación o de las condiciones de instalación de los aparatos; y derivas graduales en las series, debidos a cambios progresivos en la respuesta de los sensores (descalibración) o en el entorno (crecimiento urbano, cambios en los usos del suelo, etc).

 $^{^{2}}$ La meteorología en microescala es el estudio de los fenómenos atmosféricos de corta duración, de menor envergadura que los de mesoescala, cercanos a 1 km o menos. Fuente: Wikipedia (2019c).
Los satélites pueden obtener información sobre la distribución e intensidad de la precipitación de manera directa e indirecta (Kidd et al., 2010). Los métodos directos estiman la radiación de microondas que es absorbida y dispersada por los hidrometeoros³. Los métodos indirectos miden la radiación visible e infrarroja emitida por las nubes y usan correlaciones empíricas entre la cobertura espacial y temporal de las nubes, la temperatura por debajo de un umbral y la precipitación. Se han llevado a cabo varios programas para tratar de mejorar la calidad de las bases de datos satelitales. Los más importantes son the Global Precipitation Climatology Project (GPCP), los satélites polares de la NOAA-AMSU (Advanced Microwave Sounding Unit) y la NASA Earth Observing System (EOS). Los productos derivados de estos programas tienen generalmente una resolución espacial de unos 25 km y su resolución temporal oscila entre la media hora y las tres horas. Su cobertura es casi global ya que cubren la banda situada entre las latitudes 50°N-50°S. La base de datos satelital más conocida es la Tropical Rainfall Measuring Mission (TRMM) que fue una misión espacial conjunta entre la NASA y la Agencia de Exploración Aeroespacial de Japón (JAXA, por sus siglas en inglés) diseñada para monitorizar y estudiar las precipitaciones tropicales. La base de datos TRMM continúa con la misión conjunta de NASA/JAXA Global Precipitation Measurement (GPM), que se lanzó en febrero de 2014. Este tipo de satélites (preparados para registrar la precipitación globalmente) están operativos desde finales de los años 90 y cubren generalmente el periodo comprendido entre 1998 hasta la actualidad (Huffman et al., 2007).

Muchos autores han evaluado la calidad de los productos satelitales bajo diferentes puntos de vista. Tian et al. (2010) analizaron la base de datos TRMM a una resolución diaria; los resultados obtenidos mostraron errores de entre el 40% y el 60% en los océanos y de entre el 100% y el 140% en latitudes altas, así como sobre topografías complejas y líneas de costa. Mientras que Prakash et al. (2016) apreciaron serias limitaciones en los productos satelitales para capturar los eventos más extremos de precipitación. Otros autores han obtenido en los últimos años mejores resultados cuando los productos satelitales son calibrados mediante estaciones instrumentales. Sin embargo, su resolución espacial sigue siendo muy grosera y hace que en muchos casos no sean capaces de capturar correctamente los procesos convectivos de microescala. Además el hecho de que únicamente se disponga de información desde el año 1998 hace de los datos satelitales un producto que no puede ser utilizado para algunos propósitos específicos, como por ejemplo para análisis tendenciales o estudios de extremos. La principal ventaja de las bases de datos satelitales respecto a las estaciones meteorológicas, es que su cobertura es prácticamente global, siendo de gran utilidad para capturar la variabilidad espacial de la precipitación.

 $^{^3{\}rm Fenómeno}$ formado por un conjunto de partículas acuosas, líquidas o sólidas que caen a través de la atmósfera.

La precipitación puede ser también registrada mediante radares terrestres a partir de la radiación de microondas reflejada por los hidrometeoros. La principal ventaja de los radares respecto a las estaciones meteorológicas, es que ofrecen una estimación de la precipitación sobre un área de aproximadamente unos 300 km de diámetro y con una elevada resolución espacio-temporal (con intervalos de tiempo que oscilan los 5 minutos y una resolución espacial inferior a 2 km; He et al. 2018). La incorporación de los radares ha revolucionado la estimación de lluvia cuantitativa en todo el mundo, y se ha convertido en el primer sistema de observación en muchos países (Seo et al., 2013). No obstante, los radares también tienen sus propias limitaciones: (1) no hay disponibles datos de radar que cubran toda la superficie terrestre, (2) miden la retrodispersión de los hidrometeoros en las nubes y no la precipitación caída sobre la superficie, (3) no pueden penetrar barreras topográficas y edificios por lo que pueden presentar sesgos de hasta un 50% y (4) aunque generalmente cubren un área de unos 300 km de diámetro, su cobertura real varía dependiendo de las condiciones de cada tormenta debido a variaciones verticales de la reflectividad así como al granizo y la nieve. En general los datos estimados a partir de radares presentan mejores resultados que los de satélites, sin embargo al igual que estos, deben ser calibrarlos con datos observaciones. Además, al igual que sucede con los datos satelitales, este tipo de tecnología está operativa desde los años 90, por lo que en el mejor de los casos su cobertura temporal es de aproximadamente 30 años. Algunas agencias meteorológicas han generado sus propias bases de datos de precipitación a partir de la combinación de varios radares terrestres, como por ejemplo la base de datos KOSTRA de la agencia meteorológica alemana.

Otras bases de datos de precipitación que presentan también una cobertura global y una resolución temporal subdiaria son aquellas generadas a partir de modelos climáticos globales (*Global Climatic Models* o GCMs, por sus siglas en inglés). Los GCMs son modelos climáticos que simulan numéricamente las interacciones de la atmósfera, los océanos, el relieve terrestre, y el hielo. Son frecuentemente utilizados para el estudio de las dinámicas del sistema meteorológico y climático, con el objetivo de obtener proyecciones climáticas para el futuro o también para reconstruir la precipitación durante el pasado. Las primeras suelen ser forzadas mediante trayectorias (o sendas) representativas de concentración (*Representative Concentration Pathway* o RCP, por sus siglas en inglés). Mientras que las segundas, también conocidas como bases de datos de reanálisis, se diferencian principalmente de las primeras porque asimilan datos instrumentales durante la calibración de los modelos. Algunas de las bases de datos de reanálisis más conocidas son: CFSR (*the NCEP Climate Forecast System Reanalysis*; Kalnay et al. 1996), NCEP/NCAR (*National Centers for Environmental Prediction*; Saha et al. 2010) y ERA Interim (Dee et al., 2011), entre otras bases de datos.

Los GCMs, a su vez, son utilizados como condiciones de contorno de modelos climáticos regionales (*Regional Climatic Models* o RCMs, por sus siglas en inglés) con una resolución espacio-temporal significativamente mayor por lo que son capaces de capturar muchos de los procesos de menor escala. En general todas las bases de datos de reanálisis muestran un comportamiento similar, sobrestiman los eventos de lluvia con intensidades pequeñas y medias, y subestiman los eventos más intensos (Bosilovich et al., 2008). Estas bases de datos presentan cierta habilidad a la hora de reproducir la precipitación mensual, sin embargo, a una agregación temporal diaria o subdiaria su capacidad predictiva se reduce considerablemente (Kim y Joan Alexander, 2013; Pfeifroth et al., 2013a). Al igual que las bases de datos satelitales y de radar, las bases de datos de reanálisis suelen ser calibradas mediante datos instrumentales. Los reanálisis presentan la principal ventaja de cubrir periodos temporales mucho más largos que los radares y los satélites, en algunos casos desde mediados del siglo XX.

Tipo	Producto	Origen
Redes de estaciones meteorológicas	AEMeT, confederaciones hidrográficas, GHCN-Daily,	Provienen de instrumentos de
		medida terrestres
		(pluviómetros o pluviógrafos).
Gridded datasets	GPCC, Spain02,	Provienen de aplicar técnicas de
		interpolación utilizando datos
		instrumentales como referencia.
Bases de datos satelitales	TRMM, GPM,	Provienen de la medición
		de la radiación visible,
		infrarroja y microondas.
Radares terrestres	KOSTRA	Provienen de la medición de la
		radiación de microondas
		reflejada por los hidrometeoros.
Modelos climáticos	CFSR, NCEP/NCAR, ERA Interim,	Provienen de modelos climáticos que
		simulan numéricamente las
		interacciones de la atmósfera.

TABLA 2.1: Tabla resumen con los diferentes tipos de bases de datos de precipitación.

Existen otras fuentes de medida de la precipitación que están en auge en estos momentos, como por ejemplo aquellas que aprovechan la tecnología de las cámaras de vídeo o de las redes telefónicas (Allamano et al., 2015; Overeem et al., 2016). Lamentablemente estas fuentes de medida están todavía en proceso de desarrollo e implantación, y aunque a día de hoy ya parecen ofrecer resultados de calidad, tendremos que esperar unos años hasta poder utilizarlas en estudios hidrológicos e hidráulicos.

Por lo tanto, cada fuente de información presenta ciertas ventajas y limitaciones, sin embargo, hasta que no mejore significativamente la calidad de las bases de datos procedentes de fuentes alternativas como los satélites, radares y modelos climáticos, seguirán siendo necesarios los datos medidos con estaciones terrestres (pluviómetros) para calibrar dichos productos. La principal ventaja de las bases de datos satelitales, y de aquellas procedentes de radares y de modelos climáticos, es que son muy valiosas para capturar la variabilidad espacial de la precipitación en aquellas zonas donde no exista información instrumental.

La Tabla 2.1 resume las diferentes bases de datos mencionadas en la presente sección.

2.2. Predicción espacial y temporal de la precipitación

La predicción de la precipitación es la disciplina encargada de estimar la precipitación para un instante y una localización concreta donde no existe información de referencia. Es una disciplina muy demandada dentro del mundo de la investigación y del ámbito de la ingeniería hidrológica durante lo últimos años. Los modelos de predicción pueden aplicarse a diferentes sectores socio-económicos como son la administración de energía, la gestión de recursos agrícolas, la planificación de riesgos climáticos y la administración de los recursos hídricos. Además también pueden ser utilizados para mejorar la información de precipitación disponible, para rellenar los registros faltantes en el periodo histórico, para aumentar la longitud temporal de las series de precipitación y para mejor su cobertura espacio-temporal, entre otras aplicaciones (Aissia et al., 2017; Altunkaynak y Nigussie, 2015; Olsson et al., 2004; Yu et al., 2017; Zhang y Switzer, 2007).

Existen dos enfoques diferenciados para predecir la precipitación: (1) mediante modelos conceptuales, que se basan en resolver las ecuaciones termodinámicas y de la dinámica de fluidos de la atmósfera y (2) a través de modelos estadísticos, que se basan en una interpretación probabilística de los datos observados (Hong, 2008). Los modelos conceptuales son muy costosos desde el punto de vista computacional, además a día de hoy no son capaces de proporcionar predicciones precisas de lluvia a las resoluciones temporales y espaciales requeridas para algunas aplicaciones hidrológicas concretas (Krzysztofowicz, 1995; Toth et al., 2000). Los modelos estadísticos son más sencillos, requieren un esfuerzo de cómputo mucho menor y pueden proporcionar predicciones precisas a las escalas temporales y espaciales deseadas (Eum et al., 2017).

La predicción de la precipitación basada en modelos probabilísticos puede dividirse a su vez en su dimensión espacial y temporal. La predicción espacial tiene como objetivo estimar la lluvia en localizaciones donde no existe información de referencia para un instante concreto. Normalmente se utiliza la información de estaciones adyacentes y de variables geográficas correlacionadas (covariables) para generar estimaciones más certeras (Daly et al., 2008; Hofstra et al., 2008; Wadoux et al., 2017).

En la literatura existen multitud de técnicas de interpolación que sirven para hacer predicciones espaciales de la precipitación tales como: Kriging, distancia inversa (*Inverse*

Distance Weighting o IDW, por sus siglas en inglés), funciones splines y regresión múltiple con corrección residual, entre otras (Ninverola et al., 2007: Wagner et al., 2012). Uno de los mayores inconvenientes de las técnicas de interpolación es que los resultados son en definitiva un suavizado de la información original, y que a menos que se incorpore información externa en los modelos, no podrán capturan las variaciones en el espacio producidas por procesos locales. Para tratar de incorporar dicha variación espacial de la precipitación, algunas variantes de Kriging, como Cokriging o Kriging Universal (Universal Kriging o UK, por sus siglas en inglés), o la técnica de regresión múltiple con corrección residual, utilizan información externa como la elevación, proximidad a la costa, orientación de las laderas y otras variables hidrometeorológicas correlacionadas con la precipitación (Daly et al., 2008; Isotta et al., 2014). Cokriging aprovechar la covarianza entre dos o más variables que están relacionadas con la lluvia. La técnica UK es una variante del Kriging Ordinario (Ordinary Kriging o OK, por sus siglas en inglés) que incorpora un modelo tendencial. Las particularidades de la técnica UK respecto a OK es que tiene en cuenta las posibles fluctuaciones locales de la tendencia o media (drift). Mientras que la regresión múltiple con corrección residual es una combinación de la interpolación estadística (regresión múltiple) y espacial (IDW o funciones *splines*).

Por otro lado, la predicción temporal mediante modelos estadísticos tiene como objetivo predecir la lluvia en el pasado o para un periodo futuro, y normalmente se lleva a cabo mediante métodos de regresión. Los predictores son generalmente variables atmosféricas (temperatura, presión, geopotencial, etc.) que sirven para diferenciar entre las distintas situaciones de generación (Horton et al., 2017). El modelo aprende, durante el ajuste, qué condiciones inducen una respuesta de lluvia en particular; y por lo tanto es capaz de hacer una estimación de la misma, una vez que se le proporcionan las condiciones para el período de predicción. La predicción temporal no debe confundirse con los generadores climáticos (*Weather Generators* o WG, por sus siglas en inglés) o los generadores sintéticos, que tienen como objetivo simular series temporales de precipitación indistinguibles de las reales desde un punto de vista estadístico, pero sin ninguna capacidad predictiva para una fecha concreta (Glenis et al., 2015; Wilby, 1999).

La predicción temporal puede a su vez subdividirse atendiendo a su marco temporal de interés en: *nowcasting*, cuyo objetivo es estimar la lluvia para las próximas horas, predicción a corto plazo (*short-term forecasting*), que abarca de 1 a 3 días para el periodo futuro, predicción a medio plazo (*medium-term forecasting*), que abarca de 4 a 10 días, predicción a largo plazo (*long-term forecasting*) que abarca desde 10 días en adelante, y por último la predicción estacional, cuyo objetivo es estimar anomalías climáticas con algunos meses de antelación (Gupta y Ghose, 2015).

Según la ventana temporal requerida, cada tipo de predicción tiene un objetivo diferente, y además la metodología seguida en cada caso es completamente diferente. El nowcasting es una extrapolación en el tiempo de la precipitación en el instante actual. Normalmente se obtienen por medio de sensores remotos como radares y utiliza técnicas que estudian la posible evolución de las masas de aire. Este tipo de predicción no debe resolverse mediante modelos climáticos ya que generalmente ofrecen muchos peores resultados. La predicción a corto plazo utiliza los resultados de modelos climáticos, normalmente RCMs, alimentados mediante las condiciones actuales de la atmósfera para de manera directa (conceptual) o indirecta (a través de un modelo estadístico) estimar la precipitación en el periodo futuro. La predicción es probabilística y es el enfoque normalmente utilizado para realizar el pronóstico del tiempo. Por el contrario, la predicción a largo plazo tiene como objetivo reconstruir series de precipitación en el pasado o en el futuro durante varias décadas. Este tipo de predicción es muy útil para comprender la variabilidad natural del clima y estimar, por ejemplo, el riesgo asociado a diferentes tipos de eventos extremos con una probabilidad de ocurrencia muy baja, como los eventos de lluvia extrema o las sequías. La predicción a largo plazo suele realizarse a través de modelos de regresión que utilizan variables atmosféricas de reanálisis como predictores o directamente mediante la salida de modelos climáticos forzados mediante sendas representativas de concentración. Por último, la predicción estacional suele ayudarse de las diferentes teleconexiones climáticas⁴ existentes para predecir la precipitación para una estación del año en concreto. La intensidad de estas teleconexiones depende fuertemente del lugar y la estación del año. Este tipo de predicción generalmente se realiza mediante modelos estadísticos que relacionan dichas teleconexiones con la precipitación para un lugar concreto, o mediante modelos climáticos forzados con dichas teleconexiones. Tanto para la predicción a largo plazo como para la predicción estacional las condiciones actuales del clima no son significativas en los resultados finales.

La ciencia de la predicción de la precipitación no debe confundirse con la estimación de la precipitación en un contexto de cambio climático. Esta última utiliza GCMs forzados mediante diferentes escenarios de cambio climático (RCPs) para tratar de entender los efectos del cambio climático sobre los regímenes de precipitación en una zona en concreto. Este tipo de análisis no tiene ninguna capacidad predictiva para un mes o día en concreto (Li et al., 2017; Monjo et al., 2016; Pumo et al., 2017; Wasko y Sharma, 2017; Wilby y Wigley, 1997).

⁴Asociación estadística entre las variables climáticas en lugares geográficos fijos muy distantes entre sí. Las teleconexiones están causadas por grandes estructuras espaciales, tales como los modos acoplados, a la escala de una cuenca, de la variabilidad océano-atmósfera, los trenes de ondas de Rossby, las corrientes de latitudes medias y las trayectorias de las depresiones de latitudes medias, etc.

2.3. Desagregación temporal de la precipitación

Los datos de precipitaciones a una agregación temporal horaria o minutal, son esenciales para aplicaciones en muchos campos, como la hidrología urbana, el diseño de infraestructuras y los estudios de evaluación de riesgos, entre otras aplicaciones (Cáceres et al., 2018; Krajewski y Smith, 2002; Kun et al., 2018; Michaud y Sorooshian, 1994; Noor et al., 2018). Sin embargo, las redes de estaciones meteorológicas con registros temporales por debajo del día suelen tener una cobertura espacio-temporal muy reducida, debido principalmente a sus costes de instrumentación y a diferentes limitaciones técnicas existentes en el pasado (Pui et al., 2012).

Como vimos en la Sección 2.1 "Bases de datos de precipitación: fortalezas y debilidades", además de la información procedente de estaciones meteorológicas, existen otras fuentes de información que también proporcionan datos de precipitación a agregaciones temporales por debajo del día, como los datos satelitales (Huffman et al., 2010), los modelos climáticos (Pfeifroth et al., 2013b) y los registros de precipitación obtenidos a través de los radares (Austin y Seed, 2005). Lamentablemente estas fuentes de información suelen presentar grandes sesgos (Kim y Joan Alexander, 2013) y no deben ser interpretadas como registros puntuales ya que provienen de la agregación de los datos de precipitación sobre una superficie determinada (celdas de cálculo o píxeles). Además, los estadísticos de precipitación varían enormemente dependiendo de si son agregados o no en el espacio y en el tiempo. Esto ocasiona que algunos de los procesos que suceden a menor escala se vean enmascarados cuando son agregados a una escala mayor, como sucede con los eventos más extremos de precipitación y con la proporción de intervalos secos y lluviosos (del Jesus et al., 2015). En esa dirección algunos autores han desarrollado diferentes ecuaciones empíricas, conocidas como factores de reducción de área, que relacionan las precipitación a distintas agregaciones espacio-temporales (De Michele et al., 2001; Eagleson, 1972; Rodríguez–Iturbe y Mejía, 1974). Hay que tener en cuenta que estas relaciones varían en función del tipo de tormenta; convectiva, más intensas y de corta duración, o de origen ciclónico, de mayor duración y que cubre superficies mucho más amplias.

Debido a estas limitaciones se han propuesto diferentes métodos de desagregación para a partir de series de precipitación con una resolución temporal grosera generar datos de precipitación de mayor resolución (Burton et al., 2008; Cowpertwait, 1991; Glasbey et al., 1995; Hershenhorn y Woolhiser, 1987; Kim y Joan Alexander, 2013; Pui et al., 2012). El propósito de estas técnicas es simular un rango de posibles escenarios de precipitación que podrían suceder a agregaciones temporales menores bajo el supuesto de que las diferentes características estadísticas de los datos originales de precipitación se conserven (Li et al., 2018). Los principales métodos de desagregación incluyen: (1) modelos Poisson Cluster (PC), basados en la teoría de los procesos puntuales (Cowpertwait, 2006; Rodríguez– Iturbe y Eagleson, 1987); (2) los modelos de cascada aleatorios, basados en la teoría de invariancia de escala⁵ (Gupta y Waymire, 1993) y (3) modelos de remuestreo no paramétricos, basados en métodos de fragmentos (*Method of Fragments* o MoF, por sus siglas en inglés; Sharma y Srikanthan 2006).

Los modelos PC son modelos matemáticos basados en celdas de lluvia con una intensidad, duración y radio determinado que se distribuyen mediante un proceso de Poisson. Los parámetros de estos modelos son ajustados para que reproduzcan diferentes estadísticos de precipitación (media, varianza, asimetría, proporción de intervalos secos, probabilidades de transición⁶ y autocorrelación temporal y espacial) a distintas agregaciones temporales; y sirven para generar series sintéticas continuas de miles de años capaces de reproducir dichos estadísticos (Rodríguez– Iturbe y Eagleson, 1987). Los modelos de cascada aleatorios generalmente implican una ramificación sucesiva que describe como se distribuye la precipitación cuando cambia su resolución temporal. El modelo en cascada redistribuye la precipitación conservando el volumen total de agua (Gupta y Waymire, 1993). El método MoF utiliza las distribuciones estadísticas de las estaciones más cercanas con registros con una elevada resolución temporal, para dividir las series más groseras conservando su comportamiento estadístico (Sharma y Srikanthan, 2006).

El rendimiento de estos métodos para desagregar la precipitación de una resolución temporal diaria a horaria, o minutal, ha sido evaluado en numerosos trabajos (Lu y Qin, 2014; Pui et al., 2012). Los resultados de estos estudios indican que, en general, todos los modelos reproducen adecuadamente la precipitación media y la proporción de intervalos secos. Sin embargo, mientras que el método MoF y el modelo PC son capaces de conservar la varianza, los valores extremos de lluvia y las probabilidades de transición, los modelos en cascada presentan serios problemas. No obstante, resulta difícil obtener una conclusión general sobre qué método es el mejor ya que las propiedades estadísticas de la lluvia difieren significativamente de un clima a otro.

Es importante tener en cuenta que si bien los modelos de cascada y el método MoF se utilizan exclusivamente como "desagregadores", los modelos PC también se pueden usar como generadores sintéticos capaces de simular situaciones no registrados durante el periodo histórico. Esto hace que los modelos PC sean una herramienta muy interesante para estudios de extremos, ya que con ellos podemos generar eventos de precipitación sintéticos diferentes a los observados y limitar así la incertidumbre asociada a la corta

 $^{{}^{5}}$ La invariancia de escala es una propiedad de objetos o leyes en los que no hay cambios si la escala de tamaño (o la escala de energía) son multiplicadas por un factor común.

⁶Probabilidad de tener un intervalo de tiempo seco precedido por un intervalo de tiempo seco o probabilidad de tener un intervalo de tiempo lluvioso precedido por un intervalo de tiempo lluvioso.

longitud temporal de las series instrumentales (Cowpertwait et al., 2002). Otra diferencia importante entre estos métodos es que, mientras que los modelos de cascada y el método MoF requieren de las series de precipitación completas para el proceso de desagregación, los modelos PC únicamente necesitan las relaciones entre estadísticos de precipitación a distintas agregaciones temporales. Esto los convierte en un artefacto mucho más potente para estudios de cambio climático (Burton et al., 2010). La principal limitación de todos estos estudios es que, en general, son evaluados en la misma estación pluviométrica utilizada durante el proceso de calibración, asumiendo que se dispone de información horaria o minutal en la zona de estudio. Sin embargo, en la mayoría de ocasiones solo se dispone de datos diarios.

Para superar estas limitaciones algunos autores han desarrollado diferentes aproximaciones o alternativas mediante el uso de los modelos PC. Cowpertwait et al. (1996b) presentan una metodología basada en relaciones de regresión entre estadísticos diarios y subdiarios de precipitación donde estos últimos existen. Las relaciones de regresión son usadas para informar a los modelos PC en aquellos lugares donde no se dispone de información subdiaria. Sin embargo, Cowpertwait et al. (1996b) se dieron cuenta que las relaciones encontradas entre los estadísticos diarios y subdiarios eran diferentes dependiendo de la zona de estudio (zona norte o sur de Reino Unido). Marani y Zanetti (2007) por su parte siguieron un enfoque diferente; utilizaron leyes de escala ajustadas empíricamente entre los estadísticos diarios y subdiarios en diferentes regímenes climáticos del mundo para informar a los PC (Burlando y Rosso, 1996; Mandelbrot y Wallis, 1968). Su análisis mostró que la ley de escala que mejor ajustaba para cada estación, así como sus parámetros, dependían en gran medida de la localización y del tipo de clima, limitando así la generalización de los resultados. Beuchat et al. (2011) extendieron el trabajo de Marani y Zanetti (2007) a más de 200 estaciones con información horaria distribuidos a lo largo de los Estados Unidos, Reino Unido y Suiza, demostrando que no existe una ley de escala que ajuste mejor a los datos observados. De hecho, Beuchat et al. (2011) obtuvieron mejores resultados siguiendo un enfoque similar al presentado por Cowpertwait et al. (1996b) en el que se utilizaron relaciones de regresión (entre los estadísticos) para informar a los modelos PC. Beuchat et al. (2011) utilizaron como predictores estadísticos diarios de precipitación y variables atmosféricas, y como predictandos estadísticos subdiarios de precipitación. A pesar de encontrar una mejora significativa en los resultados, Beuchat et al. (2011) concluyeron que sería necesario realizar análisis adicionales para ampliar los resultados a diferentes zonas climáticas no cubiertas en sus análisis.

2.4. Eventos extremos de precipitación y cambio climático en España

Comprender los efectos del cambio climático sobre la intensidad, frecuencia y distribución espacial de los eventos más extremos de precipitación es de vital importancia para estudios de evaluación de riesgo ambiental (Beguería et al., 2011; Serrano-Notivoli et al., 2018b; Werner y Cannon, 2016). El quinto informe de evaluación (*Fifth Assessment Report* o AR5, por sus siglas en inglés) del panel intergubernamental sobre cambio climático de la organización de naciones unidas (*Intergovernmental Panel on Climate Change* o IPCC, por sus siglas en inglés; Stocker et al. 2013), así como la mayor parte de trabajos realizado hasta la fecha, señalan que por efecto del cambio climático los eventos más extremos de precipitación podrían volverse más intensos y frecuentes en muchas zonas del planeta durante el siglo XXI (Donat et al., 2014; Westra et al., 2013).

La razón principal por la que se prevé que los eventos extremos de precipitación se intensifiquen ante una atmósfera más cálida viene determinada por la ecuación de Clausius-Clapeyron (ECC). ECC es una ecuación de estado que relaciona la "capacidad de retención de humedad" de la atmósfera, la temperatura y la presión. Según la formulación de Clausius-Clapeyron (ECC), la capacidad de retención de agua de la atmósfera incrementa en aproximadamente entre un 6% y un 7% por cada aumento de la temperatura superficial del aire (TAS) de 1°C. Teniendo en cuenta la ecuación ECC, si planteáramos la hipótesis de que para el clima futuro la humedad relativa se mantiene constante (que es lo que se espera desde el entendimiento del clima y lo que sugieren los resultados de los diferentes modelos climáticos), la cantidad de vapor de agua en la atmósfera se vería incrementada un 7% por cada grado de aumento de la temperatura del aire. La relación ECC también ha sido utilizada para entender cómo podrían verse modificados los eventos extremos de precipitación en un contexto de cambio climático. Cuando este tipo de eventos tienen lugar, todo el vapor de agua contenido en el aire, o una fracción constante de él, se convierte en lluvia. Es por eso que muchos autores creen que la frecuencia de ocurrencia y la intensidad de los eventos extremos de precipitación podrían variar según la misma relación de la ecuación ECC (Drobinski et al., 2016).

Por lo tanto, parecen existir ciertas evidencias en cuanto a que los extremos de precipitación podrían aumentar en un rango similar al que propone la ecuación ECC para el contenido de vapor de agua. Sin embargo, cuando analizamos lo resultados de los distintos modelos climáticos observamos que difieren considerablemente dependiendo del modelo utilizado (Lenderink y Van Meijgaard, 2008). Además, a pesar de lo comentado anteriormente, no existe ninguna otra razón por la cual los extremos deban seguir exactamente la relación ECC. Los cambios en las dinámicas de la atmósfera y de las nubes, o en el perfil de temperatura adiabática húmeda, podrían ocasionar desviaciones en la relación ECC (Lenderink y Van Meijgaard, 2008; O'Gorman y Schneider, 2009). Además, la temperatura no es necesariamente un buen predictor de la humedad del aire, ya que un incremente de 1°C en la TAS correspondería con una aumento de entre el 6%y el 7% en la cantidad de vapor agua contenida en el aire, únicamente bajo la hipótesis de que la humedad fuese constante en el futuro (Lenderink et al., 2017). De hecho en algunas zonas con temperaturas elevadas el proceso podría resultar inverso debido a que la disponibilidad de vapor de agua en la atmósfera podría reducirse al migrar estas zonas hacia climas más áridos (Drobinski et al., 2018; Lenderink y Van Meijgaard, 2008). Drobinski et al. (2018) concluyen, por ejemplo, que a partir de una temperatura de 20°C esta relación podría ser inversa. Otros estudios han demostrado que la ecuación ECC es muy sensible a la agregación temporal a la que se estén analizando los datos de precipitación. Utsumi et al. (2011) señalan que el aumento en la humedad de entre el 6% y el 7%, por cada grado de temperatura podría ser equivalente para los eventos extremos de precipitación; sin embargo, esta relación únicamente parece conservarse a agregaciones temporales horarias o minutales, mientras que a una agregación diaria o superior podría cambiar o incluso ser inversa.

Otros autores debaten acerca de la causa por la cual en ocasiones se puede apreciar un incremento mayor del 7% en los eventos extremos de precipitación ante un aumento de 1°C en la TAS. En estos casos, la relación ECC se conoce como "Super ECC" (Haerter y Berg, 2009; Lenderink y Van Meijgaard, 2009). La respuesta a esta ley de "Super escala" podría tener un origen físico o estadístico. Físico debido a que la fuerza de los movimientos ascendentes en la atmósfera está determinada, en gran medida, por la liberación de calor latente que se produce durante el cambio de estado. Por lo tanto, disponer de una mayor cantidad de vapor de agua en el aire implicaría que se liberase una mayor cantidad de calor latente durante el proceso de condensación; lo cual intensificaría las corrientes ascendentes y por consiguiente se incrementaría la tasa de condensación y la formación de lluvia en la nube. Según el enfoque físico, podría existir una retroalimentación positiva entre el vapor de agua y la dinámica de la formación de precipitaciones en las nubes convectivas que provocaría la ley de escala "Super ECC" (Lenderink et al., 2017).

Por otra parte, la respuesta a la ley de "Super ECC" también podría tener un origen estadístico. Cada rango de temperatura se caracteriza por presentar diferentes condiciones atmosféricas que dan lugar a distintos regímenes de precipitación. Las bajas temperaturas que se registran principalmente en invierno hacen que prevalezca la presencia de tormentas sinópticas de carácter ciclónico. En estos sistemas de gran escala, las intensidades de lluvia son generalmente bajas pero prolongadas en el tiempo (normalmente de 4 horas a 6 horas). De manera inversa, aquellos lugares en los que el rango de temperatura es elevada están dominados por lluvias convectivas con intensidades altas y duraciones cortas (de 1 hora o menos). El aumento de la temperatura del aire implicaría un cambio en las frecuencias de las tormentas de gran escala y de los eventos convectivos; los eventos de gran escala menos intensos y con una mayor duración se reemplazarían por eventos convectivos más intensos y con una duración más corta. Según el enfoque estadístico, el cambio en la frecuencia de ocurrencia de cada tipo de tormenta explicaría la ley de "Super ECC". Por lo tanto, un aumento en la temperatura del aire implicaría un mayor número de tormentas convectivas según el enfoque estadístico (Haerter y Berg, 2009).

En España, los resultados de diferentes estudios promediados para todo el territorio muestran un aumento de la temperatura superficial del aire y un descenso significativo en la precipitación media. Turco et al. (2015) analizan las proyecciones del proyecto EN-SEMBLES⁷ de temperatura y precipitación diaria en España. En este trabajo observaron una reducción de la precipitación de entre el 5% y el 25% y un aumento en la temperatura de entre 1°C y 5°C para el año 2050 y para el escenario A1B⁸, dependiendo de la estación del año y del área geográfica considerada. López-Franca et al. (2015) muestran por su parte un aumento en la probabilidad de ocurrencia de periodos secos de larga duración en España, mientras que Pons et al. (2016) muestran una tendencia negativa en el número de días con nieve en España. Osca et al. (2013) utilizan una metodología basada en tipos de tiempo⁹ para predecir la precipitación en España. Los resultados muestran una reducción de la precipitación de hasta el 30% para finales de siglo y para el escenario A1B para toda España. Ribalaygua et al. (2013) realizan una regionalización climática mediante la técnica de análogos¹⁰ en Aragón para las variables temperatura y precipitación y para los escenarios A2, A1B y B1. Los resultados muestran un aumento en la temperatura de entre 1.5°C y 2.5°C para mediados de siglo y de entre 2.1°C y 3.75°C para finales, dependiendo del escenario y estación del año. Para la precipitación estiman un descenso de entre el 2% y el 4% para mediados de siglo, y de entre el 4.5% y el 5.5% para finales. Por su parte, Gómez-navarro et al. (2010) presentan los resultados de las proyecciones realizados para España por AEMeT (Agencia Estatal de Meteorología

⁷Proyecto financiado con fondos europeos con el objetivo de generar un sistema probabilístico de predicción estacional y climático que permita la cuantificación de las incertidumbres asociadas a la evolución del clima.

⁸El escenario A1 presupone un crecimiento económico mundial muy rápido, un máximo de la población mundial hacia mediados de siglo que después decrece, y una rápida introducción de tecnologías nuevas y más eficientes. Los patrones regionales específicos tienden a desaparecer como resultado de un aumento de la interacción cultural. La brecha existente entre regiones en relación con los ingresos per cápita se reduce sustancialmente. Partiendo del escenario A1, se han desarrollado tres alternativas que describen diferentes fórmulas de aprovisionamiento de energía: intensiva en combustibles fósiles (A1FI), energías de origen no fósil (A1T), y equilibrio entre las distintas fuentes (A1B).

⁹Los tipos de tiempo son patrones sinópticos representativos de las diferentes combinaciones espaciotemporales de la atmósfera que se suelen obtener mediante técnicas de minería de datos.

 $^{^{10}}$ La técnica de análogos o técnica k-NN (*k-nearest neighbors*) es un método no paramétrico utilizado para resolver problemas de clasificación y regresión.

de España). Los resultados muestran grandes diferencias en la evolución de la temperatura durante el siglo XXI dependiendo del modelo analizado. Gonçalves et al. (2014) realizan una regionalización dinámica mediante el modelo WRF (*Weather Research and Forecasting Model*) para una cuenca situada en el noroeste del Mediterráneo y para tres escenarios diferentes del CMIP3 (*Coupled Model Intercomparison Project phase 3*). Los resultados muestran un aumento de 1.4° C y una reducción de la precipitación de entre el 5% y el 13% para mediados de siglo. Por último, los resultados obtenidos dentro de la iniciativa Escenarios-PNACC 2017¹¹ muestran un acuerdo en el aumento en la temperatura superficial del aire de entre 0.8° C y 2.2° C dependiendo de la estación del año analizada para mediados de siglo. En el caso de la precipitación el acuerdo no es tan claro. En general los modelos muestran una reducción de la precipitación para mediados de siglo, siendo dicha reducción mucho más acusada en el periodo comprendido entre los meses de marzo y agosto (20%).

Muy pocos son, sin embargo, los autores que han estudiado cómo podría verse modificada la frecuencia e intensidad de los eventos más extremos de precipitación en España. Los únicos trabajo realizados en esa línea concluyen que es difícil apreciar cambios significativos en dicho eventos a una agregación temporal diaria (Garijo y Mediero, 2018; Merino et al., 2016; Serrano-Notivoli et al., 2018b; Vicente-Serrano et al., 2017). Algunos autores, sin embargo, han investigado si el calentamiento de la temperatura superficial del aire podría estar afectando a la frecuencia e intensidad de lo eventos extremos en España a agregaciones temporales por debajo del día (Merino et al., 2018; Scoccimarro et al., 2015). Los resultados de estos trabajos ponen de manifiesto que en un clima como el de España, donde los eventos más intensos descargan grandes cantidades de precipitación en pocas horas, especialmente en el Mediterráneo, Islas Baleares e Islas Canarias (Diez-Sierra y del Jesus, 2017; Martin-Vide, 2004; Meseguer-Ruiz et al., 2017), es indispensable analizar la precipitación a agregaciones temporales por debajo del día para comprender los efectos del cambio climático sobre los eventos más extremos de precipitación en España.

Podemos encontrar dos enfoques diferenciados que sirven para analizar los efectos del cambio climático en los regímenes de precipitación. El primero se basa en examinar el comportamiento de la precipitación en el pasado mediante registros instrumentales. Merino et al. (2018) analizan un índice extremal de precipitación que tiene en cuenta la continuidad temporal del evento en varias estaciones con información subdiaria distribuidas a lo largo de la cuenca del Ebro (España). Los resultados muestran tendencias significativas positivas en prácticamente todas las estaciones a una resolución temporal horaria, mientras que a agregaciones superiores (6, 12, 72 y 168 horas) las conclusiones

¹¹Nueva colección de escenarios de cambio climatico regionalizados del Plan Nacional de Adaptacion al Cambio Climatico (PNACC).

no son tan claras, ya que los resultados dejan de presentar significancia o cambia de sentido en muchas de las estaciones. Algunos de los inconvenientes de este primer enfoque son: (1) que normalmente no se disponen de series horarias suficientemente largas (30 años o más) para realizar análisis tendenciales con cierta rigurosidad, (2) que no se suele disponer tampoco de información subdiaria en la zona de estudio y (3) que en el caso en el que dispusiéramos de dicha información y encontrásemos tendencias significativas de cambio en la frecuencia o intensidad de los eventos extremos, no sería aconsejable proyectarlas en el tiempo más allá de un horizonte de corto plazo (2030 aproximadamente) debido a que no tienen por qué presentar un comportamiento lineal.

El segundo de los enfoques se basa en analizar el cambio en la precipitación en el siglo XXI, y finales del siglo XX, a través de los resultados de GCMs y RCMs forzados mediante escenarios de cambio climático. Una de las ventajas de este enfoque es que, en principio, dispondríamos de información para todo el siglo XXI en cualquier parte del mundo (series con una cobertura temporal de unos 150 años para el periodo 1950-2100). El principal inconveniente de este enfoque es que la calidad de los resultados está sujeta a la propia incertidumbre de los GCMs/RCMs y RCPs. Además, otro de los inconvenientes de este segundo enfoque es que los resultados de los GCMs o RCMs no pueden ser utilizados directamente ya que presentan sesgos muy importantes que deben ser corregidos mediante técnicas de corrección de sesgo, usando para ello series instrumentales localizadas cerca de la zona de interés (Cannon et al., 2015). En ese contexto, Garijo y Mediero (2018) analizan cómo podrían cambiar los periodos de retorno de precipitación para 12 modelos regionales de EURO-CORDEX¹² (Jacob et al., 2014). Los resultados muestran muy pocas celdas con significancia positiva para un umbral del 5% y una agregación temporal diaria. Scoccimarro et al. (2015), por su parte, analizan los resultados de un GCM del CMIP5 (Taylor et al., 2012) en España a dos agregaciones temporales diferentes (diaria y tres-horaria). Los resultados muestran cambios significativos entre las diferentes escalas temporales, con una mayor intensificación a una escala 3-horaria.

Por lo tanto, aunque parece probable que en un contexto de cambio climático la frecuencia de ocurrencia de los eventos más extremos de precipitación se podría ver intensificada en España para el clima futuro, la relación entre la temperatura superficial del aire y este tipo de eventos puede depender de muchos factores, como por ejemplo la agregación temporal de los datos de precipitación o la región climática analizada. Estos resultados

 $^{^{12}}$ EURO-CORDEX es la rama europea de la iniciativa internacional CORDEX, que es un programa patrocinado por el Programa mundial de investigación sobre el clima (*World Climate Research Programme* o WRCP, por sus siglas en inglés) qie tiene como objetivo organizar un marco coordinado internacionalmente para producir mejores proyecciones regionales de cambio climático para todas las regiones terrestres del mundo.

justifican la necesidad de explorar más en detalle como podría estar afectando el aumento de la temperatura superficial del aire en los regímenes de precipitación para los diferentes tipos de climas de España.

Capítulo 3

Predicción estadística de la precipitación

3.1. Introducción

Hoy en día la fuente de información más fiable para medir la intensidad de la lluvia sigue siendo aquella procedente de estaciones meteorológicas situadas en el terreno (pluviómetros). Sin embargo, dichas estaciones meteorológicas únicamente son capaces de capturar la intensidad de la lluvia a nivel puntual; es por eso que tienden a ser dispuestas en redes de estaciones con el propósito de cubrir grandes áreas. Las redes de estaciones pluviométricas proporcionan información muy útil para la caracterización espaciotemporal de la precipitación, y por lo tanto, sus registros son muy interesantes para diferentes finalidades (análisis de riesgo, diseños estructurales, etc.). Además, disponer de redes con una elevada densidad de estaciones de medida nos da la oportunidad de validar nuestros métodos en zonas con diferentes regímenes climáticos y características geográficas, y comprender así, si los métodos son generalizables o no.

En este capítulo de la tesis se han llevado a cabo dos análisis diferenciados. En primer lugar, el la Sección "Predicción probabilística a corto plazo basada en tipos de tiempo" presentamos un sistema operacional de predicción de la precipitación a corto plazo (de 1 a 3 días vista) basado en tipos de tiempo que ha sido implementado en la isla de Tenerife. Dicho sistema operacional servirá para dar una predicción cuantitativa de la lluvia a tres días vista y para estimar también el riesgo de inundación. Los métodos desarrollados se aprovechan de la red tan amplia de estaciones con información diaria, distribuidas a lo largo de la isla, para su calibración y validación. Sin embargo, hay tener en cuenta que la medición, extracción y el tratamiento de tal volumen de información puede presentar serias complicaciones, como por ejemplo, discontinuidades en las serie temporales resultado del mal funcionamiento de los equipos u otras razones. Además dan lugar a grandes bases de datos desde las que es muy difícil extraer, interpretar y tratar la información sin ayuda de herramientas específicamente diseñadas para tal propósito. Es por eso que los métodos desarrollados, además de predecir la precipitación en una ventana temporal de corto plazo, deberán ser capaces de tratar con dichas problemáticas (completar valores faltantes en las series de precipitación y generar pluviómetros sintéticos en localizaciones donde no existe información instrumental). Los métodos presentados en la Sección 3.4 han sido implementados en una herramienta desarrollada por el Instituto Hidráulico Ambiental de Cantabria (IH Cantabria) conocida como MENSEI-L (Diez-Sierra y del Jesus, 2017). MENSEI-L está operativa en el CIATF (Consejo Insular de Aguas de Tenerife) desde el año 2016, y sirve para el análisis estadístico de las redes pluviométricas así como para proporcionar pronósticos de lluvia para tres días vista.

En segundo lugar, el la Sección 3.5 "Predicción a largo plazo mediante modelos estadísticos y máquinas de aprendizaje automatizado" hemos ampliado el trabajo realizado en la Sección 3.4 para realizar predicciones a largo plazo de precipitación con el objetivo de reconstruir varias décadas de lluvias diarias en el pasado. Estos resultados son muy útiles para la gestión de recursos hídricos, para el análisis de tendencias climáticas y para el estudio del cambio en la frecuencia de ocurrencia de eventos extremos (principalmente inundaciones y sequías). En la Sección 3.5 se realiza un análisis de sensibilidad de diferentes métodos estadísticos y de aprendizaje automatizado para realizar predicciones a largo plazo de precipitación.

Los dos análisis mostrados en el presente capítulo siguen una metodología similar, ya que se basan en modelos estadísticos que utilizan como predictores la información de campos espaciales atmosféricos de bases de datos de reanálisis, y como predictandos series instrumentales diarias de precipitación. Los métodos pueden ser implementados en cualquier parte del mundo en la que se disponga de registros instrumentales de precipitación.

3.2. Área de estudio

Tenerife es una de las siete islas que forman el archipiélago Canario. Se encuentra en el Océano Atlántico, a 300 Km al oeste de la costa africana, entre los paralelos 28°N y 29°N y entre los meridianos 16°W y 17°W (ver Figura 3.1). Cubre una superficie de 2034.38 km², con una población de 891.111 habitantes, y es la isla con mayor superficie y la más poblada de las Islas Canarias y de toda la región de Macaronesia. La isla de Tenerife muestra un gradiente topográfico muy marcado desde la costa hasta la parte central de la isla. La región central de la isla es una cordillera, donde El Teide, con 3.718 m de altura,

separa la isla en dos zonas climáticas bien diferenciadas: una región norte, relativamente húmeda debido al efecto de los vientos alisios, y una región sur, más seca debido al bloqueo inducido por la orografía. Estas condiciones orográficas tan particulares hacen que exista un amplio abanico de climas dentro de un área relativamente pequeña. Un clima subtropical húmedo en las capas bajas y otro mucho más extremo y seco, casi continental alpino, en las capas altas.



Figura 3.1: Localización de la isla de Tenerife. Fuente: Diez-Sierra y del Jesus (2017).

La precipitación en Tenerife es muy escasa, con una media anual de 233 mm para toda la isla. Su distribución temporal y espacial es, sin embargo, muy heterogénea ya que un porcentaje muy alto del agua precipita en cortos períodos de tiempo y en áreas muy localizadas. Presenta una estacionalidad muy marcada con meses de verano en los que la precipitación es prácticamente inexistente y con el pico máximo en el mes de diciembre. Los valores de precipitación media anual muestran una dispersión muy grande, con años con más de 1000 mm de lluvia acumulados durante todo el año y otros en los que únicamente precipitan 100 mm. Estas singularidades climáticas, y orográficas, presentes en la isla, combinadas con los procesos de urbanización realizados en los últimos años, han hecho de las inundaciones repentinas un problema muy grave en Tenerife. De hecho, en el siglo XX se registraron aproximadamente unas 100 inundaciones con graves consecuencias económicas y humanas. Algunas de las más graves fueron las riadas de 2002^1 y 2010^2 .

3.3. Datos de partida

Con el objetivo de desarrollar los diferentes métodos propuestos en el presente capítulo se han utilizado dos tipos de fuentes de información: (1) series de precipitación diarias procedentes de estaciones automáticas y (2) bases de datos de reanálisis atmosféricas.

Los datos de lluvia fueron proporcionados por el Consejo Insular de Agua de Tenerife (CIATF), que es la agencia de planificación y gestión del agua para las islas de Tenerife. El CIATF mantiene una base de datos de observaciones de lluvia sometida a diferentes controles de calidad (Melián et al., 2011) que incluye la red de observación de la Agencia Estatal de Meteorología (AEMeT) y la del AgroCabildo, una agencia local para el desarrollo agrícola. La base de datos del CIATF contiene información para 125 medidores, combinando valores diarios y subdiarios con una cobertura temporal promedio de 15 años. La Figura 3.2 muestra la localización de las estaciones que han sido utilizadas en el presente análisis a lo largo de la isla de Tenerife así como las distintas cuencas vertientes.

Como vemos en la Figura 3.3, en los años 40, aproximadamente, se realizó una fuerte inversión instalando alrededor de 50 estaciones. Ese número de estaciones se mantuvo prácticamente constante hasta los años 80 y 90 donde se alcanzó el máximo número de estaciones operativas (unas 200). Actualmente siguen operativas unas 100 estaciones. CIATF también ha facilitado el modelo de elevación digital del terreno con una resolución espacial de 5 m para toda la isla.

Las variables atmosféricas servirán para informar a los diferentes métodos sobre el estado de la atmósfera, constituyendo así el principal predictor de la precipitación. En la isla de

¹La llamada Riada de Tenerife del año 2002, también llamada 31-M, se refiere a un fenómeno de gota fría que se produjo el 31 de marzo de 2002. Las precipitaciones torrenciales afectaron a un área muy reducida del entorno de la capital tinerfeña. Descargó 232,6 l/m² en 24 horas y 129,9 l/m² en una hora, significando el primer dato la mayor cantidad de agua recogida en la ciudad en un sólo día desde que se iniciaron los registros en 1869. El Instituto Nacional de Meteorología no avisó de la catástrofe y el día previo advirtió sólo de chubascos moderados. Las lluvias ocasionaron 8 muertos, 12 desaparecidos y decenas de heridos. Además de las pérdidas humanas la riada causó cuantiosos daños materiales, 70.000 personas se quedaron sin luz y se destruyeron total o parcialmente más de 400 viviendas. Las pérdidas alcanzaron 90 millones de euros. Fuente: Wikipedia (2019d).

 $^{^{2}}$ La llamada Riada de Tenerife del año 2010 tuvo lugar el 1 de febrero de ese año afectando principalmente al área metropolitana de Santa Cruz de Tenerife. A diferencia de la gran riada anterior sufrida en 2002, la de 2010 no se limitó a la ciudad de Santa Cruz de Tenerife y sus áreas circundantes inmediatas, sino que la potente borrasca atlántica afectó a prácticamente todas las Islas Canarias, aunque con mucha más incidencia en Santa Cruz de Tenerife. A diferencia de lo ocurrido en 2002, la riada de 2010 no produjo víctimas mortales, sin embargo, más de 900.000 habitantes se quedaron sin luz. Fuente: Wikipedia (2019e).



Figura 3.2: Localización de las estaciones pluviométricas disponibles en la isla de Tenerife que fueron utilizas en los diferentes análisis. Los puntos rojos, negros y azules corresponden a series con registros mensuales, diarios y subdiarios, respectivamente.

Tenerife los diferentes estados o patrones sinópticos³ atmosféricos quedan correctamente capturados por los campos combinados de presión del nivel del mar (*Sea Level Pressure* o SLP, por sus siglas en inglés) y de altura geopotencial (*Geopotential Height* o GH, por sus siglas en inglés), al nivel de 500 hPa (GH500) y al nivel de 850 hPa (GH850), como se describe en los estudios realizados previamente por Herrera et al. (2001) y Tullot (1959). En base a estos estudios se seleccionaron los campos espaciales para las variables SLP, GH500 y GH850, cubriendo el área entre las longitudes 45°W y 5°E, y entre las latitudes 20°N y 50°N (ver Figura 3.4).

La información espacio-temporal para las 3 variables atmosféricas ha sido obtenida de dos fuentes diferentes. Por un lado, la información para el periodo histórico (1979-2015) se ha obtenido de la base de datos de reanálisis global NCEP *Climate Forecast System Reanalysis* (CFSR; Saha et al. 2010), junto con su continuación la versión 2 (CFSRV2), desarrollado por la NOAA (*National Oceanic and Atmospheric Administration* o NOAA, por sus siglas en inglés). En este documento, el término CFSR se utilizará para referirse

 $^{^{3}}$ La escala sinóptica, también llamada escala grande o escala ciclónica, en meteorología es una escala de longitud horizontal del orden de los 1.000 km o más. Esto se corresponde con la escala horizontal típica de las depresiones en las latitudes medias. Los mapas meteorológicos habituales en que aparecen representadas las áreas de altas y bajas presiones son mapas de escala sinóptica. Fuente: Wikipedia 2019a.



Figura 3.3: Número de estaciones con registros de precipitación en el periodo 1900-2015.

a la combinación de las dos bases de datos, CFSR y CFSV2. CFSR es una base de datos de reanálisis de tercera generación que cubre todo el globo y que combina un modelo de atmósfera, tierra y océano junto con un modelo de la capa de hielo. CFSR proporciona datos 6-horarios. La resolución espacial del modelo atmosférico es de 38 km horizontalmente, con 64 niveles verticales. La resolución espacial del modelo oceánico es aproximadamente 0.25° cerca del Ecuador, y de 0.5° más allá de los Trópicos y dispone de 40 niveles verticales. El modelo de tierra cuenta con 4 niveles de suelo y el modelo de hielo con 3. CFSR y CFSRv2 juntas cubren el periodo 1979-2015. Por otro lado, se ha utilizado también la información del modelo GFS (*Global Forecast System*) de predicción para las tres variables atmosféricas (SLP, GH500 y GH850). Dicho modelo está también desarrollado por la NOAA y ofrece pronósticos de 16 días para el futuro para más de 20 variable con un modelo muy similar al utilizado para generar la base de datos de reanálisis CFSR.

3.4. Predicción probabilística a corto plazo basada en tipos de tiempo

Los modelos para el análisis de series temporales, como por ejemplo aquellos que se basan en modelos generalizados lineales (*Generalized Linear Model* o GLM, pos sus siglas en inglés), modelos estocásticos auto-regresivos de media móvil, modelos de regresión logística y aquellos basados en algoritmos de aprendizaje automatizado (bosques aleatorios, redes neuronales artificiales, etc.), se han convertido en técnicas muy populares a día de hoy para predecir la precipitación. Son técnicas que al igual que las basadas en modelos climáticos globales o regionales, presentan una limitada habilidad a la hora de



Figura 3.4: El cuadro negro corresponde al área seleccionada para los predictores atmosféricos. El cuadro rojo indica el zona donde se localizan las Islas Canarias. Fuente: Figura incluida en un artículo en revisión enviado a la revista Journal of Hydrology Diez-Sierra y del Jesus 2019.

predecir la precipitación a escalas temporales por debajo del mes; lo que se debe principalmente a la baja persistencia en el tiempo que caracteriza a la lluvia. Sin embargo, el hecho de que sean cada vez más fáciles de implementar, debido a la aparición de librerías específicas desarrolladas para ello y al poco tiempo de computación requerido, hacen que sean técnicas muy atractivas en el contexto de la predicción de la precipitación y del cálculo probabilístico del riesgo de inundaciones en tiempo real (Monira et al., 2010; Toth et al., 2000).

3.4.1. Métodos

La metodología seguida en la presente sección para la predicción probabilística a corto plazo basada en tipos de tiempo se divide en torno a tres procedimientos principales. El primero es la interpolación espacial mediante métodos geoestadísticos. Las técnicas geoestadísticas de interpolación son utilizadas por dos motivos. El primero, para rellenar los registros faltantes en las series de precipitación y disponer así de series continuas que serán utilizadas más adelante para ajustar los diferentes métodos. Y el segundo, para dar resultados en formato espacial; lo cual es muy interesante para cubrir zonas en las que no existe información instrumental, así como para generar mapas espaciales que pueden ser utilizados como datos entrada para modelos hidrológicos distribuidos.

El segundo es la generación de los tipos de tiempo (*Weather Types* o WT, por sus siglas en inglés) con el objetivo de clasificar los patrones espacio-temporales de las diferentes

variables de reanálisis (SLP, GH500, GH850) en un número limitado de mapas sinópticos representativos de todas las condiciones atmosféricas acontecidas en el pasado. Los WT capturan gran parte de la variabilidad climática existente a través de un grupo de patrones en los que cada uno de ellos representa aquellas condiciones climáticas que fueron similares entre sí en el pasado (Huth et al., 2008). Para la generación de los WT se ha aplicado un procedimiento que se divide en dos partes. Por un lado se ha aplicado la técnica de análisis de componentes principales (*Principal Component Analysis* o PCA, por sus siglas en inglés) para reducir la dimensionalidad de los datos; y por el otro se ha aplicado la técnica de clusterización *k-means* para seleccionar aquellos patrones más representativos de todo el conjunto de datos originales (Camus et al., 2011b).

El tercer y último procedimiento corresponde a la implementación del sistema operacional de predicción a corto plazo. Para ello, la herramienta MESEI-L descarga de manera automática la predicción a tres días vista para las distintas variables atmosféricas de la base de datos GFS, para, a continuación, seleccionar aquellos WT más parecidos en el espacio de las PCA. La predicción probabilística de precipitación se calcula a partir de de la lluvia que tuvo lugar durante las fechas clasificadas por el WT más parecido (con menor distancia euclídea) a la salida del modelo climático GFS.

La Figura 3.5 muestra el esquema metodológico para el sistema operacional de predicción a corto plazo basado en tipos de tiempo implementado en la isla de Tenerife. La información de las variables atmosféricas GH500, GH850 y SLP, para el periodo 1979-2015 y para el área mostrada en la figura 3.4, es seleccionada y preprocesada mediante la técnica PCA. A continuación la técnica *k-means* es utilizada para construir los diferentes WT. Las series temporales de precipitación, previamente homogeneizadas (rellenadas) mediante técnicas geoestadísticas, son divididas en una serie de subconjuntos, definido cada uno de ellos por las fechas representativas para cada WT. Por último la aplicación descarga la información a tres días vista para las variables GH500, GH850 y SLP de la base de datos GFS y busca los WT más parecidos. La predicción de la precipitación se calcula en base a la precipitación que tuvo lugar durante todos los días representados por ese mismo WT. Como resultado se generan campos espaciales de precipitación a tres días vista en formato de cuadrícula, para lo que de nuevo son utilizadas las técnicas geoestadísticas de interpolación que se describen en el siguiente apartado.

Es importante apuntar que los métodos aplicados en este capítulo se han desarrollado y validado a una resolución temporal diaria; y que debido a que el comportamiento estadístico de la precipitación varía enormemente según su agregación temporal, es probable que los resultados no puedan ser extrapolables a agregaciones más pequeñas.

En las siguientes secciones se describe en detalle los tres principales procedimientos así como los resultados obtenidos en el presente análisis.



Figura 3.5: Esquema metodológico del sistema operacional de predicción a corto plazo basado en tipos de tiempo implementado en la isla de Tenerife.

3.4.2. Interpolación espacial

Varios estudios realizados en las últimas décadas han demostrado que la técnica geoestadística Kriging ofrece mejores resultados que otras técnicas de interpolación cuando hay una alta densidad de estaciones disponibles, como sucede en la isla de Tenerife (Phillips et al., 1992; Tabios y Salas, 1985a).

La geoestadística es una disciplina que se basa en la teoría de la regionalización de variables (Goovaerts, 1997, 2000; Journel y Huijbregts, 1978). Esta técnica está ganado importancia frente a otras ya que permiten tener en cuenta la correlación espacial de la precipitación entre estaciones vecinas, lo cual es muy interesante para hacer predicciones en zonas sin información. Para interpolar la lluvia se ha seguido un proceso de dos pasos tal y como sugieren Herrera et al. (2012a). Primero, se predice si en una localización concreta llueve o no. Y después, en el caso en el que lloviera, se predice la intensidad de lluvia para eso punto (mm/día).

Se han analizado diferentes variantes de Kriging y se ha seleccionado aquella que ofrece mejores resultados mediante la técnica de validación cruzada *leave-one-out*. La técnica de validación cruzada *leave-one-out* se basa en utilizar todas las estaciones menos una en el proceso de interpolación para predecir la precipitación precisamente en esa localización que se deja fuera durante el proceso ajuste. Este proceso se repite para todas



Figura 3.6: Gráfico de dispersión entre la precipitación media anual y la elevación para las estaciones con más de 30 años de información durante el periodo 1950-2015.



Figura 3.7: Precipitación media anual para el periodo 1950-2015 calculada a partir de todas las estaciones pluviométricas con más de 30 años de información disponibles durante dicho periodo.

las estaciones comparando las series predichas con las originales. Las variantes de Kriging analizadas fueron: Kriging Ordinario; Kriging Universal, utilizando la elevación del terreno como tendencia (drift); y Kriging Universal, utilizando la precipitación media anual y la elevación como tendencias. La Figura 3.6 muestra la relación existente entre la precipitación media anual y la elevación en la isla de Tenerife. Como se puede apreciar, dicha relación es casi lineal hasta los 1500 metros aproximadamente; a partir de esa altura, la relación decae principalmente por el efecto de la inversión térmica⁴. La Figura 3.7 muestra la precipitación media anual para el periodo 1950-2015 calculada a partir de todas las estaciones con más de 30 años de información durante dicho periodo. En la Figura 3.7 se puede apreciar perfectamente las diferentes zonas climáticas existentes en la isla. El proceso de validación cruzada se realizó en el periodo 1950-2015. Las métricas sesgo estandarizado (Bias/Std), error medio cuadrático (*Root Mean Square Error* o RM-SE, por sus siglas en inglés) y coeficiente de correlación de Pearson (R) fueron utilizadas para comparar los diferentes métodos. Kriging Universal, utilizando como tendencia la elevación del terreno y la precipitación media promedio (ver Figuras 3.6 y 3.7), fue la técnica que mejores resultados obtuvo, con un valor de R para todas las estaciones de 0.8, un sesgo estandarizado de 0.02 mm/día y un RMSE de 6.7 mm/día.

La Figura 3.8 muestra los resultados para las diferentes métricas obtenidos mediante la técnica Kriging Universal (que incluye la elevación y la precipitación media como tendencia) seleccionada como la mejor mediante validación cruzada. Como podemos observar, en general, existe un muy buen acuerdo entre el las series interpoladas y las originales. Los peores resultados fueron obtenidos en la zona sureste de la isla, lo que se debe principalmente a la menor densidad de estaciones y la orografía tan compleja que presenta esa zona de la Isla.

La técnica Kriging requiere una forma paramétrica específica del variograma para el proceso de interpolación. Existen diferentes aproximaciones a la hora de abordar este problema como puede ser ajustar un único variograma para la precipitación media anual (variograma global), o ajustar varios variogramas si se diese el caso en el que la correlación espacial entre las estaciones fuera diferente entre las distintas estaciones del año o entre subcuencas (Hofstra et al., 2008). En el caso concreto de Tenerife, al disponer de una densidad muy elevada de estaciones (125 estaciones y un promedio de 100 estaciones con dato al día en el periodo 1950-2015), los mejores resultados fueron obtenidos ajustando el variograma para cada día de manera independiente. Por lo tanto, para cada día del año hemos seleccionado el variograma que mejor ajusta de entre una serie de funciones paramétricas (exponencial, esférica, lineal, circular, Gaussiana, etc.) mediante los registros disponibles para cada día. Las funciones esférica y exponencial fueron seleccionadas como óptimas el mayor número de los días.

 $^{^{4}}$ La inversión térmica se produce cuando en la atmósfera, la temperatura del aire en vez de descender mientras se sube en altura, como es normal, va aumentando cada vez más, limitando así las corrientes convectivas ascendentes que se producen en la atmósfera. El aire no puede elevarse en una zona de inversión térmica, puesto que es más frío y, por tanto, más denso en la zona inferior. Fuente: Wikipedia 2019b



Figura 3.8: Resultados de validación cruzada para el periodo 1950-2015. Los paneles muestran, de arriba a abajo, las métricas: sesgo estandarizado (Bias/Std), error medio cuadrático (RMSE) y correlación de Pearson (R) para (prcp>0.1 mm/día).

3.4.3. Generación de tipos de tiempo y de tormentas tipo

Los tipos de tiempo atmosféricos (WT) son patrones sinópticos representativos que constituyen una base óptima para expresar el estado de la atmósfera y su variabilidad natural a través de un conjunto reducido de situaciones atmosféricas. A los efectos de este estudio, el estado de la atmósfera para un día concreto estará representado por los campos combinados de las variables SLP, GH500 y GH850, de la base de datos CFSR, para el área que cubre las coordenadas 45° W y 5° E, y 20° N y 50° N agregados a una resolución temporal diaria. Como comentamos, las variables, así como su cobertura espacial, han sido elegidas basándonos en estudios previos realizados en Tenerife (Herrera et al., 2001; Tullot, 1959). Los WT se calculan mediante un proceso de dos pasos. En primer lugar se aplica un análisis de componentes principales (PCA; Abdi y Williams 2010) para reducir la dimensionalidad de los datos. Posteriormente se aplica el algoritmo de agrupación o selección *k-means* (Hastie y Friedman, 2009) al conjunto de datos de dimensiones reducidas para determinar los tipos de tiempo más representativos.

Para realizar el análisis de componentes principales, primero se agregan los datos atmosféricos de la base de datos CFSR a una resolución temporal diaria (13.514 días durante todo el período de análisis) sobre una malla de 0,5° x 0,5° (formando una matriz de 60x100 elementos). Para cada día dispondremos de 3 matrices de 60 x 100 elementos en total (una para cada variable SLP, GH500 y GH850). Cada elemento de la matriz representa el valor de una de las tres variables para una ubicación específica. Las matrices para una misma fecha se combinan y reorganizan para formar un vector de 180.000 componentes (60 x 100 x 3), que se apilan para cada día formando una matriz de 180.000 x 13.514 elementos. Dicha matriz contienen la información atmosférica para las 3 variables durante todo el período de referencia (1979-2015). La información atmosférica para cada día podría interpretarse como un conjunto de datos en un espacio de 180.000 dimensiones; no obstante, las correlaciones existentes entre los valores de una variable en diferentes ubicaciones, o entre diferentes variables en la misma ubicación, hace que muchas de estas dimensiones sean redundantes y poco informativas. Estas correlaciones pueden perturbar, e incluso arruinar en algunos casos, el procedimiento de ajuste de los modelos de regresión (Gutiérrez et al., 2004). Para reducir estas correlaciones y mantener a su vez su poder discriminante, los patrones atmosféricos se estandarizan y luego se transforman a través del análisis de componentes principales (Abdi y Williams, 2010). Mediante el análisis de componentes principales (PCA) se construye una base alternativa para representar los datos originales. Cada una de las componentes se ordena en función de la cantidad de varianza original que describen; la primera componente se alinea con la dirección que presenta una mayor variabilidad en los datos originales, y cada componente sucesiva se alinea en la siguiente dirección que muestre más varianza (siendo todas las componentes ortogonales entre sí). La aplicación del método PCA ofrece una representación más funcional de los datos de partida, ya que muchas de las dimensiones originales se verán reducidas en la nueva proyección sin perder prácticamente nada de información.

La técnica de PCA es aplicada a la matriz original de $180.000 \ge 13.514$ elementos. El resultado es una matriz con 14 componentes principales que capturan el 95% de la varianza del conjunto de datos original. De esta manera, la matriz original pasa de disponer de $180.000 \ge 13.514$ elementos a $14 \ge 13.514$ que representan la serie de 13.514 días para las 14 componentes resultado del análisis PCA.



Figura 3.9: 81 tipos de tiempo (WT) seleccionados para la variable presión a nivel del mar (SLP). Fuente: Figura adaptada a partir de los resultados obtenidos en Diez-Sierra y del Jesus (2017).

Por otro lado, la clasificación de las condiciones atmosféricas en una serie de tipos de tiempo se puede realizar mediante diferentes técnicas de minería de datos o de clasificación. Conceptualmente todas ellas se basan en encontrar una serie de grupos representativos de la muestra original con la máxima disimilitud entre ellos. Los métodos se diferencian entre ellos principalmente en la forma en la que se determinan las distancias y las relaciones de vecindad. Algunos de los métodos más utilizados como por ejemplo el algoritmo k-means (Hastie y Friedman, 2009) y los mapas de redes auto-organizativas (Kohonen, 1990), fueron utilizados en trabajos previos para clasificar campos espaciales de diferentes variables geofísicas (Guanche et al., 2013; Gutiérrez et al., 2004; Izaguirre et al., 2012).



Figura 3.10: Distribución espacial de la probabilidad de lluvia para cada tipo de tormenta. Fuente: Figura adaptada a partir del artículo Diez-Sierra y del Jesus (2017).



Figura 3.11: Distribución espacial de la intensidad de lluvia para cada tipo de tormenta. Fuente: Figura adaptada a partir del artículo Diez-Sierra y del Jesus (2017).

Nosotros aquí hemos utilizado la técnica de clasificación k-means. K-means divide el conjunto de datos de partida en un determinado número de subconjuntos, definido cada uno de ellos por un prototipo y formado por los datos para los cuales ese prototipo es el más cercano (Hastie y Friedman, 2009). Una vez establecido el número de grupos e inicializados los prototipos (o centroides), en cada iteración se identifican los datos de entrada más próximos a cada centroide y se redefine el centroide como la media de los datos más similares hasta minimizar la varianza total intra-grupos, es decir, hasta que la suma de distancias entre los prototipos y los datos de entrada correspondientes a cada prototipo sea mínima. La técnica k-means ha sido aplicada al resultado del análisis de componentes principales. Más detalles sobre la metodología seguida para la selección de los tipos de tiempo pueden encontrase en Camus et al. (2011b).

La Figura 3.9 muestra los WT seleccionados para la variable SLP. El número total de WT (81 en este caso), ha sido seleccionado mediante el criterio *Dunn Index* (Baarsch y Celebi, 2012). El criterio *Dunn Index* resulta del cociente entre la mínima distancia entre dos instantes de tiempo diferentes (campos espaciales de SLP, GH500 y GH850) pertenecientes a subgrupos distintos y la máxima distancia entre dos instantes de tiempo del mismo grupo. Esta técnica es una manera objetiva de cuantificar la dispersión de nuestros datos en función del número de subgrupos seleccionados. En función de dicho índice hemos establecido como 81 el número óptimo de tipos de tiempo.

Los tipos de tormenta (ver Figuras 3.10 y 3.11) fueron calculados mediante la precipitación que tuvo lugar en las fechas (días) representados por cada WT. Dos tipos de tormenta han sido calculados para cada WT. El primero corresponde a la probabilidad de que llueva en el caso en el que se diera dicho WT (Figura 3.10). Y el segundo corresponde a la intensidad de lluvia media de todos los días representados por cada WT (Figura 3.11). Según este enfoque, se podría asumir que cada WT induce un tipo de lluvia que puede ser adecuadamente capturada y representada por sus valores promedio. Cuando los tipos de tormentas son definidos de esta manera implica que no tenemos que realizar clasificaciones adicionales con la variable precipitación, esta se deriva directamente de la clasificación inicial hecha para las condiciones atmosféricas. La Figura 3.10 muestra la distribución espacial de la probabilidad de lluvia para cada tipo de tormenta. Cada punto corresponde a la probabilidad de que llueva (precip > 0.1 mm/día) para cada una de las estaciones y para cada tipo de tiempo. Como podemos observar cada WT queda representando por un tipo de tormenta con un patrón espacial completamente diferente. Algunos tipos de tiempo como el 6, 7, 8, 9, 41 y 66 corresponden a tipos de tormenta con una elevada probabilidad de lluvia. Estos tipos de tormentas corresponden a su vez a situaciones climáticas muy específicas como depresiones frías o sistemas de bajas presiones en las zonas templadas. Es interesante observar como los WT con una alta probabilidad de lluvia no son, en muchos de los casos, los que presentan valores

de intensidad más elevados (ver Figura 3.11). Lo que quiere decir que los WT con más probabilidad de lluvia no tienen por qué presentar mayor potencial para producir eventos extremos. Los 81 WT y sus correspondientes tipos de tormentas, permiten explorar todo el espectro de patrones sinópticos que afectan a la isla de Tenerife.

3.4.4. Predicción a corto plazo probabilística

Existen muy pocas herramientas específicamente desarrolladas para realizar predicciones a corto plazo de precipitación (Neiman et al., 2009; Wright et al., 2017). En la mayoría de los casos dichas herramientas se basan en utilizar directamente las salidas de modelos climáticos regionales o en extrapolar la precipitación observada a partir de datos de radar e imágenes satelitales. En este último caso, como se comentó en el estado del arte, no estaríamos hablando de predicción a corto plazo si no de *nowcasting*, que sirve para predecir la precipitación a unas pocas horas vista. En el caso de los modelos climáticos, estos no son capaces a día de hoy de ofrecer pronósticos precisos de precipitación a la resolución temporal y espacial requerida por muchas aplicaciones hidrológicas. Mientras que los productos derivados de satélites y de radares, generalmente subestiman los eventos más extremos de precipitación y por lo tanto deberían ser calibrados mediante datos instrumentales de precipitación (Krzysztofowicz, 1995; Liu et al., 2013; Moser et al., 2015; Toth et al., 2000).

Las principales ventajas de la metodología basada en tipos de tiempo, respecto a las mencionadas anteriormente, son: (1) su coste computacional es muy reducido lo que permite realizar predicciones en unos pocos segundos; (2) los resultados muestran una distribución estadística semejante a los datos observados y (3) nos permite realizar dos tipos de predicciones. Por un lado podemos trabajar con las distribuciones de precipitación que tuvieron lugar en cada WT y dar como resultado la precipitación media (ver Figuras 3.10 y 3.11) o los cuantiles, dependiendo de si quisiéramos conocer o no la variabilidad de los datos de precipitación asociados a cada WT. Y por el otro, podría darse el caso de que los eventos más extremos de precipitación no fueran representativos del riesgo real de inundación, ya que esta podría depender de otros factores, como la distribución espacial de la misma o de factores antrópicos (urbanización, deforestación, etc.). Este último enfoque permite asociar los eventos que realmente ocasionaron daños económicos, o humanos, en el pasado con unos WT determinados sin necesidad de utilizar los datos de precipitación. En este caso no estaríamos hablando de un sistema de predicción de la precipitación sino de un sistema de alerta de riesgo ante inundaciones. La principal desventaja de la metodología basada en tipos de tiempo es que no permite extrapolar los datos de precipitación para generar eventos de mayor magnitud. Para

ello habría que acudir a otros métodos, como por ejemplo aquellos basados en modelos lineales generalizados.

Como se comentó previamente, el sistema de predicción se alimenta de los pronósticos atmosféricos proporcionados por el modelo de predicción GFS. Los pronósticos de SLP, GH500 y GH850, son descargados de la NOAA para los tres días posteriores. Una vez descargados, se buscan los WT más parecidos y se seleccionan aquellos WT cuya distancia euclídea es menor en el espacio de las PCAs. La predicción probabilística de lluvia se lleva a cabo mediante los campos espaciales de precipitación que tuvieron lugar durante las fechas correspondientes a esos WT.

Las Figuras 3.12, 3.13 y 3.14 muestran un ejemplo de la predicción realizada en la fecha 2017-06-06 para las fechas 2017-06-07, 2017-06-08 y 2017-06-09, respectivamente. La Figura 3.12 muestra los campos espaciales de GH500 extraídos del modelo GFS. Las Figuras 3.13 y 3.14 muestran los tipos de tormenta correspondientes a dichos WT. La Figura 3.13 corresponde a los resultados de probabilidad de lluvia mientras que la Figura 3.14 a la intensidad. La técnica Kriging Universal fue utilizada para generar los resultados en formato espacial con una resolución de 5 metros. La posición de las celdas y su resolución coinciden con el modelo digital de terreno proporcionado por CIATF. En este ejemplo únicamente se muestra la precipitación media (ocurrencia e intensidad) asociada a cada WT. Sin embargo, la principal ventaja de este método es que cada tipo de tormenta representa n días con unas condiciones atmosféricas sinópticas similares, pero que en algunos casos pudieron originar tormentas muy diferentes debido principalmente a procesos locales no capturados por los modelos de reanálisis. El potencial de la técnica basada en tipos de tiempo reside precisamente en que una vez realizada la clasificación podríamos explorar toda esa variabilidad. Por ejemplo, en vez de dar como resultado los valores de precipitación media, podríamos calcular el cuantil del 99% o la probabilidad de que un tipo de tiempo concreto diese como resultado un evento de precipitación con una intensidad mayor a un umbral determinado (ver Figura 3.17).



Figura 3.12: Pronóstico de GFS para la variable GH500 y para las fechas 2017-06-07, 2017-06-08 y 2017-06-09. Fuente: Figura adapatada a partir del artículo Diez-Sierra y del Jesus (2017).



Figura 3.13: Predicción de la probabilidad de lluvia (%) para los días 2017-06-07, 2017-06-08 y 2017-06-09. El cuadro situado en la esquina inferior izquierda muestra el número del WT correspondiente. Fuente: Figura adaptada a partir del artículo Diez-Sierra y del Jesus (2017).



Figura 3.14: Predicción de la intensidad de lluvia (mm/día) para los días 2017-06-07, 2017-06-08 y 2017-06-09. El cuadro situado en la esquina inferior izquierda muestra en número del WT correspondiente. Fuente: Figura adaptada a partir del artículo Diez-Sierra y del Jesus (2017).

Se ha validado el modelo de predicción basado en WT de dos maneras diferentes. Primero se han reconstruido los 36 años de precipitación que coinciden con el periodo en el que disponemos de datos de reanálisis (1979-2015). Los resultados se han comparado con las series instrumentales mediante la técnica de validación cruzada k-fold (Markatou et al., 2005). Esta técnica se basa en dividir el período de observación en k subperiodos y reconstruir cada subperiodo usando la información de los otros k - 1. La precipitación para un día determinado se calculará mediante el promedio de los datos de precipitación que tuvieron lugar en ese WT durante el periodo de entrenamiento (Figuras 3.10 y 3.11). La técnica k-fold evita el sobreajuste de los modelos⁵ así como también cualquier efecto espúreo de una división en particular. Hemos preferido utilizar como predictor del modelo la base de datos de reanálisis de CFSR, en vez de las salidas de GFS, para eliminar así la incertidumbre asociada al modelo climático de predicción. Es importante tener en cuenta que los resultados no son únicos ya que las probabilidades (probabilidad de que llueva un día determinado) están involucradas en el proceso de reconstrucción.

 $^{{}^{5}}$ El sobreajuste (también es frecuente emplear el término en inglés *overfitting*) es el efecto de sobreentrenar un algoritmo para el cual se conoce el resultado deseado.

Por ello la reconstrucción se repitió 100 veces y como resultado se calculó el promedio de las 100 realizaciones.

Como ejemplo, la Figura 3.15 muestra la serie reconstruida (línea roja discontinua) mediante la técnica WT y la serie observada para el año 2010 (línea azul) para la estación "Santiago del Teide", ubicada en la parte noroeste de la isla. La serie reconstruida corresponde a una de las 100 simulaciones. El panel superior muestra la serie a una agregación temporal diaria mientras que el panel inferior corresponde a la media móvil tres-diaria. Como se puede observar en la figura, la correlación entre la serie reconstruida y la observada es mayor una vez que se aplica la media móvil, lo cual es esperable ya que la reconstrucción se realizó con los valores promedios de lluvia para cada WT.



Figura 3.15: Serie reconstruida (línea roja) mediante la técnica WT y observada (línea azul) para la estación "Santiago del Teide", ubicada en la parte noroeste de la isla para el año 2010. La serie reconstruida corresponde a una de las 100 simulaciones. El panel superior muestra la serie diaria mientras que el panel inferior corresponde a la media móvil 3-diaria. Fuente: Figura adaptada a partir del artículo Diez-Sierra y del Jesus (2017).

Las 17 estaciones con mayor información en el periodo 1979-2015 fueron seleccionadas para analizar la capacidad del método basado en WT para reconstruir las series de precipitación históricas durante el proceso de validación cruzada (ver Figura 3.16). La precipitación media asociada a cada WT fue utilizada durante el proceso de reconstrucción (ver Figuras 3.10 y 3.11). Los resultados promediados para las 17 estaciones muestran un sesgo prácticamente nulo para el número de días de lluvia y para su intensidad. Los resultados de validación ofrecen un valor de RMSE promediado para todas las estaciones de 15.6 mm/día. El porcentaje de días que son clasificados correctamente como días de lluvia es del 30% de promedio para todas las estaciones. La cifra aumenta hasta un 50% para la media móvil 3-diaria y alcanza el 70% cuando la intensidad de lluvia observada es superior a 30 mm/día. La Figura 3.16 muestra el índice de puntuación f-score (Powers, 2011) para las 17 estaciones. El índice de puntuación f-score es muy útil para comparar la habilidad de las predicciones cuando se trabaja con conjuntos de
datos desequilibrados (conjuntos de datos en los que una clase es mucho más frecuente que la otra), como en el caso de Tenerife donde el porcentaje de días de lluvia puede variar de un 25% de los días en las estaciones situadas en el norte de la isla, a un 5%en algunas estaciones situadas en el sur. La Figura 3.16 muestra que la habilidad de modelo basado en WT para predecir los días de lluvia es significativamente mejor en el norte que en el sur de la isla; lo que probablemente se deba a que los tipos de tiempo capturan la precipitación frontal, que suele ocurrir en el norte de la isla, mejor que la convectiva, que prevalece en el sur. Un modelo que tiene una precisión del 30% y un valor de f-score de 0.28 podría no parecer muy hábil. Sin embargo, si comparamos estos resultados con aquellos generados con un modelo aleatorio el cual únicamente preserva el número de días de lluvia al año para cada estación, vemos que los resultados obtenidos son significativamente pe
ores. El modelo aleatorio únicamente acertaría el 13 %
de los días de lluvia y alcanzaría una puntuación de *f-score* cercana a 0.13; lo que nos llevaría a un modelo la mitad de bueno que el basado en WT. Si utilizásemos un modelo un poco más complejo, que además de conservar el número de días de lluvia también preservase las probabilidades de transición (modelo basado en cadenas de Markov), obtendríamos una precisión del 20% y un *f-score* de 0.23, lo que nos conduciría a un modelo con un valor de *f-score* significativamente inferior al alcanzado por nuestro modelo.



Figura 3.16: Resultados de *f-score* durante la validación cruzada para las 17 estaciones seleccionadas durante la validación cruzada. Fuente: Diez-Sierra y del Jesus (2017).

Por otro lado también se ha validado la habilidad del sistema de predicción basado en WT para identificar aquellos eventos con una intensidad de precipitación superior a 200 mm/día en el periodo 1979-2015; umbral a partir del cual según los registros históricos muchos de los eventos generaron inundaciones. Como podemos observar en la Figura 3.17, la mayoría de los eventos se concentran en unos pocos WT. Además, a excepción

de los WT número 21 y 63, la probabilidad de ocurrencia de los WT es significativamente inferior a la media (1.23 % de los días). Es importante prestar especial atención a aquellos WT con poca probabilidad de ocurrencia y que contienen un elevado número de eventos extremos, como es el caso de los WT número 18 y 27. Si nos fijamos por ejemplo en el WT 27, vemos que su probabilidad de ocurrencia es del 0.5 %, lo que quiere decir que en 35 años únicamente se ha dado 63 días de media. Sin embargo, de esos 63 días, 7 tuvieron asociados tormentas con una intensidad mayor de 200 mm/día. Algunos de estos eventos de inundación, como los que tuvieron lugar en las fechas 4-12-1991, 13-12-1995 y 31-03-1995, para los WT número 37, 27 y 21, respectivamente, están asociados a situaciones de "gota fría".

Por lo tanto, los resultados del presente análisis muestran que aunque el sistema basado en WT no ofrece predicciones precisas de la precipitación para un día determinado, es especialmente útil como sistema de la alerta temprana ante inundaciones.



Figura 3.17: 35 eventos de lluvia con una intensidad superior a 200 mm/día en el período 1979-2015. Las barras azules y naranjas corresponden al número de eventos con una intensidad mayor 200 mm/día y a la probabilidad de ocurrencia asociada a cada WT, respectivamente. La línea horizontal negra corresponde a la probabilidad de ocurrencia media para los 81 WT. Fuente: Figura adaptada a partir del artículo Diez-Sierra y del Jesus (2017).

3.4.5. Conclusiones

La técnica Kriging Universal, que utiliza como tendencia (drift) la elevación y la precipitación media anual, ha sido seleccionada para reconstruir los datos de precipitación faltantes para el periodo 1979-2015 para las 125 estaciones, así como también para generar los resultados en formato espacial con una resolución de 5 m. Una de las principales limitaciones de las técnicas geoestadísticas es que en aquellas áreas donde hay un bajo número de estaciones, o donde están muy alejadas entre sí, la calidad de la reconstrucción se ve fuertemente afectada por esta falta de información (Beguería et al., 2016). En dichas áreas, habría que utilizar técnicas de interpolación que, además de información topográfica, integrasen como covariables variables climáticas capaces de capturar la heterogeneidad subyacente en la precipitación (Daly et al., 2008; Isotta et al., 2014).

El sistema de predicción basado en WT requiere un enfoque más sofisticados que aquel basado en la precipitación media asociada a cada WT. Un 50 % de acierto en los días de lluvia cuando la información de precipitación es agregada a una resolución tresdiaria es aceptable; pero aún no es lo suficientemente bueno para implementarse como sistema de predicción de precipitación cuantitativa. Sería conveniente investigar nuevos enfoques basados en técnicas de aprendizaje automatizado supervisadas para mejorar los resultados de predicción a corto plazo de precipitación obtenidos en el presente análisis. No obstante, hemos demostrado que la metodología basada en WT presenta un gran potencial como sistema de alerta de inundaciones, ya que clasifica correctamente los tipos de clima que produjeron lluvias extremas e inundaciones en la isla de Tenerife en el pasado.

Los WT constituyen una buena representación de los diferentes tipos de patrones sinópticos atmosféricos existentes en Tenerife ya que los tipos de tormenta derivados muestran patrones de lluvia bastante homogéneos. Sin embargo, sería necesario investigar en profundidad las diferentes relaciones entre los WT y las tormentas tipo. En este estudio, se realizó una clasificación ciega o no supervisada. Es decir, la precipitación no fue utilizada en ningún momento durante el proceso de calibración de los modelos. Para obtener unos resultados óptimos, la clasificación debería de considerar el objetivo final: agrupar las situaciones atmosféricas en patrones de lluvia homogéneos.

Los análisis presentados en la presente sección han sido incorporados en una aplicación que recibe el nombre de MENSEI-L (Diez-Sierra y del Jesus, 2017). MENSEI-L está implementada en el CIATF desde el año 2016 y constituye una herramienta muy útil para el análisis estadístico de redes de estaciones pluviométricas. MENSEI-L también simplifica la aplicación de técnicas matemáticas avanzadas (geoestadística) y automatiza los diferentes procesos, permitiendo que cualquier usuario no especializado pueda hacer uso de ellas. Los diferentes análisis presentando en este apartado pueden utilizarse para evaluar el riesgo asociado a eventos extremos y para el diseño de infraestructuras, entre otras aplicaciones.

3.5. Predicción a largo plazo mediante modelos estadísticos y máquinas de aprendizaje automatizado

En la Sección 3.4 "Predicción probabilística a corto plazo basada en tipos de tiempo", se ha presentado una herramienta para hacer predicciones a corto plazo de precipitación así como para automatizar diferentes procesos relacionados con el tratamiento de datos de precipitación. Los resultados obtenidos en dicha sección ponen de manifiesto que el método de aprendizaje no supervisado basado en tipos de tiempo podría no ser el más eficaz a la hora de predecir la ocurrencia e intensidad de lluvia para un día determinado. No obstante, es una herramienta que resulta muy útil como sistema de alerta ante inundaciones, ya que es capaz de clasificar la mayoría de eventos de inundación en el pasado en unos pocos tipos de tiempo con muy poca probabilidad de ocurrencia. En esta sección se ha ampliado el trabajo realizado en la Sección 3.4 a través de un análisis de sensibilidad en el que comparamos diferentes técnicas estadísticas y de aprendizaje automatizado (supervisadas y no supervisadas) para reconstruir la precipitación varias décadas en el pasado (predicción a largo plazo). Las metodologías desarrolladas en la presente sección podrían ser utilizadas también para realizar predicciones a corto plazo si se incorporará explícitamente la autocorrelación temporal en los modelos.

El pronóstico o predicción a largo plazo basado en métodos estadísticos, normalmente, utiliza técnicas de regresión, de las cuales se pueden encontrar una gran cantidad de aproximaciones en la literatura; incluidos métodos paramétricos y no paramétricos, lineales y no lineales (He et al., 2015; Kannan y Ghosh, 2013; Pérez-Rodríguez et al., 2012; Qiu et al., 2016). Los modelos lineales generalizados (*Generalized Linear Model* o GLMs, por sus siglas en inglés), los modelos de regresión logística y las máquinas de vectores de soporte (*Support Vector Machine* o SVM, por sus siglas en inglés) con funciones kernel⁶, son modelos paramétricos con un número limitado de parámetros; mientras que la técnica de análogos o *k-nearest neighbors* (k-NN), los árboles de decisión, las SVMs con funciones kernel de base radial y las redes neuronales, por ejemplo, son modelos no paramétricos en los no se asume ningún modelo formal por defecto (Sheskin, 2003).

El aumento exponencial de la capacidad computacional de los ordenadores durante los últimos años ha favorecido el uso de técnicas de aprendizaje automático sobre otros métodos de regresión (Hong, 2008); lo que se debe, principalmente, a que son capaces de encontrar relaciones no lineales entre las variables, y también a que no es necesario asumir ningún tipo de distribución/relación entre las variables a priori. Además, algunas de las hipótesis que suelen tener que cumplir las métodos estadísticos (normalidad, homoscedasticidad, etc.) pueden ser obviados con el uso de este tipo de métodos.

⁶Funciones que permiten convertir lo que sería un problema de clasificación no lineal en el espacio dimensional original, en un problema de clasificación lineal en un espacio dimensional mayor.

En esta sección, se comparan diferentes métodos estadísticos (GLM) y de aprendizaje automatizado (SVM, k-NN, bosques aleatorios, técnicas de clusterización o agrupamiento y redes neuronales) para realizar predicciones a largo plazo de precipitación. Como predictores se seleccionarán las mismas variables atmosféricas de reanálisis utilizadas en la sección previa (SLP, GH500, GH850) de la base de datos CFSR (ver Sección 3.3 "Datos de partida").

La predicción a largo plazo tiene, generalmente, como objetivo reconstruir la información de precipitación en el pasado durante varias décadas, y es muy útil para comprender la variabilidad natural del clima y poder estimar, por ejemplo, el riesgo asociado a diferentes tipos de eventos extremos con una probabilidad de ocurrencia muy baja, como inundaciones, sequías, etc. Varios autores han investigado la habilidad de estos algoritmos para predecir la precipitación en el pasado (Olsson et al., 2004; Stern y Coe, 1984; Sumi et al., 2012; Valverde Ramírez et al., 2005). Sin embargo, los resultados alcanzados evidencian que cada algoritmo tiene sus ventajas y limitaciones, por lo que la selección del método óptimo generalmente no es un tema para nada trivial (Gupta y Ghose, 2015). Además, ninguno de los estudios realizados hasta la fecha ha llevado a cabo una comparación tan exhaustiva como la que se presenta aquí, haciendo uso de los principales métodos presentes en la literatura para la predicción a largo plazo de la precipitación. Asimismo, a diferencia de la mayoría de los estudios realizados hasta la fecha, aquí se analiza la capacidad de los diferentes métodos, no solo para preservar algunas métricas (precisión, error cuadrático medio, etc.), sino también para preservar diferentes estadísticos de las series observadas de precipitación como: la varianza, las probabilidades de transición, la correlación espacial y algunos índices extremales que influyen enormemente en las respuestas hidrológicas (Serrano-Notivoli et al., 2018a). De igual modo, los resultados de los estudios realizados hasta la fecha, generalmente, no se basan en pruebas estadísticas para evaluar si la diferencia en la destreza entre los diferentes modelos era significativa o no.

Los métodos presentados en esta sección pueden aplicarse en todo el mundo siempre y cuando se disponga de series instrumentales con una cobertura temporal suficientemente larga para entrenar y validar los métodos. Además los análisis realizados podrían extenderse también para estudios de cambio climático mediante la incorporación de los efectos del calentamiento global en los predictores.

Al igual que en la sección anterior (Sección 3.4), los diferentes análisis se han realizado en la isla de Tenerife, España, donde la escasez de precipitaciones y la alta variabilidad espacio-temporal de la misma dificulta enormemente la predicción de la precipitación.

3.5.1. Métodos

Como se mencionó en secciones previas, los métodos estadísticos y de aprendizaje son entrenados/ajustados para predecir la precipitación diaria utilizando como predictores variables atmosféricas de reanálisis. Las mismas 17 estaciones pluviométricas seleccionadas en el apartado 3.4.4, "Predicción a corto plazo probabilística", serán utilizadas para calibrar y validar los diferentes modelos. Estas estaciones han sido seleccionadas en base a tres criterios: (1) las estaciones deben disponer de la mayor cobertura temporal posible, (2) deben cubrir el mismo periodo de referencia para poder comparar así los resultados entre estaciones y (3) el número de estaciones seleccionadas cubrirán, en la medida de lo posible, todos los tipos de climas existentes en la isla. Este último punto es muy importante ya que permite comparar la habilidad de los modelos en diferentes regímenes climáticos. Siguiendo estas consideraciones, se seleccionaron aquellas estaciones con al menos 25 años de datos en el período 1979-2015, que coincide con la cobertura temporal de la base de datos de reanálisis CFSR.



Figura 3.18: Vista satelital de Tenerife. Los puntos blancos representan la localización de las 17 estaciones seleccionadas para los diferentes análisis. En la imagen satelital se puede observar El Teide y Las Cañadas en el centro de la isla. Fuente: Figura incluida en el artículo en revisión enviado a la revista *Journal of Hydrology* Diez-Sierra y del Jesus 2019.

La Figura 3.18 muestra la ubicación y el identificador de las 17 estaciones pluviométricas seleccionadas. Como se puede apreciar, las estaciones cubren la zona norte de la isla, relativamente húmeda, y zona sur, mucho más árida. La Tabla 3.1, muestra la elevación, el porcentaje de datos faltantes y la zona de la isla en la que se encuentra cada estación (N:Norte, S:Sur, O:Otra). Además, también se puede apreciar que se dispone de estaciones cubriendo un rango de alturas que va desde los 50 m hasta los 2400 m sobre el nivel del mar. La precipitación media anual para las 17 estaciones es de 371 mm y llueve de promedio unos 45 días al año.

El 80 % de los datos de cada estación son utilizados para ajustar los modelos (entrenar), y el 20 % restante para evaluar los resultados predichos (test), de manera que cada una de las series de precipitación de 36 años se dividen en dos conjuntos: el conjunto de entrenamiento, que contiene 30 años de datos; y el conjunto que conocido como test, que contienen los restantes 6 años. Los modelos son ajustados de manera independiente para cada estación.

TABLA 3.1: La tabla muestra el identificador (ID), la elevación (Elev., M), el porcentaje de datos faltantes (% huecos) y la ubicación dentro de la isla (Norte, N; Sur, S; otro, O) de las 17 estaciones utilizadas para realizar los diferentes análisis. Fuente: Tabla adaptada a partir del artículo en revisión enviado a la revista Journal of Hydrology Diez-Sierra y del Jesus 2019.

ID	Elev. (m)	% huecos	Localización
1940	959.86	15.1	N
2081	633.93	0.2	N
2110	383.33	3.9	N
2112	378.33	2.6	N
2115	502.77	25.9	N
2135	122.8	25.0	N
2173	513.45	2.3	N
2204	114.06	21.5	N
2241	511.61	4.9	N
2249	49.9	1.6	N
2015	2370.16	4.7	0
2050	450.22	3.7	0
2118	47.7	0.0	0
1976	1409.1	2.5	S
1989	597.62	2.6	S
2010	71.81	4.9	S
2061	125.31	21.3	S

Por otro lado, las técnicas de aprendizaje automatizado disponen de hiperparámetros que controlan su comportamiento. Los hiperparámetros pueden determinar la rutina de optimización utilizada para el ajuste, el esquema de regularización utilizado y el tipo de transformación no lineal aplicada a los datos de entrada, entre otras cosas. El conjunto de entrenamiento se utiliza para determinar los hiperparámetros óptimos mediante la técnica de validación cruzada k-fold (Markatou et al., 2005). Para encontrar estos hiperparámetros óptimos, se repite el proceso de validación cruzada tantas veces

como combinaciones de parámetros haya. Los 30 años de entrenamiento se subdividen a su vez en k subconjuntos: el conjunto k-1 se usa para entrenar el modelo y el k-ésimo se utiliza para evaluarlo. Para cada conjunto de hiperparámetros, el proceso se repite k veces, determinando un rendimiento promedio y seleccionando aquellos hiperparámetros que maximicen (o minimicen) nuestra función objetivo. El rendimiento de los modelos es evaluado finalmente sobre el conjunto conocido como test, el cual no fue usado en ningún momento durante el proceso de calibración (ver Figura 3.19). Cada modelo es evaluado por separado para predecir la ocurrencia de la lluvia (si llueve o no llueve) y su intensidad. También se utilizarán distintas funciones objetivos o de pérdida (*loss fuctions*) para capturar diferentes propiedades de las series de precipitación.

La Figura 3.19 muestra el esquema metodológico seguido para ajustar los diferentes modelos.



Figura 3.19: Esquema metodológico seguido para ajustar y evaluar los modelos. Fuente: Figura adaptada a partir del artículo en revisión enviado a la revista Journal of Hydrology Diez-Sierra y del Jesus 2019.

3.5.1.1. Construcción de los predictores

Al igual que en la Sección 3.4 "Predicción probabilística a corto plazo basada en tipos de tiempo", los campos espaciales de la base de datos de reanálisis CFSR, para las variables SLP, GH500 y GH850, son utilizados como predictores para entrenar los diferentes métodos. El área y la cobertura temporal seleccionadas han sido las mismas que las utilizadas en la Sección 3.4 (ver Figura 3.4), sin embargo, en este caso se utilizará como predictor directamente el resultado del análisis de componentes principales.

Como comentamos, la aplicación del método PCA ofrece una representación más funcional de los datos de partida, ya que muchas de las dimensiones originales se verán reducidas en la nueva proyección sin perder prácticamente nada de información. La técnica de PCA es aplicada a la matriz original de 180.000 x 13.514 elementos. El resultado es una matriz con 14 componentes principales que capturan el 95 % de la varianza del conjunto de datos original (ver Sección 3.4.3 "Generación de tipos de tiempo y tormentas tipo").



Figura 3.20: En el panel situado a la izquierda se muestra las funciones seno y coseno, para dos años cualquiera, que han sido utilizadas como predictores adicionales en los modelos de regresión. En el panel situado en la derecha se muestra el valor de índice NAO anual para lo meses de diciembre a marzo en el periodo 1979-2015.

Además de las variables atmosféricas, se ha incorporado también la estacionalidad como un predictor adicional a los modelos. Aunque en la mayoría de los casos los campos espaciales de las variables SLP, GH500 y GH850 caracterizan por si solos las diferentes estaciones del año (primavera, verano, otoño e invierno), en otros casos no ocurre así, y son otras variables, como la temperatura superficial del aire o la humedad las que explican en que estación del año nos encontramos, así como el comportamiento estadístico de la precipitación para esas fechas. Es por eso que cuando se informa a los regresores sobre el comportamiento estacional de la precipitación los resultados suelen mejorar. Una forma sencilla de incluir dicha no estacionariedad es usar como predictor alguna función que imite la forma de la precipitación media mensual durante el año. La función analítica más simple, y que es capaz de reproducir esa forma, es una combinación de un seno $(y_1 = \sin(\frac{2\pi t}{T}))$ y un coseno $(y_2 = \cos(\frac{2\pi t}{T}))$ de período (T) 12 meses (ver Figura 3.20). Las funciones seno y coseno $(y_1 y y_2)$ constituyen dos predictores adicionales que se añaden a las técnicas estadísticas y de aprendizaje automatizado para informar sobre la estacionalidad de la precipitación a lo largo del año (Méndez et al., 2007).

Por último, también es sabido que el índice climático de la Oscilación del Atlántico Norte (*North Atlantic Oscillation* o NAO, por sus siglas en inglés) tiene un efecto muy importante sobre los regímenes de precipitación en muchas partes de Europa. Concretamente en las islas Canarias la precipitación para los meses de invierno se intensifica durante los años de NAO negativa (García-Herrera et al., 2003). Es por ello que también se ha creído conveniente incluir el valor del índice NAO anual agregado para los meses comprendidos entre diciembre y marzo como predictor adicional.

3.5.1.2. Métodos estadísticos y de aprendizaje automatizado

Los métodos estadísticos utilizados tradicionalmente para predecir la precipitación se basan en modelos clásicos de regresión lineal y en GLMs; permitiendo estos últimos que los errores de las variables respuesta se distribuyan mediante distribuciones no Gaussianas (Coe y Stern, 1982; Stern y Coe, 1984). Sin embargo, con el aumento de la capacidad computacional de los ordenadores durante estos últimos años, los métodos de aprendizaje automatizado han ido ganando importancia frente a la regresión lineal, ampliando enormemente el abanico de métodos disponibles para enfrentarse a la problemática de la predicción temporal de la precipitación (Qiu et al., 2016).

Las técnicas de aprendizaje automatizado tienen principalmente dos ventajas frente a los métodos convencionales. La primera es que normalmente no requieren ninguna suposición acerca de la distribución de los errores. Y la segunda es que la forma de las relaciones entre los predictores y los predictandos no necesita ser conocida a priori (Appelhans et al., 2015).

Por otro lado, la intermitencia de la lluvia a una agregación temporal diaria o menor (la sucesión de intervalos húmedos y secos de duración finita) hace que sea más conveniente dividir el problema de predicción en dos partes, modelando por un lado la ocurrencia de la lluvia, y por el otro su intensidad (Olsson et al., 2004). Es por ello que la metodología para predecir la precipitación se suele dividir en dos partes: la parte en la que se utilizan los modelos conocidos como *clasificadores*, que tratan con datos categóricos (llueve y no llueve) y tienen el objetivo de predecir la ocurrencia de lluvia; y la parte en la que se utilizan los modelos conocidos como *regresores*, que tratan con datos continuos y son utilizados para predecir la intensidad de las precipitación.

La Tabla 3.2 presenta los modelos estadísticos y de aprendizaje automatizado utilizados durante los diferentes análisis. La primera columna muestra el nombre del modelo, la segunda corresponde a su abreviatura (Abr.), la tercera muestra si el método se utiliza para resolver un problema de clasificación (C), regresión (R) o ambos (C / R), la cuarta columna enumera los hiperparámetros que serán optimizados durante el análisis, y finalmente, la quinta columna enumera el rango de valores de los hiperparámetros explorados durante la optimización de los modelos. Los algoritmos utilizados para realizar los diferentes análisis están implementados en las librerías *stats* (R Core Team, 2017) y *Scikit-learn* (Pedregosa et al., 2011). A continuación se presentan los aspectos más importantes de los métodos seleccionados como regresores y clasificadores.

Se han seleccionado dos GLMs. Por un lado, el método GLM-L corresponde a una regresión lineal clásica pero con una función de enlace logarítmica. La función de enlace logarítmica transforma los datos para que estos se asemejen más a una distribución TABLA 3.2: Métodos estadísticos y de aprendizaje automatizados utilizados durante los diferentes análisis. Los nombres de los métodos aparecen en la primera columna; la segunda columna corresponde a las abreviatura de los mismos (Abr.); en la tercera columna se muestra si el método se utiliza como clasificador (C), regresor (R) o ambos (C / R); la cuarta y la quinta columna recogen los hiperparámetros y los rangos establecidos para la búsqueda de los hiperparámetros óptimos. Fuente: Tabla adaptada a partir del artículo en revisión enviado a la revista *Journal of Hydrology* Diez-Sierra y del Jesus 2019.

Modele	Abn	C/P		Grid Search
Modelo	ADI.	0/1	Parámetros	Valores
Generalized Linear Models (familia=gaussian, link=log)	GLM-L	R	None	None
Generalized Linear Models (familia=gamma, link=log)	GLM-G	R	None	None
			solver	sag,newton-cg, lbfgs,liblinear
Logistic Regression	LR	C	penalty	11, 12
			С	0.1, 1, 5, 10, 25, 50, 75, 100, 200, 1000
Bandom Forest	BE	C and B	n_estimators	1,2,5,10,20,40,60,80,100,200
Random Forest	IU		min_samples_leaf	1,2,4,6,10,15,30,50
k Neerest Neighbourg	I NN	C and P	n_neighbors	1,2,3,4,5,6,7,8,9,10,15,20,25,30,35,40,45,50
k-mearest meighbours	K-ININ	C and R	weights	uniform, distance
			С	0.1,1,2,5
	SVM	C	kernel	rbf
Support Vector Machines			γ	0.005, 0.01, 0.025, 0.05
Support vector Machines			С	25,50,75,100,150,200,250,300
		D	kernel	rfb
		n	ε	0.001,0.1,0.2,0.5,1,2,5,10,20
			γ	0.01,0.025,0.05,0.075,0.1
Weather Typing (K-means)	WT	C and R	n_clusters	4,9,16,25,36,49,64,81,100,121,144
			solver	lbfgs, sgd, adam
			alpha	0.0001,0.001,0.1,10,1000
		C	hidden_layer_sizes	N:2,3,4,5,6,7,10; L:1, 2, 3
			activation	identity, logistic, tanh, relu
Neural Networks	NN		max_iter	2000
			solver	lbfgs, sgd, adam
		B	alpha	0.0001,0.001,0.1,10,1000
		n	hidden_layer_sizes	N: 2,3,4,5,6,7,8,9,10,15,20; L:1, 2, 3
			activation	identity, logistic, tanh, relu

Gaussiana, mejorando así la calidad del ajuste. Por otro lado, GLM-G, permite variables respuesta⁷ que tienen modelos de distribución de errores que siguen una distribución gamma. La distribución gamma se usa comúnmente para modelar la lluvia ya que la intensidad de la misma tiende a presentar asimetrías muy marcadas a agregaciones temporales diarias o por debajo del día (Ben Alaya et al., 2017; Stephenson et al., 1999; Yang et al., 2005).

Además de los GLMs se han utilizado 6 algoritmos diferentes de aprendizaje automatizado (ML). El método conocido como bosques aleatorios (*Random Forests* o RF, por sus siglas en inglés) es un método de conjuntos o combinado (*ensemble*) cuyo esquema de entrenamiento se basa en un número de árboles de decisión, dando como resultado la moda de las clases predichas del conjunto de árboles individuales (clasificación), o la

 $^{^{7}\}mathrm{Las}$ variables de interés en un experimento (las que se miden u observan) se denominan variables de respuesta o dependientes.

media de las predicciones de los árboles individuales (regresión). Dos hiperparámetros han sido optimizados para el método RF: *N_estimators*, que corresponde al número total de árboles en el bosque, y *min_samples_leaf*, que corresponde al número mínimo de muestras requeridas para formar un nodo/hoja sobre el cual calcular la moda o la media.

El método de los vecinos más cercanos (k-nearest neighbors o k-NN, por sus siglas en inglés) es un método no lineal cuyas predicciones se calculan a través la moda (clasificación) o la media (regresión) ponderada en función de los k vecinos más cercanos. Dos hiperparámetros han sido optimizados para el método k-NN: $n_neighbors$, que corresponde al número de vecinos utilizados en la predicción, y weights, que corresponde a la forma en la que se asignan los pesos a cada vecino. Esta a su vez puede ser uniforme (uniform), que significa que a todos los vecinos k les corresponde el mismo peso, o en función de la distancia (distance), que significa que a cada vecino se le asigna un peso en función de su distancia inversa.

Las redes neuronales (*Neural Networks* o NN, por sus siglas en inglés) transforman los predictores a través de una capa de entrada (*input layer*) mediante una función específica (*activation function*) con el objetivo de predecir unos datos de salida (*output layer*). Para ello establecen combinaciones lineales y transformaciones no lineales (*activation function*) mediante una serie de neuronas y capas ocultas (*hidden layers*). Tres hiperparámetros han sido optimizados en el caso del método NN: *hidden_layer_sizes*, que corresponde al número de neuronas y de capas utilizadas; *activation*, que define la función no lineal usada por cada neurona para transformar la combinación lineal de datos de entrada; y *alpha*, un término que controla la intensidad de la regularización.

Las máquinas de vectores de soporte (Support Vector Machine o SVM, por sus siglas en inglés) se pueden utilizar tanto para resolver problemas de clasificación como de regresión. Su funcionamiento se basa en encontrar los hiperplanos que maximizan el espacio mínimo que separa las muestras que pertenecen a diferentes grupos (márgenes). Los puntos, o muestras, se denominan vectores, mientras que a aquellos que definen los hiperplanos se denominan vectores de soporte (support vectors). Se suelen utilizar funciones de base radial (Radial Basin Funtions o RBF, por sus siglas en inglés) para garantizar que la separación entre clases es no lineal. Tres hiperparámetros han sido optimizados para el algoritmo SVM: γ , que es el radio del área de influencia de los vectores de soporte; C, que puede verse como el inverso del término de regularización; y ϵ , que define un margen de tolerancia a partir del cual no se penalizan los errores.

La regresión logística (*Logistic Regression* o LR, por sus siglas en inglés) clasifica los resultados de ocurrencia de lluvia transformando los datos de entrada mediante una función de enlace logística (*logit*) a través de una regresión lineal. Tres hiperparámetros fueron analizados para el modelo LR: *Solver*, que es el algoritmo utilizado en el problema

de optimización; *penalty*, que corresponde a la función aplicada para asignar los pesos durante la regresión; y C, que puede verse como la inversa del termino de regularización (muy parecido que en el algoritmo SVM).

Finalmente, el método basado en tipos de tiempo (*Weather Typing* o WT, por sus siglas en inglés) divide el espacio de entrada en una serie de tipos y utiliza la moda o la media de los datos asociados a cada tipo para resolver el problema de clasificación o regresión. Los mismos tipos de tiempo y tormentas tipo que fueron calculados en la Sección 3.4.3 "Generación de tipos de tiempo y de tormentas tipo" mediante el algoritmo k-means (Camus et al., 2011a), han sido utilizados en la presente sección.

Una descripción más detallada de los hiperparámetros seleccionados y de la sensibilidad de los modelos a cada uno de ellos se puede encontrar en *scikit-learn* (Pedregosa et al., 2011).

3.5.1.3. Funciones de pérdida

Las funciones de pérdida o *loss function*, en inglés, miden la distancia entre el valor estimado y el valor objetivo que el modelo debe predecir. El procedimiento de ajuste de cualquier método implica encontrar los valores de los parámetros que optimizan el valor de dicha función de pérdida. En la mayoría de los casos, los modelos de regresión tratan de minimizar el error cuadrático medio (RMSE). Una ventaja de los métodos ML es que la función de pérdida puede ser modificada fácilmente para que los valores predichos por el modelo puedan minimizar/maximizar cualquier función que nos interese.

En el presente trabajo se han utilizado dos funciones de pérdida diferentes según su procedimiento de ajuste. En el caso de los clasificadores, que sirven para predecir la ocurrencia o probabilidad de que llueva un día determinado, se ha utilizado la función f-score (ecuación 3.1).

$$f\text{-}score = 2 \times \frac{\text{Precisión} \times \text{Exhaustividad}}{\text{Precisión} + \text{Exhaustividad}}$$
(3.1)

donde la precisión se define como

$$Precisión = \frac{TP}{TP + FP}$$
(3.2)

y la exhaustividad como

$$Exhaustividad = \frac{TP}{TP + FN}$$
(3.3)

TP (*True Positive*) corresponde al número de días de lluvia correctamente predichos como días de lluvia por el modelo; FP (*False Positive*) corresponde al número de días secos (sin lluvia) predichos como días lluviosos por el modelo; y FN (*False Negatives*) corresponde al número de días lluviosos predichos como días sin lluvia por el modelo.

La precisión mide la probabilidad de que un día predicho como lluvioso por el modelo se corresponda con un día lluvioso real, mientras que la exhaustividad mide la probabilidad de que un día lluvioso sea predicho como lluvioso por el modelo. Un resultado de 1 en ambas métricas corresponde a una puntuación perfecta, es decir que todos los datos son clasificados correctamente, mientras que un resultado de 0 correspondería al peor resultado para ambas métricas. Un modelo que cuando predice los días de lluvia siempre acierta, pero que predice muchos menos días de lluvia al año, tendría una precisión perfecta (un valor de 1); pero sin embargo su valor de exhaustividad sería menor que 1, ya que algunos días lluviosos habría sido predichos como secos por el modelos (FN). Un modelo que predice todos los días como lluviosos tendría una exhaustividad igual a 1 pero su valor de precisión estaría muy cercano a 0.

Por otro lado, la métrica *f-score* es muy útil para comparar la habilidad predictiva de los modelos cuando se trabaja con conjuntos de datos desequilibrados (conjuntos de datos en los que una clase es mucho más frecuente que las otras). Este es el caso de la precipitación en Tenerife que presenta estaciones que alcanzan el 25 % de días de lluvia al año en el norte de la isla y el 5 % en otras situadas en el sur.

Los regresores, que predicen la intensidad de la lluvia, serán evaluados utilizando la métrica error cuadrático medio (RMSE) como función de pérdida (ecuación 3.4).

$$RMSE = \sqrt{\frac{\sum_{t=1}^{n} (x_{1,t} - x_{2,t})^2}{n}}$$
(3.4)

donde x_1 y x_2 corresponden a las series observadas y simuladas, respectivamente. Se ha seleccionado la métrica RMSE como función de pérdida para poder realizar una comparación justa entre los modelos estadísticos y los algoritmos MLs ya que los GLMs utilizan dicha función por defecto.

Aunque no son utilizadas como funciones de pérdida, el sesgo (BIAS) y la correlación de Pearson (R), definidas en las ecuaciones 3.5 y 3.6, respectivamente, también serán empleadas como métricas para evaluar los diferentes modelos.

$$BIAS = \frac{\sum_{t=1}^{n} (x_{1,t} - x_{2,t})}{n}$$
(3.5)

$$R = \frac{\sum_{t=1}^{n} x_{1,t} x_{2,t} - n\bar{x}_1 \bar{x}_2}{\sqrt{\sum_{t=1}^{n} x_{1,t}^2 - n\bar{x}_1^2} \sqrt{\sum_{t=1}^{n} x_{2,t}^2 - n\bar{x}_2^2}}$$
(3.6)

Donde $x_{1,t}$ y $x_{2,t}$ corresponde a las series observadas y simuladas, respectivamente, y n al tamaño de la muestra.

3.5.1.4. Búsqueda en cuadrícula (Grid Search)

Antes de evaluar el rendimiento predictivo de los diferentes modelos sobre el conjunto de datos de prueba (test), habría que determinar los hiperparámetros óptimos para cada uno de los modelos analizados (ver Tabla 3.2). Para ello hemos explorado todas las combinaciones de hiperparámetros existentes mediante una búsqueda conocida como búsqueda en cuadrícula o Grid Search, en inglés. La cuarta columna de la Tabla 3.2, muestra los hiperparámetro analizados para cada uno de los modelos, mientras que la quinta columna muestra los diferentes valores explorados. Cada modelo es entrenado con todas las posibles combinaciones de hiperparámetros, y es evaluado sobre el conjunto de entrenamiento mediante la técnica de validación cruzada k-fold (Markatou et al., 2005). K-fold implica dividir el conjunto de datos en k subconjuntos de igual tamaño, usando los subconjuntos k-1 para entrenar el modelo y el subconjunto k-ésimo para validar. El procedimiento se repite k veces. Mediante esta técnica se calcula el rendimiento promedio en los k entrenamientos para cada combinación de hiperparámetros. Los hiperparámetros óptimos serán aquellos con los que se obtenga un mejor promedio en las k iteraciones. En este estudio, k es igual a 5, de modo que el 80% de los datos seleccionados se utilizan para entrenar el modelo (train) y el 20% restante se utilizará para validar los hiperparámetros. Cada conjunto de entrenamiento se divide en cinco subconjuntos, 4 de ellos para ajustar el modelo y 1 para validar.

La búsqueda en cuadrícula (*Grid-Search*) realizada en este sección implica ajustar más de 25,000 modelos diferentes. El número 25,000 resulta de la combinación de modelos, hiperparámetros y estaciones.

3.5.1.5. Evaluación de los modelos

Como se comentó previamente, se ha simulado la ocurrencia y la intensidad de la lluvia de manera independiente. Los modelos definidos como clasificadores (C), en la Tabla 3.2,

son utilizados para reconstruir la serie temporal completa de ocurrencia de lluvia para las 17 estaciones por separado. Para ello, antes de entrenar los modelos, se han transformado las series temporales de precipitación en series binarias (0 = NoLluve, 1 = Llueve). La función *f-score* (eq. 3.1) será utilizada como función de pérdida o función objetivo para evaluar los diferentes clasificadores. Los modelos definidos como regresores (R) en la Tabla 3.2, serán entrenados utilizando únicamente aquellos días con una intensidad de lluvia superior a 0.1 mm. En este caso la función de pérdida utilizada será la métrica RMSE (ver eq. 3.4). En ambos casos lo modelos se ajustarán utilizando como predictores las 14 primeras componentes principales, que explican el 95 % de la varianza de nuestros datos, y la estacionalidad (funciones seno y coseno).

3.5.2. Resultados

3.5.3. Selección del mejor modelo

La Figura 3.21 muestra la variación en el rendimiento de los modelos según la combinación de hiperparámetros seleccionada durante la validación cruzada. Todas las combinaciones de hiperparámetros que aparecen en la Tabla 3.2 fueron utilizadas en el presente análisis. Las funciones seno y coseno, que informan sobre la no estacionariedad en la precipitación durante los diferentes meses de año, mejoraron la capacidad de los modelos de regresión en todos los casos. Sin embargo, su habilidad predictiva no se vio afectada al introducir el índice climático NAO; lo cual probablemente se deba al hecho de que la variable SLP (en un área muy parecida al que se utiliza para calcular la NAO) captura de por si dicha oscilación. La Figura 3.21 muestra la distribución de resultados para las métricas f-score (panel situado a la izquierda) y R (panel situado a la derecha) durante la validación cruzada para toda la combinación completa de hiperparámetros. Las funciones de densidad no paramétricas calculadas mediante el método Kernel fueron utilizadas para mostrar los resultados. El valor situado más a la derecha, en el eje de las abscisas, corresponde a la combinación de hiperparámetros que ofrece mejor resultado en términos de f-score y R. Dicha combinación será la elegida, más adelante, para evaluar la capacidad predictiva de los modelos en el subconjunto de datos de prueba (test) y para comparar entre sí los diferentes modelos.

Como se puede observar en el panel situado a la izquierda de la Figura 3.21, los modelos LR y SVM muestran distribuciones con una dispersión significativamente inferior al resto de los modelos, lo que significa que son menos sensibles a la combinación de hiperparámetros seleccionada. Lo contrario sucede con los modelos WT, RF, k-NN y NN; especialmente con el método NN, ya que su rendimiento varía considerablemente dependiendo del conjunto de hiperparámetros utilizado. Todos los modelos muestran distribuciones con una alta variabilidad a la hora de predecir la intensidad de la lluvia (panel situado a la derecha de la Figura 3.21).

También podemos observar que algunas funciones de densidad de Kernel, como aquellas obtenidas para los modelos NN, k-NN, RF y SVM, presentan un comportamiento bimodal. En estos casos, la moda situada más a la izquierda en el eje de las abscisas, representa un mínimo local que correspondería a combinaciones de parámetros con menor capacidad predictiva. Con el objetivo de encontrar la mejor combinación de hiperparámetros y minimizar el coste computacional, sería recomendable comenzar realizando una primera búsqueda, un tanto grosera, en torno a un rango muy amplio de búsqueda, para luego efectuar una búsqueda, más detallada, alrededor de aquellos hiperparámetros que ofrecieron mejores resultados.



Figura 3.21: Distribución de resultados para las métricas f-score (panel situado a la izquierda) y R (panel situado a la derecha) durante la validación cruzada para toda la combinación completa de hiperparámetros. Cada columna corresponde a un méto-do diferente y cada fila corresponde a una de las 17 estaciones. Los histogramas y las funciones de densidad, representadas mediante el método Kernel, representan los resultados de f-score (panel de la izquierda) y R (panel de la derecha) para todos los clasificador y regresores, respectivamente. El eje X, de las abscisas, tiene un rango de 0 a 1. La línea discontinua vertical corresponde al valor de 0.5. Fuente: Figura incluida en un artículo en revisión enviado a la revista Journal of Hydrology Diez-Sierra y del Jesus 2019.

Podemos observar también que la combinación de hiperparámetros ganadora es diferente para cada estación (ver Tabla 3.3 y Tabla 3.4) a excepción del método WT, donde el mismo número de clústeres es seleccionado a partir del criterio Dunn Index (Baarsch y Celebi, 2012).

TABLA 3.3: Hiperparámetros óptimos para la ocurrencia de la lluvia. Fuente: Tabla adaptada a partir del artículo en revisión enviado a la revista *Journal of Hydrology* Diez-Sierra y del Jesus 2019.

	Hiperparámetros					ID				
		1940	2081	2110	2112	2115	2135	2173	2204	2241
	solver	liblinear	liblinear	sag	liblinear	sag	sag	newton-cg	sag	sag
LR	penalty	l1	l1	12	l1	12	12	12	12	12
	С	1	1	1	1	1	25	10	10	10
BF	n_estimators	60	200	2	10	5	40	100	5	5
111	min_samples_leaf	1	2	10	4	6	2	2	4	1
k-NN	n_neighbors	5	7	1	3	3	4	7	5	5
K-111	weights	distance	distance	uniform	uniform	uniform	distance	uniform	uniform	uniform
	С	0.1	1	5	1	1	1	1	1	5
SVM	kernel	rbf	rbf	rbf	rbf	rbf	rbf	rbf	rbf	rbf
	γ	0.025	0.025	0.005	0.025	0.01	0.01	0.025	0.01	0.005
WT	n_clusters	81	81	81	81	81	81	81	81	81
	solver	adam	lbfgs	lbfgs	lbfgs	sgd	adam	lbfgs	lbfgs	lbfgs
	alpha	0.0001	0.0001	0.0001	0.1	0.0001	0.1	10	0.1	0.1
NN	hidden_layer_sizes	(10,1)	(5,1)	(7,1)	(10,1)	(2,1)	(6,1)	(10,1)	(10,1)	(10,1)
	activation	relu	relu	relu	logistic	tanh	relu	tanh	relu	relu
	max_iter	200	200	200	200	200	200	200	200	200

TABLA 3.3: Hiperparámetros óptimos para la ocurrencia de la lluvia. (Continuación).

	Hiperparámetros				I	D			
		2249	2015	2050	2118	1976	1989	2010	2061
	solver	sag	sag	lbfgs	sag	liblinear	sag	sag	sag
LR	penalty	12	12	12	12	l1	12	12	12
	С	1000	1	75	1	1	0.1	1	0.1
BF	n_estimators	200	5	1	200	5	5	5	1
ILF	min_samples_leaf	1	1	1	2	1	1	4	4
k-NN	n_neighbors	3	1	3	8	3	1	3	1
K-I I I	weights	uniform	uniform	uniform	distance	uniform	uniform	uniform	uniform
	С	2	1	2	5	1	1	1	1
SVM	kernel	rbf	rbf	rbf	rbf	rbf	rbf	rbf	rbf
	γ	0.025	0.05	0.005	0.005	0.05	0.05	0.05	0.05
WT	n_clusters	81	81	81	81	81	81	81	81
	solver	lbfgs	lbfgs	adam	lbfgs	lbfgs	lbfgs	lbfgs	lbfgs
	alpha	0.001	0.1	0.0001	10	0.001	0.0001	0.0001	0.1
NN	hidden_layer_sizes	(10,1)	(7,1)	(10,1)	(3,1)	(10,1)	(10,1)	(10,1)	(7,1)
	activation	relu	tanh	tanh	tanh	relu	relu	relu	tanh
	max_iter	200	200	200	200	200	200	200	200

Las Tablas 3.3 y 3.4 muestran que los hiperparámetros seleccionados como óptimos, mediante la búsqueda en cuadrícula, varían enormemente en función de la estación seleccionada, sin embargo, podemos sacar algunas conclusiones de estos resultados. Si observamos, por ejemplo, el valor del hiperparámetro de regularización (C) seleccionado como óptimo para el método LR, vemos que muestra una dispersión muy grande entre estaciones. Sin embargo, en la Figura 3.21 nos damos cuenta que en realidad C no tiene ningún efecto en los resultados. También encontramos que el modelo RF requiere un mayor número de árboles ($N_{-}estimadores$) y un número mínimo mayor de muestras en

	Hiperparámetros					ID				
		1940	2081	2110	2112	2115	2135	2173	2204	2241
BE	n_estimators	200	200	100	200	80	40	100	60	100
ILL	min_samples_leaf	30	15	30	10	15	6	15	10	15
k-NN	n_neighbors	40	15	40	15	30	30	50	25	40
K-1111	weights	uniform	distance							
	C	50	75	25	25	75	25	25	50	25
SVM	kernel	rbf	rbf	rbf	rbf	rbf	rbf	rbf	rbf	rbf
5 1 11	γ	0.01	0.025	0.025	0.025	0.075	0.1	0.01	0.025	0.05
	e	5	20	5	5	5	5	5	5	5
WT	n_clusters	81	81	81	81	81	81	81	81	81
	solver	sgd	adam	lbfgs	sgd	adam	sgd	sgd	sgd	adam
	alpha	10	10	1000	0.1	10	10	10	10	0.001
NN	hidden_layer_sizes	(15,1)	(20,1)	(9,1)	(3,2)	(7,1)	(10,1)	(8,1)	(5,1)	(20,1)
	activation	relu	relu	relu	logistic	logistic	identity	relu	relu	logistic
	max_iter	2000	2000	2000	2000	2000	2000	2000	2000	2000

TABLA 3.4: Hiperparámetros óptimos para la intensidad de la lluvia. Fuente: Tabla adaptada a partir del artículo en revisión enviado a la revista *Journal of Hydrology* Diez-Sierra y del Jesus 2019.

TABLA 3.4: Hiperparámetros óptimos para la intensidad de la lluvia. (Continuación).

	Hiperparámetros				I	D			
		2249	2015	2050	2118	1976	1989	2010	2061
BE	n_estimators	200	60	200	60	200	40	5	5
ILF	min_samples_leaf	10	30	30	15	15	15	50	30
L NN	n_neighbors	15	50	20	50	35	45	30	50
K-ININ	weights	distance	distance	distance	distance	uniform	distance	distance	distance
	С	25	10	25	15	15	25	250	15
SVM	kernel	rbf	rbf	rbf	rbf	rbf	rbf	rbf	rbf
SVIVI	γ	0.05	0.05	0.075	0.1	0.05	0.025	0.01	0.05
	ε	5	5	5	5	5	5	5	5
WT	n_clusters	81	81	81	81	81	81	81	81
	solver	adam	lbfgs	adam	lbfgs	lbfgs	sgd	sgd	lbfgs
	alpha	10	1000	10	10	1000	10	10	1000
NN	hidden_layer_sizes	(6,1)	(10,1)	(3,2)	(2,1)	(9,1)	(8,1)	(3,2)	(2,2)
	activation	relu	relu	logistic	logistic	relu	identity	tanh	relu
	max_iter	2000	2000	2000	2000	2000	2000	2000	2000

cada hoja (min_samples_leaf) para predecir la intensidad de la lluvia que la ocurrencia. Esto es esperable ya que un problema de regresión trata con variables continuas que normalmente requieren modelos más complejos que en un problema de clasificación binario, que solo tiene que predecir entre dos categorías (lluvia, no lluvia). Algo parecido sucede con la cantidad de vecinos requeridos (n_neighbors) en el modelo k-NN. Un mayor número de vecinos es requerido para predecir la intensidad de la lluvia que la ocurrencia. En el caso del modelo SVM, lo que buscamos son dos cosas: un hiperplano con el margen mínimo más grande (C), y un hiperplano que separe correctamente la mayor cantidad de datos posible. Para valores elevados del término de regularización C, el modelo elegirá durante su optimización un hiperplano de menor margen, mientras que un C inferior implicaría un margen más grande y una función de decisión más simple. Cherkassky y Ma (2004) sugieren que la elección óptima del hiperparámetro ϵ , que define el margen de tolerancia donde no se aplican penalizaciones a los errores, tiene un efecto insignificante en el rendimiento del modelo siempre y cuando C sea mayor que un cierto umbral. Recomendamos, por lo tanto, definir primero el umbral del parámetro C, y luego ajustar el hiperparámetro ϵ . SVM, en la librería *Scikit-learn* (Pedregosa et al., 2011), presenta un valor predeterminado de ϵ igual a 0.1. No obstante, para reducir el sesgo de los modelos hemos comprobado que deberíamos de aumentar significativamente dicho valor. Normalmente se requieren valores varias órdenes de magnitud mayores de ϵ , especialmente para conjuntos de entrenamiento muy grandes y/o ruidosos (Mattera y Haykin, 1999).

NN usa el parámetro *alpha* como término de regularización que ayuda a evitar al modelo sobreajustarse. Al igual que sucede con el algoritmo SVM, NN en *Scikit-learn*, presenta un valor predeterminado de *alpha* que en este caso es igual a 0.0001. Del mismo modo, hemos encontrado que el hiperparámetro *alpha* debería de tomar valores varios órdenes de magnitud para evitar el sobreajuste de modelo NN en algunas de las estaciones. El hiperparámetro *Hidden_layer_sizes*, para el modelo NN, define el número de neuronas y capas utilizadas. Los resultados de la Tabla 3.4 muestran que únicamente 2 estaciones requieren más de 1 capa (*hidden layer*) mientras que el número de neuronas puede variar entre 2 y 20. Los valores dentro de los paréntesis (ver Tablas 3.3 y 3.4), corresponden al número de neuronas y capas, respectivamente. Por último, las funciones de activación introducen relaciones no lineales en los modelos NN. Las funciones no lineales: *Relu* [f(x) = max(0, x)] y tahn [f(x) = tanh(x)] han sido seleccionadas para la mayoría de las estaciones. La función de activación *Identity*, que establece relaciones lineales, solo ha sido seleccionado como óptima en 2 ocasiones; lo que tiene sentido debido a la no linealidad de las series de precipitación a una agregación temporal diaria.

Las Tablas 3.5 y 3.6 muestran la habilidad predictiva de los modelos durante el subconjunto de entrenamiento (*train*) y de prueba (*test*), respectivamente. Los resultados han sido promediados para todas las estaciones. Como podemos observar, la mayoría de los modelos presentan mejores resultados en el subconjunto de validación que en el de prueba. Estas diferencias son mayores para los modelos RF y k-NN.

Como comentamos previamente, la validación cruzada sirve, entre otras cosas, para evitar el sobreajuste de los modos. Sin embargo, al comparar su habilidad durante el subconjunto de datos de entrenamiento y de prueba, nos damos cuenta de que algunos métodos, como por ejemplo RF y k-NN, resultan en modelos sobreajustados. Este comportamiento puede explicarse por las siguientes razones. En el caso de k-NN, la explicación radica en el hecho de que el número óptimo de vecinos seleccionados para la predicción es igual a 1 para algunas de las estaciones. Para estas estaciones el modelo k-NN selecciona durante su entrenamiento el valor de precipitación asociado al patrón sinóptico atmosférico más similar para cada predicción, logrando una predicción perfecta. Algo similar ocurre con RF y el hiperparámetro *min_samples_leaf*. Cuando el valor seleccionado en la validación cruzada es demasiado pequeño, RF predice valores muy similares a los observados durante el entrenamiento. Por lo tanto, si queremos evitar este comportamiento (sobreajuste), deberíamos tomar valores más altos para los hiperparámetros $n_{estimators}$ y min_samples_leaf, en el caso de RF, y $n_{neighbors}$ en el caso de k-NN, incluso cuando la habilidad de los modelos se viese degradada.

La alta variabilidad en los resultados mostrados en la Figura 3.21, demuestra que es esencial calibrar los hiperparámetros antes de cualquier aplicación.

TABLA 3.5: Valor de f-score promediado para las 17 estaciones sobre el subconjunto de entrenamiento (train) y prueba (test). Fuente: Tabla incluida en un artículo en revisión enviado a la revista Journal of Hydrology Diez-Sierra y del Jesus 2019.

	f-score											
	LR NN RF			F	k-N	IN	SV	\mathbf{M}	WT			
train	test	train	test	train	test	train	test	train	test	train	test	
0.38	0.37	0.42	0.39	0.63	0.33	0.8	0.32	0.40	0.36	0.27	0.26	

TABLA 3.6: Valor de R promediado para las 17 estaciones sobre el subconjunto de entrenamiento (train) y prueba (test). Fuente: Tabla incluida en un artículo en revisión enviado a la revista Journal of Hydrology Diez-Sierra y del Jesus 2019.

						Ь	ł						
GLN	M-L	L GLM-G		N	NN RI		F k-NN		IN	\mathbf{SVM}		WT	
train	test	train	test	train	test	train	test	train	test	train	test	train	test
0.40	0.29	0.37	0.32	0.41	0.37	0.60	0.33	0.93	0.34	0.39	0.35	0.18	0.18

3.5.4. Predicción de la ocurrencia de la precipitación

La Tabla 3.7 muestra el valor de *f*-score para todos los clasificadores y para todas las estaciones a una resolución diaria. El modelo NN, con una valor promedio de *f*-score cercano a 0.4, ofrece los mejores resultados seguido de cerca por los modelos LR y SVM. Los modelos RF y k-NN muestran valores de *f*-score algo menores, mientras que el método basado en WT muestra los peores resultados muy por debajo del resto de los modelos. También podemos apreciar que los resultados para la ocurrencia de lluvia son significativamente mejores en aquellas estaciones ubicadas en el norte de Tenerife que en el sur (ver Tabla 3.1). Esto se debe probablemente a que los modelos capturan mejor las precipitaciones de origen frontal, que dominan en el norte de la isla, que los procesos convectivos, que prevalecen en el sur. El rendimiento del modelo NN es superior en la mayoría de las estaciones excepto en la estación 2115, donde el modelo SVM presenta resultados ligeramente mejores.

Para verificar estadísticamente que NN es el mejor de los clasificadores hemos llevado a cabo un análisis de significancia basado en la prueba t de Student o Test-T. Hemos realizado múltiples Test-T para verificar qué modelos presentaban diferencias significativas entre ellos con un nivel de significación del 95%. El método de corrección de

	LR	NN	RF	k-NN	SVM	WT
1940	0.46	0.48	0.39	0.39	0.47	0.33
1976	0.29	0.33	0.25	0.24	0.23	0.18
1989	0.28	0.31	0.23	0.23	0.21	0.19
2010	0.32	0.36	0.26	0.28	0.27	0.22
2015	0.39	0.43	0.35	0.36	0.38	0.25
2050	0.29	0.32	0.28	0.25	0.29	0.2
2061	0.21	0.24	0.22	0.16	0.17	0.12
2081	0.51	0.54	0.47	0.46	0.53	0.41
2110	0.31	0.32	0.28	0.28	0.31	0.23
2112	0.35	0.39	0.32	0.31	0.38	0.26
2115	0.42	0.38	0.37	0.36	0.43	0.32
2118	0.47	0.49	0.41	0.41	0.48	0.32
2135	0.39	0.4	0.33	0.32	0.39	0.28
2173	0.46	0.49	0.42	0.41	0.48	0.36
2204	0.39	0.42	0.33	0.33	0.39	0.27
2241	0.36	0.38	0.32	0.29	0.37	0.27
2249	0.38	0.42	0.34	0.33	0.39	0.28
Mean	0.37	0.39	0.33	0.32	0.36	0.26

TABLA 3.7: Resultado de *f-score* para todos los clasificadores y estaciones a una agregación temporal diaria. Fuente: Tabla incluida en un artículo en revisión enviado a la revista *Journal of Hydrology* Diez-Sierra y del Jesus 2019.

TABLA 3.8: Resultados de las pruebas t de Student para predecir la ocurrencia de lluvia sobre la métrica *f-score*. La letra S indica que existe una diferencia significativa entre los resultados de ambos modelos, mientras que la letra N indica que no existe una diferencia significativa. Fuente: Tabla incluida en un artículo en revisión enviado a la revista *Journal of Hydrology* Diez-Sierra y del Jesus 2019.

	KNN	\mathbf{LR}	NN	\mathbf{RF}	SVM
LR	S	-	-	-	-
NN	S	S	-	-	-
RF	N	S	S	-	-
SVM	S	Ν	S	S	-
WT	S	S	S	S	S

Holm (Holm, 1979) ha sido utilizado para lidiar con el problema de la multiplicidad⁸. De esta manera se ha llevado a cabo una prueba t de Student para cada par de combinaciones de modelos sobre la métrica *f-score*. La Tabla 3.8 indica aquellos modelos que presentan una diferencia significativa al realizar la prueba t de Student. Se puede observar que NN presenta resultados significativamente mejores que los otros modelos, lo que nos permite concluir que es el mejor método para predecir la ocurrencia de la lluvia. LR y SVM ocuparon el segundo puesto con resultados significativamente mejores que los modelos RF, k-NN y WT.

También se ha analizado el rendimiento de los modelos para predecir la ocurrencia de la lluvia por encima de diferentes umbrales de intensidad de precipitación: 0.1, 5, 20 y 40 mm/día. Mediante la métrica exhaustividad hemos comparado la habilidad de

 $^{^8 \}rm El$ problema de multiplicidad surge cuando un número elevado de hipótesis son contrastadas simultáneamente. Lo que hace que se incremente la posibilidad de que se den falsos positivos.

TABLA 3.9: Valor promediado de exhaustividad para las 17 estaciones y para los umbrales de intensidad de precipitación de 0.1, 5, 20 y 40 mm/día. Fuente: Tabla adaptada a partir del artículo en revisión enviado a la revista *Journal of Hydrology* Diez-Sierra y del Jesus 2019.

	1	Umbral (mm/día)										
	0.1	5	10	20	40							
LR	0.37	0.47	0.51	0.56	0.59							
NN	0.39	0.51	0.54	0.57	0.63							
\mathbf{RF}	0.34	0.41	0.45	0.48	0.51							
k-NN	0.30	0.39	0.43	0.46	0.46							
SVM	0.36	0.45	0.49	0.50	0.53							
WT	0.26	0.31	0.34	0.34	0.36							

los modelos para predecir cuantos de los días lluviosos reales fueron simulados como días lluviosos para los umbrales seleccionados. La exhaustividad tiene la ventaja de no involucrar los falsos positivos (errores de tipo I) en el análisis. La Tabla 3.9 muestra el valor promediado de exhaustividad para las 17 estaciones y para los diferentes umbrales seleccionados. Como vemos el valor del exhaustividad es mayor a medida que aumenta el valor del umbral, alcanzando 0.63 para el clasificador NN y para el umbral de 40 mm/día. El incremento del valor de exhaustividad a medida que aumenta el umbral, indica que los eventos de lluvia más intensos son más fáciles de predecir ya que dependen de situaciones sinópticas atmosféricas más claras.

La persistencia de la precipitación es otra característica muy importante y que está relacionada con la ocurrencia de la lluvia. Se suele medir mediante lo que se conoce como probabilidades de transición, que indican la probabilidad de tener un intervalo seco precedido de otro intervalo seco (ϕ^{DD}) o de tener un intervalo húmedo precedido de otro intervalo seco (ϕ^{DD}) o de tener un intervalo húmedo precedido de otro intervalo seco (ϕ^{DD}) o de tener un intervalo húmedo precedido de otro intervalo seco (ϕ^{DD}) o de tener un intervalo húmedo precedido de otro intervalo seco (ϕ^{DD}) o de tener un intervalo húmedo precedido de otro intervalo húmedo (ϕ^{WW}). La Tabla 3.10 muestra que, en general, todos los métodos son capaces de conservar los valores observados de ϕ^{DD} con errores muy pequeños. Sin embargo, no sucede los mismo en el caso de ϕ^{WW} ; algunos modelos presentan diferencias significativas entre los valores observados y simulados, como sucede con los métodos WT, k-NN y RF. Los modelos NN, LR y SVM, nuevamente presentan los mejores resultados promediados, sin embargo, subestiman ligeramente también los valores observados de ϕ^{WW} . NN presenta el error más pequeño para ϕ^{WW} , lo que se debe principalmente a su mejor capacidad para predecir la ocurrencia de la lluvia (*f-score*).

Hemos encontrado también resultados muy interesantes al analizar la habilidad de los clasificadores para predecir el número de días de lluvia por mes y por año. La Figura 3.22 muestra un gráfico de dispersión entre el número de días de lluvia al mes para las series observadas y simuladas, para cada uno de los clasificadores y para todas las estaciones al mismo tiempo. Como podemos observar, NN, LR y SVM presentan valores más elevados de R, alcanzando un valor promediado para todas las estaciones de 0.83. Los modelos RF

	0	bs	L	'R	N	N	F	εF	k -1	NN	S	/M	W	ν T
	ϕ^{DD}	ϕ^{WW}	ϕ^{DD}	ϕ^{WW}	ϕ_{DD}	ϕ^{WW}	ϕ^{DD}	ϕ^{WW}	ϕ^{DD}	ϕ^{WW}	ϕ^{DD}	ϕ^{WW}	ϕ^{DD}	ϕ^{WW}
1940	85.8	51.5	85.8	41.9	85.5	44.8	85.1	33.1	88.0	33.4	85.8	42.9	86.1	28.9
1976	94.6	31.9	94.5	25.2	94.5	29.8	94.0	19.9	95.2	20.8	94.4	19.3	94.7	14.7
1989	95.7	34.3	95.7	24.7	95.8	28.1	95.2	20.6	96.3	24.2	95.7	16.6	95.7	15.9
2010	93.5	39.3	93.4	29.4	93.4	31.5	93.0	22.7	94.4	22.2	93.4	23.3	94.0	19.1
2015	88.3	51.4	88.4	35.8	88.3	38.7	87.5	30.2	89.9	34.5	88.2	34.0	88.9	21.7
2050	90.7	39.8	90.6	27.3	90.7	28.3	90.1	30.9	92.1	23.9	90.6	26.2	90.9	18.4
2061	95.3	32.4	95.3	19.3	95.4	24.6	95.0	21.9	95.8	21.7	95.2	15.1	95.1	11.1
2081	73.3	58.1	73.3	47.2	73.3	49.7	72.7	41.5	75.3	41.0	73.4	49.0	75.4	37.3
2110	86.9	37.1	87.0	29.3	86.9	30.9	86.4	26.7	87.6	31.7	86.8	29.5	87.1	20.3
2112	86.2	42.1	86.1	32.5	86.1	36.3	85.5	28.5	87.5	28.9	86.0	33.8	86.2	23.6
2115	80.4	48.3	80.2	39.0	80.5	33.9	79.8	33.9	81.0	35.5	80.1	40.1	81.0	29.1
2118	84.0	52.7	84.0	43.0	83.8	43.4	83.2	35.0	86.3	33.5	83.9	43.9	86.4	27.4
2135	84.5	44.7	84.5	35.4	84.2	36.9	83.7	29.5	85.7	31.3	84.3	36.3	84.8	25.8
2173	76.8	53.0	76.6	42.1	76.8	45.0	75.8	37.3	78.2	35.7	76.7	43.9	77.1	33.2
2204	86.6	45.4	86.5	35.6	86.3	39.3	85.9	30.4	87.6	29.2	86.5	35.6	86.6	25.4
2241	83.8	41.5	84.0	32.5	83.7	35.0	82.2	31.1	85.3	26.9	83.6	33.5	83.9	25.8
2249	85.7	42.0	85.7	34.7	85.8	37.2	84.6	29.4	87.7	29.2	86.0	33.2	85.7	25.6
Error	0.0	0.0	0.1	10.0	0.1	7.8	0.7	14.3	1.3	14.2	0.1	11.1	0.5	20.1

TABLA 3.10: Probabilidades de transición observadas y simuladas (ϕ^{DD} y ϕ^{WW}) para todos los clasificadores y estaciones analizadas. Fuente: Tabla incluida en un artículo en revisión enviado a la revista *Journal of Hydrology* Diez-Sierra y del Jesus 2019.

y k-NN muestran resultados ligeramente inferiores, mientras que WT presenta el peor de los resultados con un valor de R igual a 0.65. NN, LR y SVM son los únicos métodos capaces de simular meses con más de 20 días de lluvia, lo que es excepcionalmente raro en Tenerife. Además, estos métodos muestran distribuciones menos sesgadas y con formas más similares a las observadas.

De manera similar, la Figura 3.23 muestra el gráfico de dispersión entre el número de días de lluvia al año para las series observadas y simuladas y para todas las estaciones al mismo tiempo. Como podemos observar, la capacidad predictiva de los modelos mejora cuando los resultados son evaluados a una agregación temporal anual. Todos los modelos, excepto WT, presentan valores de R superiores a 0.9. En general la mayoría de los modelos son capaces de predecir adecuadamente los extremos de la distribución, que corresponden a años con más de 100 días de lluvia o menos de 20. Los resultados mostrados en las Figuras 3.22 y 3.23 son especialmente buenos teniendo en cuenta que el número de días de lluvia al mes o al año puede variar enormemente en Tenerife dependiendo de la fecha y estación analizada. Como es de esperar, la técnica WT de aprendizaje no supervisado⁹, así como la técnica k-NN (que a excepción del parámetro asociado al número de vecinos no implica ningún tipo de entrenamiento) son las técnicas que presentan peores resultados.

⁹El aprendizaje no supervisado tiene lugar cuando no se dispone de datos "etiquetados" para el entrenamiento de los modelos. Sólo se dispone de los datos de entrada (input), pero no existen datos de salida que correspondan a un determinado input. Se basan en encontrar algún tipo de organización que simplifique la estructura de los datos.



Figura 3.22: Distribución de probabilidad conjunta para número de días de lluvia al mes mediante las series observadas y simuladas para los diferentes clasificadores. Cada panel muestra los resultados para las 17 estaciones al mismo tiempo. La línea discontinua indicaría un ajuste perfecto. Fuente: Figura adaptada a partir del artículo en revisión enviado a la revista Journal of Hydrology Diez-Sierra y del Jesus 2019.



Figura 3.23: Distribución de probabilidad conjunta para número de días de lluvia al año mediante las series observadas y simuladas para los diferentes clasificadores. Cada panel muestra los resultados para las 17 estaciones al mismo tiempo. La línea discontinua indicaría un ajuste perfecto. Fuente: Figura adaptada a partir del artículo en revisión enviado a la revista Journal of Hydrology Diez-Sierra y del Jesus 2019.

3.5.5. Predicción de la intensidad de lluvia

La Tabla 3.11 muestra el resultado de las métricas R y RMSE para todos los regresores y para las 17 estaciones. Como podemos observar en la Tabla 3.11, NN presenta el valor más elevado de R (0.37) y el menor valor de RMSE (12.6). Los modelos SVM, k-NN y RF presentan valores ligeramente peores de R y RMSE que NN, mientras que WT ofrece los peores resultados. Los métodos estadísticos (GLM-L y GLM-G), en general, ofrecen resultados inferiores que los métodos de aprendizaje automatizado; a excepción del método WT. Hay que tener en cuenta que WT es el único método de aprendizaje automatizado no supervisado y por lo tanto es normal que presente los peores resultados.

Al igual que en el caso de la predicción de la ocurrencia de la lluvia, y casi por las mismas razones, la mayoría de las estaciones que ofrecen los mejores resultados (valores superiores de R e inferiores de RMSE) se encuentran en el norte de la isla (ID: 2241, 2173, 2081, 2204, 1940). Es interesante observar cómo algunas estaciones separadas por unos pocos kilómetros presentan valores muy diferentes de R, como las estaciones 2173 y 2135. Estas diferencias, sin embargo, podrían explicarse por la diferencia de cota que existe entre ellas (400 m); lo cual podría resultar en regímenes de lluvia completamente distintos.

TABLA 3.11: Valores de R y RMSE obtenidos entre las series observadas y simuladas mediante los modelos de regresión mostrados en la Tabla 3.2 para las 17 estaciones.
Fuente: Tabla incluida en un artículo en revisión enviado a la revista Journal of Hydrology Diez-Sierra y del Jesus 2019.

	GLM-L		GLM-G		NN			RF	k	-NN	S	SVM	WT	
	R	RMSE	R	RMSE	R	RMSE	R	RMSE	R	RMSE	R	RMSE	R	RMSE
1940	0.42	13.6	0.41	14.0	0.46	13.4	0.4	13.7	0.46	13.5	0.42	13.6	0.24	14.9
1976	0.46	24.0	0.5	25.0	0.54	22.1	0.5	22.7	0.5	22.9	0.52	22.5	0.38	24.8
1989	0.22	18.2	0.27	17.8	0.34	17.1	0.33	17.0	0.28	17.3	0.3	17.2	0.16	18.9
2010	0.05	14.2	0.25	11.1	0.3	10.7	0.24	10.9	0.27	10.8	0.27	10.8	0.11	11.5
2015	0.11	21.6	0.28	19.2	0.31	18.7	0.25	19.1	0.27	19.1	0.26	19.1	0.08	20.1
2050	0.19	17.8	0.25	17.5	0.29	16.8	0.24	17.0	0.33	16.6	0.29	16.8	0.17	17.5
2061	0.09	18.5	0.19	15.7	0.19	15.2	0.27	14.9	0.21	15.2	0.2	15.2	0.14	16.9
2081	0.42	9.5	0.39	9.9	0.49	9.1	0.43	9.4	0.45	9.3	0.46	9.2	0.28	10.0
2110	0.24	15.1	0.26	14.9	0.28	14.7	0.26	14.8	0.28	14.8	0.28	14.8	0.11	15.6
2112	0.31	10.1	0.31	10.1	0.36	9.9	0.34	10.0	0.31	10.1	0.33	10.0	0.12	10.8
2115	0.36	9.3	0.37	9.4	0.4	9.1	0.35	9.3	0.38	9.2	0.39	9.2	0.18	9.9
2118	0.2	10.5	0.21	11.6	0.34	10.0	0.29	10.1	0.32	10.1	0.33	10.0	0.15	10.6
2135	0.29	8.6	0.33	8.5	0.34	8.4	0.28	8.6	0.29	8.6	0.33	8.5	0.14	9.0
2173	0.43	8.9	0.41	9.0	0.45	8.8	0.4	9.1	0.41	9.0	0.43	9.0	0.25	9.6
2204	0.33	10.4	0.38	10.1	0.4	9.9	0.34	10.2	0.32	10.3	0.36	10.1	0.16	10.9
2241	0.4	11.7	0.37	11.9	0.44	11.4	0.38	11.7	0.35	11.9	0.42	11.5	0.23	12.4
2249	0.36	9.0	0.33	9.2	0.4	8.8	0.32	9.1	0.35	9.0	0.4	8.9	0.14	9.6
Mean	0.29	13.6	0.32	13.2	0.37	12.6	0.33	12.8	0.34	12.8	0.35	12.7	0.18	13.7

Al igual que en el caso de la ocurrencia de la lluvia, se ha realizado un análisis de significancia para verificar la hipótesis de que el método NN es significativamente mejor que el resto a la hora de predecir la intensidad de la lluvia. Para ello se ha realizado un análisis multivariado de varianza (MANOVA; Muller y Peterson 1984), para muestras dependientes o apareadas, bajo la hipótesis nula de que todos los modelos presentan

	GLM-G	GLM-L	kNN	NN	\mathbf{RF}	SVM
GLML	Ν	-	-	-	-	-
kNN	Ν	Ν	-	-	-	-
NN	S	S	S	-	-	-
RF	Ν	N	N	S	-	-
SVM	S	S	N	S	S	-
WT	S	S	S	S	S	S

TABLA 3.12: Resultados de la prueba t de Student para la métrica RMSE. La letra S indica que hay una diferencia significativa entre los resultados de ambos modelos, mientras que la letra N indica que no. Fuente: Tabla incluida en un artículo en revisión enviado a la revista *Journal of Hydrology* Diez-Sierra y del Jesus 2019.

la misma capacidad predictiva cuando esta es medida bajo las métricas R y RMSE al mismo tiempo. Como resultado del análisis MANOVA, la hipótesis nula fue rechazada con un nivel de significación del 95%, lo que quiere decir que uno de los modelos es significativamente distinto a los demás con una probabilidad del 95%. Una vez rechazada la hipótesis nula se ha seguido el mismo procedimiento que en la sección anterior. Múltiples Test-T fueron realizadas para verificar qué modelos presentaban diferencias significativas entre ellos. Los resultados de las múltiples pruebas t de Student se muestran en la Tabla 3.12. Como podemos observar NN ofrece resultados significativamente mejores que el resto de modelos, lo que nos permite concluir que NN es el modelo que mejor predice la intensidad de lluvia cuando es analizado en torno a las métricas R y RMSE.

Hemos considerado importante evaluar también la habilidad de los diferentes métodos para reproducir algunos estadísticos e índices que normalmente son utilizados para describir el comportamiento estadístico de las series de precipitación. Estos son: la media (μ) , la varianza diaria (σ^2) y los índices R20 (número de días con precipitaciones superiores a 20 mm) y RX1 (máximo valor de precipitación). Como se puede apreciar en la Tabla 3.13, las series simuladas muestran valores de precipitación media muy parecidos a los observados con errores medios absolutos muy cercanos a 0. Los métodos k-NN y SVM son los que presentan un sesgo mayor con un error promedio para todas las estaciones igual a 0.7 mm/día. Los estadísticos σ^2 , R20 y RX1 son ampliamente subestimadas por todos los métodos. El método GLM-G presenta errores más pequeños al predecir los estadísticos σ^2 , R20 y RX1, sin embargo, todavía está muy por debajo de los valores observados. La mayoría de la estaciones presentan valores observados de RX1 por encima de 100 mm/día, sin embargo, únicamente los métodos estadísticos son capaces de alcanzar dicha intensidad en algunas de las estaciones.

TABLA 3.13: Valores observados y simulados para los estadísticos: media diaria (μ), varianza diaria (σ^2), R20 (número de días con precipitaciones superiores a 20 mm) y RX1 (máximo valor de precipitación). Fuente: Tabla incluida en el artículo en revisión enviado a la revista Journal of Hydrology

		RX1	50	78	80	20	35	40	71	33	54	23	32	22	20	20	37	20	25	118
	E	R20	105	251	175	2	56	51	49	9	125	ю	7	9		0	2	12	9	112
	A	σ^2	45.1	244.9	85.2	17.7	31.4	38.5	86.1	14.9	27.4	13.1	12.7	10.7	9.6	12.8	14.4	17.5	9.0	165
		μ	9.6	17.62	15.4	6.1	9.1	9.0	9.2	6.0	11.2	8.6	6.5	4.5	5.6	6.6	7.1	8.8	6.1	0.2
		RX1	36	72	34	13	39	34	33	30	33	27	22	22	19	33	26	40	23	126
	Ν	R20	80	302	67	0	32	40	10	45	45	6		4	0	20	13	53	∞	120
	SV	σ^2	36.5	166.8	20.0	4.3	24.1	24.8	15.4	17.7	17.8	11.7	7.6	12.5	9.1	12.7	14.0	24.3	9.7	181
		μ	8.3	19.1	14.4	6.0	7.6	8.3	9.6	6.3	10.0	8.7	6.9	3.9	5.4	7.1	8.0	8.0	6.6	0.7
		RX1	29	58	30	20	28	35	22	30	29	24	21	16	18	21	21	24	24	131
	Z	R20	59	203	80		21	35	4	27	38	19	7	0	0	с С	4	17	9	120
	k.	σ^2	23.9	99.0	21.2	9.3	14.3	24.3	9.6	17.0	15.7	13.0	10.3	7.1	6.5	10.9	10.0	14.7	11.5	187
		π	8.4	16.0	14.9	6.2	8.0	7.6	8.4	5.3	10.3	8.3	6.2	3.9	5.5	6.1	6.8	8.1	5.7	0.7
		RX1	32	65	37	15	34	28	22	28	30	23	24	21	25	27	24	34	20	129
19.	\mathbf{RF}	R20	$\frac{98}{2}$	1236	101	0	89	44	33	57	103	18	20		ъ	28	15	89		100
s 20		σ^{5}	34.3	154.4	35.8	9.3	30.9	25.8	23.5	19.6	21.5	14.0	15.8	11.7	10.9	16.9	15.3	25.1	11.5	178
Jesu		μ	9.6	17.0	14.7	6.0	9.7	8.9	9.3	6.1	11.2	8.7	6.7	4.5	6.0	6.7	7.3	9.0	6.2	0.1
' del		RX1	52	68	46	15	51	21	23	33	36	19	18	17	19	30	32	34	26	125
rra y	z	R20	184	245	167	0	97	51	5	98	81	0	0	0	0	68	34	140	20	91
z-Sie	Z	σ^2	65.3	197.5	64.5	17.3	43.5	26.9	12.3	30.3	20.9	16.5	15.1	17.3	9.1	24.2	23.4	38.9	19.1	168
Diez		π	9.8	16.9	16.1	5.9	9.4	9.0	9.3	6.0	11.2	8.6	6.6	4.5	5.7	6.7	7.3	9.2	6.0	0.2
		RX1	97	240	75	54	97	85	66	103	63	44	56	126	35	51	43	56	41	86
	Ч-G	R20	137	193	106	16	97	85	32	127	121	47	63	58	27	87	36	123	49	67
	GLI	σ^{2}	81.3	556.4	83.7	24.6	76.6	76.1	50.0	47.1	35.6	17.9	28.9	56.0	15.8	26.0	23.6	41.2	23.6	131
		μ	9.9	18.6	14.9	6.1	9.5	9.1	9.5	6.2	11.3	8.6	6.8	5.0	5.9	6.7	7.3	9.0	6.2	0.2
		RX1	85	166	100	150	199	69	173	57	85	35	39	40	30	39	80	58	30	80
	Ч-Г	R20	536	395	388	84	280	300	109	427	772	478	277	123	159	471	226	583	212	195
	GLI	σ^2	48.1	315.1	80.4	83.8	120.4	61.7	133.7	23.3	40.2	15.7	18.9	13.0	13.9	22.5	28.0	36.7	15.4	143
		μ	9.7	17.0;	14.6	4.6	6.7	8.1	8.6	6.1	11.0	8.6	6.7	4.5	5.8	6.6	6.7	8.8 8	5.9	0.4
		RX1	130	182	130	136	337	194	130	134	216	145	97	232	126	104	155	130	105	0.0
	sc	R20	220	169	126	44	168	148	54	228	203	164	133	87	72	222	106	225	136	0
	lo	σ^2	224.6	385.1	324.1	125.9	388.0	306.6	240.0	107.8	235.7	112.2	98.7	111.6	80.0	97.6	117.4	160.1	92.1	0.0
		μ	9.6 2	17.16	14.75	5.9]	9.5 5	9.0 5	9.2 2	6.0 1	11.2^{5}	8.6 1	6.7	4.5]	5.8	6.6	7.3 1	8.9 1	6.1	0.0
			1940	1976	1989	2010	2015	2050	2061	2081	2110	2112	2115	2118	2135	2173	2204	2241	2249	Error

Los resultados obtenidos para los estadísticos σ^2 , R20 y RX1 (mostrados en la Tabla 3.13) ponen de manifiesto que todos los métodos subestiman ampliamente la intensidad de los valores más extremos de las distribuciones observadas. Este efecto se puede apreciar más claramente cuando las series de precipitación son separadas en dos regímenes, uno para valores inferiores a 20 mm/día y otro para valores superiores. En la Figura 3.24 se compara la distribución observada y simulada para los valores de intensidad de lluvia por debajo de 20 mm/día. Los hexágonos con mayor número de datos presentan colores más intensos. Las gráficas de densidad 2D nos permiten apreciar que los hexágonos con el mayor número de datos se encuentran desplazados de la bisectriz para la mayoría de los modelos. Se puede apreciar también en la Figura 3.24 que las formas que siguen las distribuciones observadas están sesgadas positivamente con un menor número de datos para intensidades más altas. La moda, o valor que aparece con más frecuencia, se encuentra cercano a un valor de 0.1 mm/día en las series observadas. En el caso de las series simuladas, únicamente las formas de las distribución simuladas por los modelos NN y SVM parecen imitar a las observadas con valores de moda que se parecen más a los observados. En el resto de los modelos, el valor de la moda se sitúa entre los 2.5 mm/día y los 5 mm/día.

En la Figura 3.25 se hace una comparativa de la distribución de lluvia observada y simulada para intensidades superiores a 20 mm/día. La superficie sombreada en color rojo muestra los valores que no están representados en los histogramas por tener estos una intensidad inferior a 20 mm/día. En la Figura 3.25 se puede observar que los eventos más extremos de precipitación son subestimados por la mayoría de los modelos. Únicamente los métodos estadísticos (GLM-L y GLM-G) son capaces de simular valores superiores a 100 mm/día. Sin embargo, como vimos en la Tabla 3.13 no son capaces de conservar satisfactoriamente los índices RX1 y R20.

Del mismo modo que en el apartado anterior (3.5.4), cuando analizamos las series a agregaciones temporales por encima del día los resultados predichos de intensidad de lluvia mejoran significativamente. La Figura 3.26 muestra la habilidad de los modelos para simular las series de lluvia observadas a una agregación mensual. Todos los modelos, excepto WT, presentan valores de R muy cercanos a 0.8. Sin embargo, NN una vez más presenta los mejores resultados. Los métodos estadísticos (GLM-G y GLM-L) son los únicos métodos capaces de simular meses con intensidades acumuladas de lluvia por encima de 500 mm. También podemos observar que las formas de las distribuciones simuladas reproducen adecuadamente las observadas, con un valor de moda ubicado en torno a 50 mm/mes y con muy pocos valores simulados por encima de 500 mm/mes.

Cuando las series son agregadas a una resolución temporal anual es muy difícil sacar conclusiones sobre que métodos son los mejores. La Figura 3.27 muestra la habilidad de los diferentes modelos para simular la precipitación acumulada anual para todas las estaciones. Todos los métodos muestran valores de R muy cercanos a 0.8. El método k-NN, y sobre todo el método SVM, subestiman los años con más intensidad de lluvia. Las técnicas de aprendizaje automatizado combinadas (*ensemble*) como RF, k-NN y WT rara vez simulan años con valores de precipitación acumulada superiores a los 800 mm al año.



Figura 3.24: Distribución de probabilidad conjunta de la intensidad de lluvia observada y simulada (prcp≤20mm/día) para todos los regresores. Cada panel muestra los resultados para las 17 estaciones al mismo tiempo. Los hexágonos con mayor número de datos presentan colores más intensos. Fuente: Figura adaptada a partir del artículo en revisión enviado a la revista Journal of Hydrology Diez-Sierra y del Jesus 2019.

Es importante tener en cuenta que ninguno de los regresores utilizados durante los diferentes análisis realizados en la presente sección (3.5) tiene en cuenta la ubicación de las estaciones; ya que los modelos se ajustan de manera independiente para cada estación. Es por eso que hemos querido verificar si los predictores atmosféricos son capaces de informar a los modelos de la estructura espacial de la precipitación. Para ello se ha



Figura 3.25: Distribución de probabilidad conjunta de la intensidad de lluvia observada y simulada (prcp>20mm/día) para todos los regresores. Cada panel muestra los resultados para las 17 estaciones al mismo tiempo. La superficie sombreada en rojo muestra los valores que no están representados en los histogramas al ser estos inferiores a 20 mm/día. Fuente: Figura adaptada a partir del artículo en revisión enviado a la revista Journal of Hydrology Diez-Sierra y del Jesus 2019.

comparado la correlación espacial simulada con la observada. Los paneles situados en la parte superior de la Figura 3.28 muestran la correlación espacial observada a una agregación diaria, mensual y anual, respectivamente. Los paneles situados en la parte inferior de la Figura 3.28 muestran el ratio entre la correlación espacial simulada y observada. De izquierda a derecha cada columna corresponde a una agregación diaria, mensual y anual, respectivamente. Como se puede observar, la correlación espacial observada muestra, generalmente, curvaturas algo más pronunciada a una agregación temporal diaria y anual que a una mensual. A excepción del modelo WT, la mayoría de los modelos subestiman ligeramente los valores de correlación espacial a distancias superiores a los 10 km para una resolución diaria. Todos los modelos muestran resultados satisfactorios



Figura 3.26: Distribución de probabilidad conjunta de la intensidad de lluvia acumulada mensual para las series observadas y simuladas por los diferentes regresores. Cada panel muestra los resultados para las 17 estaciones al mismo tiempo. La línea discontinua indicaría un ajuste perfecto. Fuente: Figura adaptada a partir del artículo en revisión enviado a la revista Journal of Hydrology Diez-Sierra y del Jesus 2019.

a una agregación temporal mensual. Los métodos SVM, k-NN y RF simulan series con valores de correlación espacial más elevados que los observados a una resolución anual; lo que se podría explicar porque son métodos que muestran distribuciones con menos variación que las observadas a dicha resolución temporal (ver la Figura 3.27). Únicamente el método WT es capaz de preservar la correlación espacial observada para todas las agregaciones temporales; lo cual es esperable ya que es el único método en el que las predicciones se realizan para todas las estaciones al mismo tiempo. Las diferencias entre los resultados observados y simulados para el resto de los métodos se deben principalmente a dos motivos: (1) que la correlación por pares no está considerada explícitamente durante los análisis y (2) que durante el proceso de reconstrucción de las series de precipitación existe cierta aleatoriedad asociada a la probabilidad de ocurrencia de lluvia en un día determinado.



Figura 3.27: Distribución de probabilidad conjunta de la intensidad de lluvia acumulada anual para las series observadas y simuladas por los diferentes regresores. Cada panel muestra los resultados para las 17 estaciones al mismo tiempo. La línea discontinua indicaría un ajuste perfecto. Fuente: Figura adaptada a partir del artículo en revisión enviado a la revista Journal of Hydrology Diez-Sierra y del Jesus 2019.

Por último y como ejemplo de la capacidad del modelo NN para predecir la precipitación en la isla de Tenerife, hemos reconstruido la precipitación para las 17 estaciones a una agregación diaria para el periodo 1979-2015. La Figura 3.29 muestra la precipitación promediada para las 17 estaciones simuladas y observadas a una agregación temporal diaria, mensual y anual, respectivamente. Se muestra un periodo de tiempo más corto, para una agregación diaria y mensual, para apreciar mejor los resultados. Como la probabilidad está inmersa en el proceso de simulación de la ocurrencia de la precipitación se han llevado a cabo 100 simulaciones, la banda de color rojo representa el área comprendida bajo el cuantil del 5 % y del 95 % para el conjunto de simulaciones. Al comparar los resultados de las 17 estaciones al mismo tiempo los resultados mejoran significativamente que cuando son analizadas de manera individual (R=0.61), ya que al agregar los valores de precipitación para toda la isla estos se suavizan, y por lo tanto es más fácil su predicción.



Figura 3.28: Los paneles localizados en la parte superior muestran la correlación espacial observada para todos los regresores y para las 17 estaciones. Los paneles localizados en la parte inferior muestran el ratio en la correlación espacial entre las series simuladas y observadas. De izquierda a derecha cada columna corresponde a una agregación diaria, mensual y anual, respectivamente. Fuente: Figura adaptada a partir del artículo en revisión enviado a la revista Journal of Hydrology Diez-Sierra y del Jesus 2019.



 $\label{eq:Figura 3.29} Frecipitación media para las 17 estaciones observadas y simuladas mediante el método Neural Network (NN) a una agregación temporal diaria, mensual y anual, respectivamente. La banda de color rojo representa el área comprendido bajo el cuantil del 5 % y del 95 % para 100 simulaciones.$

3.6. Conclusiones

En la presente sección hemos comparado la habilidad de 8 métodos estadísticos y de aprendizaje automatizado para predecir la precipitación a largo plazo. Los métodos utilizan como predictores los campos espaciales de la variables SLP, GH500 y GH850 a una resolución temporal diaria para el área comprendida por las coordenadas 45°W y 5°E, y 20°N y 50°N. El análisis se ha realizado para 17 estaciones distribuidas a lo largo de la isla de Tenerife (España) con un clima semiárido.

Se ha comparado la habilidad de los diferentes modelos para reproducir las series observadas utilizando diferentes métricas sobre la ocurrencia y la intensidad de la lluvia a distintas agregaciones temporales. También se ha determinado el mejor conjunto de hiperparámetros para cada modelo mediante la técnica de validación cruzada de entre un rango de valores definido por un producto cartesiano de varios hiperparámetros.

Los resultados muestran que los métodos de aprendizaje automatizado son muy sensibles a los hiperparámetros seleccionados. De hecho, una selección incorrecta de hiperparámetros podría llevar a modelos sin ninguna capacidad predictiva. Los modelos RF y k-NN generalmente tienden a sobreajustarse. Para evitarlo, los hiperparámetros $n_estimators$ y min_samples_leaf, en el caso de RF, y $n_neighbors$ en el caso de k-NN, deberían de tomar valores más elevados incluso cuando su capacidad predictiva se viese degradada. Los resultados también muestran que la combinación de hiperparámetros seleccionada como óptima varía considerablemente de una estación a otra; lo que demuestra que es esencial determinar los hiperparámetros óptimos antes de cualquier aplicación en lugar de recurrir a unos hiperparámetros predefinidos. Para minimizar el coste computacional, es recomendable comenzar con un amplio rango de búsqueda, y luego centrar el rango alrededor de los hiperparámetros que ofrecieron mejores resultados.

NN, con un resultado de *f-score* promedio cercano a 0.4, para todas las estaciones, es el método que presenta mayor habilidad para predecir la ocurrencia de la precipitación. Los métodos LR y SVM ofrecieron también buenos resultados. Todos los modelos conservan los valores observados de ϕ^{DD} y subestiman los valores observados de ϕ^{WW} . El método NN presenta errores menores al predecir las probabilidades de transición debido principalmente a que presenta valores más elevados de *f-score*. Los resultados obtenidos para la métrica exhaustividad son mayores a medida que se aumenta el umbral de la intensidad de lluvia; lo que indica que los eventos más intensos son más fáciles de predecir.

Todos los modelos, excepto WT, alcanzan valores de R por encima de 0.8 a la hora de simular el número de días de lluvia por mes y por año. Los métodos NN, SVM y LR

son los únicos métodos capaces de simular meses con más de 20 días húmedos, lo que es excepcionalmente inusual en Tenerife.

NN presenta resultados significativamente mejores que el resto de los modelos al predecir la intensidad de la lluvia. SVM, k-NN y RF ocupan el segundo lugar, con valores ligeramente inferiores de R y superiores de RMSE. El método basado en tipos de tiempo (WT), que fue utilizado para realizar la predicción probabilística a corto plazo en la Sección 3.4, es el que ofrece peores resultados de todos los modelos.

Todos los métodos subestiman ampliamente la varianza de las series observadas así como los eventos más intensos de precipitación. GLM-G es el modelo que mejor reproduce los índices extremales RX1 y R20, sin embargo, los resultados aún están lejos de los observados. Los resultados mejoran significativamente cuando comparamos las series observadas y simuladas para agregaciones temporales por encima del día. Todos los modelos, excepto WT, presentan valores de R cercanos a 0.8 cuando predicen la intensidad de la lluvia a una agregación temporal mensual y anual, sin embargo, NN ofrece de nuevo los mejores resultados. GLM-G es el único método capaz de simular meses con intensidades superiores a los 500 mm/mes. Los métodos de conjunto (*ensemble*) RF, k-NN y WT rara vez simulan años con valores de precipitación acumulada superiores de 800 mm. La incorporación de la estacionalidad mejora la habilidad de predicción de los modelos, sin embargo, no sucede lo mismo con el índice climático NAO. En general los métodos estadísticos y de aprendizaje automatizado supervisado ofrecen mejores resultados que los no supervisados.

Aunque cada modelo es ajustado de manera independiente para cada estación, las series simuladas son capaces de preservar en gran medida la correlación espacial observada a una agregación diaria, mensual y anual, respectivamente. A distancias inferiores y superiores a los 10 km las series simuladas subestiman y sobrestiman, respectivamente, los valores observados a una agregación temporal diaria. El único método capaz de preservar la correlación espacial observada para ambas agregaciones temporales es el método WT; lo que se debe a que es el único método en el que las predicciones son realizadas para todas las estaciones al mismo tiempo. La incorporación de modelos conceptuales de precipitación espacio-temporal mediante cópulas o a través de otras técnicas aprendizaje automatizado profundo (*deep learning*) podrían mejorar estos resultados (Stehlík y Bárdossy, 2002; Yang et al., 2005) y serán consideradas en trabajos futuros.

Los resultados obtenidos en la presente sección demuestran que NN es el método que mejores resultados ofrece para predecir la ocurrencia y la intensidad de precipitaciones a una resolución diaria, mensual y anual. Todos los métodos, excepto WT, presentan buenos resultados a una resolución anual. Ninguno de los modelos es capaz de capturar la gran variabilidad existente en las series de precipitación situadas en un clima semiárido,
como el que presenta Tenerife, lo que sugiere que los métodos analizados aquí no son apropiados para reproducir los eventos más extremos de precipitación que tuvieron lugar en el pasado. Otros enfoques como el uso de distribuciones mixtas (Jeffries y Pfeiffer, 2001; Mínguez et al., 2013) o mediante la incorporación de otro tipo de funciones de minimización serán investigadas en el futuro. Los buenos resultados logrados a la hora de predecir la precipitación a agregaciones temporales superiores del día hacen que los análisis mostrados en la presente sección sean especialmente útiles para estudios de recursos hídricos.

Capítulo 4

Desagregación temporal de la precipitación es España

4.1. Introducción

Como se mencionó en el Capítulo 2 "Estado del arte", disponer de datos de precipitación a agregaciones temporales por debajo del día es esencial para aplicaciones en muchos campos, como en el campo de la hidrología urbana, el diseño de infraestructuras y la evaluación de riesgos, entre otros (Cáceres et al., 2018; Krajewski y Smith, 2002; Kun et al., 2018; Michaud y Sorooshian, 1994; Noor et al., 2018; Smith et al., 2007). Además en España, donde los eventos más intensos de precipitación descargan grandes cantidades de agua en pocas horas, especialmente en el Mediterráneo, Islas Baleares e Islas Canarias (Diez-Sierra y del Jesus, 2017; Martin-Vide, 2004; Meseguer-Ruiz et al., 2017), es indispensable disponer de datos con una resolución horaria o minutal para caracterizar adecuadamente el riesgo asociado a dichos eventos. Algunos ejemplos del carácter torrencial de la precipitación en España son, por ejemplo, los eventos que tuvieron lugar en Valencia entre el 2 y el 3 de noviembre de 1987 con 817 mm precipitados, los 600 mm registrados en Almería en unas pocas horas el 17 de octubre de 1973, los 360 mm en Tenerife durante las 24 horas del día 11 de noviembre de 1950, los 157 mm precipitados en una hora en Mallorca el 17 de junio de 2005, los 130 mm también en una hora en Tenerife el 31 de marzo de 2002 y los 160 mm registrados en menos de 1 hora en Castellón el 18 de octubre del 2018 (Monjo et al., 2016).

En cuanto a la información pluviométrica, España dispone de una red de pluviómetros homogéneamente distribuidos a lo largo del territorio que son facilitados gratuitamente por AEMeT. Dicha red consta de unas 5000 estaciones con registros diarios y más de 20 años de datos, de promedio, para todas las estaciones cubriendo el periodo 1950-2018.

En el caso de la información disponible a una resolución horaria o minutal, el número de estaciones es mucho menor, con aproximadamente 1000 estaciones de las cuales únicamente 475 disponen de más de 10 años de datos. Esta escasa cobertura temporal en las series subdiarias, hace que deban utilizarse con cautela según su aplicación, como por ejemplo, en el caso de análisis de riesgos asociados a eventos extremos. Además, estas estaciones (subdiarias) no se distribuyen gratuitamente, ni si quiera en el caso en el que fueran utilizadas para fines relacionados con la investigación. Existen otras fuentes de información que también disponen de datos de precipitación a agregaciones subdiarias, como las bases de datos de satélite (Huffman et al., 2010), las bases de datos generadas por modelos numéricos (Pfeifroth et al., 2013b) y las bases de datos procedentes de radares (Austin y Seed, 2005). Estas fuentes de información, sin embargo, tienden a presentar grandes sesgos que es necesario corregir mediante registros instrumentales (Kim y Joan Alexander, 2013). Además, no deben ser interpretadas directamente como registros puntuales, ya que resultan de datos promediados sobre áreas de un tamaño determinado (del Jesus et al., 2015).

Por otro lado, el quinto informe de evaluación (AR5) del panel intergubernamental sobre cambio climático (IPCC) de la organización de naciones unidas (Stocker et al., 2013), así como la mayor parte de trabajos realizados hasta la fecha, señalan que por efecto del cambio climático los eventos más extremos de precipitación podrían ser más intensos y frecuentes en muchas zonas del planeta para mediados y finales del siglo XXI (Donat et al., 2014; Westra et al., 2013). La explicación de dicho incremento reside principalmente en el aumento de la temperatura superficial de aire como efecto de la emisión de CO₂ a la atmósfera. Según la formulación de Clausius-Clapeyron (ECC), la capacidad de retención de agua de la atmósfera aumenta en aproximadamente entre un 6% y un 7% por cada incremento de 1°C en la temperatura superficial del aire (TAS). Sin embargo, la temperatura no es necesariamente un buen predictor de la cantidad real de vapor de agua contenida en el aire, ya que un incremento de 1°C correspondería con una aumento de entre el 6% y el 7% en la cantidad de vapor agua, únicamente bajo la hipótesis de que la humedad relativa fuera constante en el futuro (Lenderink et al., 2017). De hecho, en algunas áreas con temperaturas elevadas el proceso podría resultar inverso debido a que la disponibilidad de vapor de agua en la atmósfera podría verse reducida al migrar dichas áreas hacia climas más áridos (Drobinski et al., 2018; Lenderink y Van Meijgaard, 2008). Drobinski et al. (2018) concluyen, por ejemplo, que en aquellas zonas con temperaturas superiores a los 20°C esta relación podría ser inversa. Otros estudios han demostrado que la ecuación ECC es extremadamente sensible a la escala temporal a la que se analicen los datos de precipitación. Utsumi et al. (2011) señalan que el aumento en la humedad de entre el 6% y el 7% por cada grado de temperatura podría ser equivalente para los eventos extremos de precipitación; o lo que es lo mismo, que los

eventos extremos aumentarán según la relación ECC. Sin embargo, esta relación parece conservarse únicamente a agregaciones temporales horarias o subhorarias, mientras que a agregaciones superiores podría ser inversa.

En ese contexto, Garijo y Mediero (2018) analizan cómo podrían cambiar los periodos de retorno de precipitación para 12 modelos regionales de EURO-CORDEX. Los resultados muestran muy pocas celdas con significancia positiva para un umbral del 5% a una agregación temporal diaria. Scoccimarro et al. (2015), por su parte, analizan los resultados de un modelo del CMIP5 (Taylor et al., 2012), en España, a dos agregaciones temporales distintas (diaria y tres-horaria). Los resultados muestran un comportamiento diferente entre ambas agregaciones temporales, con una mayor intensificación para las series 3-horarias que para las diarias. Por último, Merino et al. (2018) analizan un índice extremal de precipitación que tiene en cuenta la continuidad temporal de los eventos en varias estaciones con información subdiaria distribuidas a lo largo de la cuenca del Ebro (España). Los resultados muestran tendencias significativas positivas en prácticamente todas las estaciones a una resolución temporal horaria. A agregaciones superiores (6 h, 12 h, 72 h y 168 h) las conclusiones no son tan claras ya que dicha significancia, desaparece o incluso cambia de sentido, en muchas de las estaciones analizadas.

En resumen, los resultados obtenidos en la mayoría de los estudios realizados hasta la fecha, dependen en gran medida de las condiciones climáticas y geográficas de cada zona, de los modelos climáticos utilizados y de la resolución temporal de las series de precipitación analizadas. Es por ello que parece fundamental seguir investigando en esta misma dirección para comprender cómo podrían cambiar los eventos más extremos de precipitación en España en el futuro.

El objetivo principal de este capítulo es elaborar una metodología que sirva para generar series de precipitación horarias en cualquier localización de España donde se disponga de registros diarios. Además, dicha metodología podrá ser aplicada tanto para el clima actual como para diferentes escenarios de cambio climático. Para ello se analizarán diferentes métodos de desagregación de la precipitación basados principalmente en leyes de escala (Marani y Zanetti, 2007) y en el trabajo realizado por Beuchat et al. (2011); este último se basa en establecer relaciones de regresión entre los estadísticos de la precipitación a diferentes agregaciones temporales utilizando como predictores variables atmosféricas de bases de datos de reanálisis (ver la Sección 2.3 en el "Estado del arte").

La metodología propuesta por los autores se aplica al territorio Español y será ajustada y validada con más de 700 estaciones con registros horarios mediante técnicas de validación cruzada. Los estadísticos subdiarios predichos serán utilizados para alimentar generadores sintéticos de precipitación con el fin de generar series horarias en cualquier localización de España donde se disponga de datos diarios de precipitación (Diez-Sierra y del Jesus, 2019). La metodología utilizada para desagregar la precipitación, así como los resultados obtenidos, se exponen en la Sección 4.4 "Desagregación temporal de la precipitación en España para el clima presente". Los resultados obtenidos nos permite disponer de estadísticos subdiarios de precipitación distribuidos en todo el territorio español para el clima actual. Estos estadísticos serán la información de referencia para proyectar las series de precipitación para el futuro.

Por otro lado, en la Sección 4.5 "Desagregación temporal de la precipitación en España en un contexto de cambio climático", se calculará el cambio relativo entre los estadísticos de precipitación para el período histórico y 3 períodos horizonte de corto, medio y largo plazo, para varios modelos climáticos de la iniciativa CORDEX y para los escenarios RCP 4.5 y RCP 8.5. Los cambios relativos calculados a una agregación diaria servirán para actualizar los predictores de nuestros modelos de regresión, y así poder predecir los estadísticos subdiarios de precipitación en todas las estaciones con información diaria para los diferentes escenarios de cambio climático futuros.

Finalmente, como resultado de la Sección 4.5, se analiza el cambio en los estadísticos de precipitación a una agregación temporal diaria y horaria para los principales climas de España (Geiger, 1961). Los resultados de nuestro análisis muestran diferencias significativas entre ambas agregaciones temporales. A una resolución diaria, los resultados muestran cambios significativos negativos en la precipitación media diaria y cambios significativos positivos en la proporción de períodos secos en la mayoría de los climas. El número de estaciones que presentan significancia en el cambio es mayor para el escenario RCP 8.5 y para el período 2080-2100 (largo plazo). A una resolución horaria encontramos, además, cambios significativos en la varianza y la asimetría, principalmente como consecuencia del aumento de la temperatura superficial del aire. Los resultados obtenidos en el presente capítulo ponen de manifiesto que, como consecuencia del calentamiento global, es muy probable que se modifique la frecuencia e intensidad de los eventos extremos de precipitación en España para agregaciones temporales por debajo del día.

4.2. Área de estudio

Los análisis realizados en el presente capítulo se han llevado a cabo en el territorio español. España presenta unas condiciones especialmente atractivas para aplicar los diferentes métodos principalmente por dos motivos. Primero, porque cubre un amplio abanico de climas (ver Figura 4.1) con diferentes regímenes de precipitación en cada uno de ellos (AEMeT, 2011). Esta diversidad climática hace de España un lugar muy interesante para probar la habilidad de los diferentes métodos de desagregación temporal

en distintos tipos de climas. Y segundo, porque dispone de un número muy elevado de estaciones con registros horarios y diarios de precipitación, lo que hace posible validar los diferentes métodos de desagregación.



Figura 4.1: (Izquierda) Localización de las estaciones horarias (735, estrellas) y diarias (2896, puntos) utilizadas en el presente análisis y que disponen de información instrumental durante el periodo 1985-2015. (Derecha) Distribución espacial de los tipos de climas existentes en España según la clasificación de Köppen-Geiger realizada por AEMeT (AEMeT, 2011). Los acrónimos mostrados en la leyenda corresponden a los siguientes subgrupos climáticos: BWh (Árido cálido), BWk (Árido frío), BSh (Semiárido cálido), BSk (Semiárido frío), Csa (Mediterráneo Típico), Csb (Mediterráneo Oceánico), Csc (Mediterráneo subalpino con verano seco), Cfa (Subtropical húmedo o sin estación seca), Cfb (Oceánico templado), Dsb y Dfb (Climas hemiboreales), Dsc y Dfc (Climas subárticos) y ET (Tundra). Fuente: Figura adaptada a partir del artículo Diez-Sierra y del Jesus (2019).

La diversidad climática en España incluye: climas semiáridos en la región mediterránea dominados por procesos convectivos que producen inundaciones extremas; climas templados afectados por borrascas del Atlántico y que inducen precipitación frontales; climas continentales, en el interior de la Península, con una marcada estacionalidad y lluvias intensas y de corta duración; y climas únicos en todo el mundo, como el que se da en las Islas Canarias (Diez-Sierra y del Jesus, 2017; Herrera et al., 2001; Tullot, 1959), muy influenciado por la abrupta orografía local, la Corriente Canaria y su proximidad al continente africano.

España contiene cuatro de los cinco principales grupos climáticos según la clasificación climática de Köppen-Geiger (Peel et al., 2007): B (seco), C (templado), D (continental) y E (polar). El mapa climático mostrado en la Figura 4.1, ha sido desarrollado por la agencia estatal de meteorología AEMeT (AEMeT, 2011). Para su elaboración, AEMeT utilizó miles de estaciones con observaciones de temperatura y precipitación durante el período 1971-2000 (ver Figura 4.1). El único grupo climático que no está representado en ninguna parte del territorio español es el grupo A (tropical). Los subgrupos climáticos Csc y ET, aunque presentes en áreas muy pequeñas del territorio, como por ejemplo

alrededor del Teide y en las partes más altas de los Pirineos, no contienen ninguna estación instrumental de precipitación con información horaria, y por lo tanto no han sido incorporados en los análisis. De manera similar, los climas de montaña Dsb, Dsc, Dfb y Dfc disponen de muy pocas estaciones con información subdiaria (entre una y tres), es por ello que serán combinadas en un único grupo climático D.

4.3. Datos de partida

Los datos de precipitaciones utilizados en el presente estudio comprenden una gran base de datos con estaciones diarias y horarias que cubren homogéneamente la Península Ibérica, las Islas Baleares y las Islas Canarias (ver Figura 4.1). La Tabla 4.1 muestra las organizaciones que han facilitado la información de precipitación.

Inicialmente, disponemos de unas 5000 estaciones de con información diaria y 1000 con información horaria. Como primer filtro, se seleccionaron aquellas estaciones con al menos diez o más años completos durante el período 1986-2005. Definimos un año completo como aquel que tiene más de 24 días con datos de lluvia para cada mes del año. A las estaciones resultantes se les realizó una serie de tests de homogeneidad, tanto absoluta como relativa (Herrera et al., 2012b), resultando en un total de 2896 estaciones con resolución diaria y 735 con resolución horaria. La Figura 4.1 muestra la distribución espacial de las 735 estaciones con registros horarios (estrellas) utilizadas en el presente análisis, así como las 2896 estaciones con registros diarios (puntos) que serán utilizadas para extender los métodos para el clima presente y futuro.

TABLA 4.1: La tabla muestra las instituciones que han facilitado la información de
precipitación. En la columna N° estaciones, la letra d y la h indican el número de
estaciones con información diaria y horaria, respectivamente. Fuente: Tabla adaptada
a partir del artículo Diez-Sierra y del Jesus (2019)

Instituciones	N° estaciones			
AEMET (AEMeT)	2896 d, 38 h			
Cuenca Mediterránea	100 h			
Andaluza (CMA)	109 11			
C.H. Segura (CHS)	114 h			
C.H. Miño-Sil (CHMS)	89 h			
C.H. Cantábrico (CHC)	56 h			
C.H. Jucar (CHJ)	185 h			
C.H. Ebro (CHE)	69 h			
Organismo Autónomo	16 h			
Parques Nacionales (OAPN)	10 11			
Sistema de Información	227 h			
Agroclimática para el Regadio (SIAR)	237 11			
Servei Meteorològic	43 h			
de Catalunya (SMC)	40 11			

TABLA 4.2: La tabla muestra la institución, el nombre del modelo climático global (GCM) y regional (RCM), la versión, la inicialización, y el dominio para cada uno de los modelos utilizados. Los escenarios RCP 4.5 y 8.5 fueron analizados para cada modelo.

Institución	GCM	RCM	Versión	Inicialización	Dominio
CLMcom	MPI-M-MPI-ESM-LR	CCLM4-8-17	v1	r1i1p1	EURO
DMI	ICHEC-EC-EARTH	HIRHAM5	v1	r3i1p1	EURO
KNMI	ICHEC-EC-EARTH	RACMO22E	v1	r1i1p1	EURO
KNMI	MOHC-HadGEM2-ES	RACMO22E	v2	r1i1p1	EURO
MPI-CSC	MPI-M-MPI-ESM-LR	REMO2009	v1	r1i1p1	EURO
MPI-CSC	MPI-M-MPI-ESM-LR	REMO2009	v1	r2i1p1	EURO
SMHI	CNRM-CERFACS-CNRM-CM5	RCA4	v1	r1i1p1	EURO
SMHI	ICHEC-EC-EARTH	RCA4	v1	r12i1p1	EURO
SMHI	IPSL-IPSL-CM5A-MR	RCA4	v1	r1i1p1	EURO
SMHI	MOHC-HadGEM2-ES	RCA4	v1	r1i1p1	EURO
SMHI	MPI-M-MPI-ESM-LR	RCA4	v1a	r1i1p1	EURO
KNMI	ICHEC-EC-EARTH	RACMO22T	v1	r1i1p1	AFR
SMHI	CCCma-CanESM2	RCA4	v1	r1i1p1	AFR
SMHI	CNRM-CERFACS-CNRM-CM5	RCA4	v1	r1i1p1	AFR
SMHI	CSIRO-QCCCE-CSIRO-Mk3-6-0	RCA4	v1	r1i1p1	AFR
SMHI	ICHEC-EC-EARTH	RCA4	v1	r12i1p1	AFR
SMHI	IPSL-IPSL-CM5A-MR	RCA4	v1	r1i1p1	AFR
SMHI	MIROC-MIROC5	RCA4	v1	r1i1p1	AFR
SMHI	MPI-M-MPI-ESM-LR	RCA4	v1	r1i1p1	AFR
SMHI	NCC-NorESM1-M	RCA4	v1	r1i1p1	AFR
SMHI	NOAA-GFDL-GFDL-ESM2M	RCA4	v1	r1i1p1	AFR

Además de los datos de precipitación, la metodología propuesta requiere variables atmosféricas de reanálisis que serán utilizadas como predictores para mejorar el rendimiento de los modelos de regresión. Las variables atmosféricas informan a los modelos de regresión sobre la relación entre los estadísticos de precipitación a diferentes escalas temporales para cada régimen climático de España.

Los predictores han sido obtenidos de dos bases de datos de reanálisis diferentes con el fin de evaluar la sensibilidad de los métodos ante productos con distinta resolución espacio-temporal; es esperable que un producto con mayor resolución espacio-temporal capture mejor los procesos locales. Por un lado se ha utilizado la base de datos de reanálisis NCEP (Kalnay et al., 1996) con una resolución espacial de 2.5° grados y una resolución temporal mensual. Y por otro, se ha utilizado la base de datos CFSR (Saha et al., 2010) desarrollada por la NOAA y que presenta una resolución espacial de 0.312 ° grados y una resolución temporal horaria. La media y la varianza para la temperatura superficial de aire (TAS), humedad relativa a 850 hPa (HUR), presión a nivel del mar (SLP), componente de velocidad del viento zonal a 500 hPa (Uwnd) y componente de velocidad del viento meridional a 500 hPa (Vwnd), son utilizadas cómo covariables para los modelos de regresión.

Los datos de precipitación, así como de las variables atmosféricas para el clima futuro,

han sido obtenidas gracias a las simulaciones generadas en el marco de la iniciativa COR-DEX (*Coordinated Regional Climate Downscaling Experiment*). Más concretamente, se han utilizado los datos asociados a la malla de EURO-CORDEX (Jacob et al., 2014), que cubre toda la península Ibérica, las Islas Baleares, Ceuta y Melilla, con una resolución espacial de 0.11° (~12.5km), y los datos asociados a la malla AFR-CORDEX (Laprise et al., 2013), que cubre las islas Canarias con una resolución de 0.44° (~50km). La Tabla 4.2 contiene el nombre de la institución, del GCM y RCM utilizados, de la versión, de la inicialización, y del dominio, para cada uno de los modelos utilizados en el estudio. Los escenarios RCP 4.5 y RCP 8.5 han sido considerados, para cada modelo, ya que representan un escenario de cambio climático moderado y extremo, respectivamente¹.

Estos modelos han sido seleccionados ya que comprenden un conjunto heterogéneo de instituciones, modelos e inicializaciones; cubriendo así las tres principales incertidumbres asociadas a los resultados de las proyecciones de cambio climático: (1) la variabilidad interna o natural, que depende de las condiciones climáticas con las que fueron inicializados los modelos y está presente principalmente en el corto plazo; (2) la propia incertidumbre asociada al modelo, cuyos resultados dependen de la ecuaciones físicas y parametrizaciones y que está presente principalmente en el medio plazo; y (3) el escenario de cambio climático (RCP), que depende del comportamiento del ser humano en el futuro, y que está presente principalmente a finales del siglo XXI (Hawkins y Sutton, 2011). La información de cambio climático fue descargada mediante la librería *Climate4R* (Iturbide et al., 2019).

4.4. Desagregación temporal de la precipitación en España para el clima presente

4.4.1. Métodos

La Figura 4.2 muestra el esquema metodológico seguido para predecir los estadísticos subdiarios de precipitación para el clima presente. Como se muestra en la Figura 4.2, la base de datos de precipitación horaria (con 735 estaciones con registros horarios) es agregada a una escala diaria. Los estadísticos media (μ), varianza (σ), asimetría (γ), autocorrelación temporal (ρ), proporción de intervalos secos (ϕ) y probabilidades de transición (ϕ^{DD} y ϕ^{WW}) fueron calculados a las agregaciones temporales T=[1-h, 2-h, 3-h, 6-h, 12-h, 1-d, 2-d y 3-d]. La información atmosférica de reanálisis, a una agregación

¹El escenario RCP 4.5 comprenden un escenario en el que los esfuerzos en mitigación conducen a un escenario de estabilización en 2100 con un forzamiento de 4.5 W/m² y 538 ppm de CO₂ para 2100. El RCP 8.5 es un escenario en el que no se toman medidas de mitigación por lo que la tendencia continua siendo creciente en 2100 con un forzamiento de 8.5 W/m² y 936 ppm para 2100.



Figura 4.2: Esquema metodológico seguido para desagregar las series diarias de precipitación. Primero se genera una base de datos de precipitación horaria para toda España a partir de la información proporcionada por las distintas administraciones mostradas en la Tabla 4.1. Luego, la información horaria es agregada a una resolución diaria y, junto con la información atmosférica, a una resolución mensual, serán utilizadas como predictores para los modelos de regresión (desagregación). Finalmente, los métodos se validan comparando los estadísticos subdiarios observados y simulados mediante la técnica de validación cruzada. Fuente: Figura adaptada a partir del artículo Diez-Sierra y del Jesus (2019).

mensual, es utilizada para mejorar la habilidad de los desagregadores en las diferentes zonas climáticas de España. Los estadísticos subdiarios predichos serán comparados con los observados para evaluar la calidad de los diferentes modelos de regresión y leyes de escala mediante el método de validación cruzada.

A continuación se describe en detalle todos los métodos utilizados. En primer lugar se describe el método basado en las leyes de escala (Marani y Zanetti, 2007), luego el modelo presentando por Beuchat et al. (2011) y por último el modelo implementado en la presente tesis (Diez-Sierra y del Jesus, 2019).

4.4.1.1. Leyes de escala

Las leyes de escala son ecuaciones analíticas que pueden ser utilizadas para describir el comportamiento de los estadísticos de una variable a diferentes agregaciones temporales. Estas ecuaciones analíticas, ajustadas mediante información instrumental diaria y supradiaria, sirven para predecir los estadísticos de precipitación a agregaciones subdiarias asumiendo que se dispone de los mismos estadísticos a agregaciones superiores. Marani y Zanetti (2007) primero, y Beuchat et al. (2011) después, analizaron la capacidad de dichas técnicas para desagregar los estadísticos varianza y autocorrelación temporal para más de 200 estaciones con información horaria distribuidas a lo largo de los Estados Unidos, Reino Unido y Suiza.

Las leyes de escala utilizadas son: la ley de escalado de memoria finita (Mandelbrot y Wallis, 1968), descrita en la ecuación 4.4.1; una ley de escala potencial (Mandelbrot y Wallis, 1968), descrita en la ecuación 4.4.2; y la ley de escala propuesta en Marani (2005), descrita en la ecuación 4.4.3.

En las ecuaciones 4.4.1 y 4.4.3, $\sigma^2(T)$ corresponde a la varianza en función su la agregación temporal *T*. Mientras que $\sigma_i^2 \in I$, en la ecuación 4.4.1, σ_i y γ en la ecuación 4.4.2 y σ_i , α y ϵ , en la ecuación 4.4.3, son parámetros de ajuste.

$$\sigma^{2}(T) = 2\sigma_{i}^{2}I\{I[exp(-T/I) - 1] + T\}$$
(4.4.1)

$$\sigma^2(T) = \sigma_i T^\gamma \tag{4.4.2}$$

$$\sigma^{2}(T) = \begin{cases} 2\sigma_{i}^{2}\frac{\epsilon}{\alpha} \left[\frac{\epsilon}{\alpha} \left(e^{-\frac{\alpha\tau}{\epsilon}} - 1 \right) + T \right] & \text{if } T \leq \epsilon \\ 2\sigma_{i}^{2} \left[\frac{\epsilon^{\alpha}e^{-\alpha}}{(1-\alpha)(2-\alpha)} T^{2-\alpha} \\ + \frac{\epsilon}{\alpha} \left(1 - \frac{e^{-\alpha}}{1-\alpha} \right) T & \text{if } T > \epsilon \\ + \frac{\epsilon^{2}}{\alpha^{2}} \left(e^{-\alpha} - 1 \right) + 2\frac{\epsilon^{2}e^{-\alpha}}{\alpha(2-\alpha)} \end{bmatrix} \end{cases}$$
(4.4.3)

La ley de memoria finita (ecuación 4.4.1) presenta una caída pronunciada para la autocorrelación temporal, lo que la convierte en un modelo adecuado para describir eventos de lluvia dispersos en el tiempo, como por ejemplo las tormentas convectivas de corta duración. La ley potencial (ecuación 4.4.2) es una ley de escala simplificada con únicamente dos parámetros de ajuste. Mientras que el modelo propuesto por Marani (2005) (ecuación 4.4.3) presenta una estructura mucho más compleja capaz de capturar eventos de lluvia que muestran alta dependencia entre ellos, como por ejemplo las perturbaciones de gran escala; en esta última función la autocorrelación se caracteriza por presentar una cola que decae lentamente. Según Marani (2005) fue esta última ecuación la que se ajustó mejor en la mayoría de estaciones analizadas.

Los parámetros de las leyes de escala se ajustan únicamente mediante información diaria y supradiaria de precipitación. En concreto se utiliza la varianza y la autocorrelación temporal, con un retraso de 1 intervalo de tiempo (lag=1), para las agregaciones temporales de 24, 48, 72 y 96 horas. Para tener en cuenta la influencia de la estacionalidad, las leyes se ajustan para cada mes del año por separado. El método de mínimos cuadrados es utilizado para realizar los ajustes.

Es importante tener en cuenta que la ecuación 4.4.3 es más flexible que las ecuaciones 4.4.1 y 4.4.2 ya que incluye un mayor número de parámetros. Después de algunos experimentos, Marani y Zanetti (2007) descubrieron que los mejores resultados fueron obtenidos cuando se asumía un parámetro $\epsilon \leq 1$ para la ecuación 4.4.3. Beuchat et al. (2011), más tarde, establecieron el valor de ϵ en 0.3, 0.7, 1 y 3 con el objetivo de igualar la cantidad de parámetros entre las diferentes leyes de escala y realizar una comparación más justa. En este trabajo, se han utilizado los mismos valores del parámetro ϵ propuestos por Beuchat et al. (2011).

4.4.1.2. Modelo de Beuchat

El método de desagregación presentado en esta tesis (Diez-Sierra y del Jesus, 2019) está basado en el modelo propuesto por Beuchat et al. (2011). Este modelo se basa en encontrar relaciones de regresión entre los estadísticos subdiarios y supradiarios de precipitación. Los métodos utilizan además, como predictores adicionales, la elevación del terreno y estadísticos atmosféricos a una agregación temporal mensual de bases de datos de reanálisis. Las relaciones de regresión se calculan para la varianza, asimetría y proporción de intervalos secos. A continuación se describe brevemente el método propuesto por Beuchat et al. (2011).

La metodología propuesta por Beuchat et al. (2011) se basa en ajustar un modelo de regresión para cada conjunto de estadísticos y agregación temporal subdiaria T=[1-h, 3-h, 6-h y 12-h]. Como predictores se utilizan los estadísticos supradiarios de precipitación para las agregaciones temporales T=[1-d, 2-d y 3-d], así como la media y la varianza mensual de las variables TAS, HUR, SLP, Uwnd, Vwnd, y la elevación. Las variables atmosféricas fueron seleccionadas para las celdas de la base de datos de reanálisis más cercanas a las estaciones. El análisis tiene como resultado 12 modelos de regresión individuales (tres estadísticos por cuatro agregaciones temporales). La media, la varianza y la asimetría son transformados previamente a una escala logarítmica para garantizar que las predicciones siempre presenten resultados positivos. La proporción de intervalos secos se transforma mediante la función logit para asegurar que el rango está comprendido en el intervalo [0, 1]. Para hacer frente al comportamiento no estacional de los estadísticos a lo largo de los diferentes meses de año, estos son calculados por separado para cada mes del año. Por lo tanto, antes de estimar el conjunto de estadísticos, cada serie temporal de precipitación es dividida en 12 subseries (una para cada mes de año). Las variables atmosféricas servirán para ayudar a los modelos de regresión (desagregadores) a establecer diferentes relaciones de regresión dependiendo del tipo de clima y del mes del año analizado. El método de regresión utilizado en Beuchat et al. (2011) es el método MARS (Multivariate Adaptive Regression Splines; Friedman y Roosen 1995; Friedman 1991). MARS es una técnica de regresión no paramétrica que combina los predictores en base a funciones *splines*, lo que permite establecer puntos de ruptura (nodos) entre los predictores y los predictandos. El procedimiento de ajuste se lleva a cabo en varias iteraciones en las que cada una de ellas introduce un grado más de interacción entre los predictores. Durante el primer paso, el modelo MARS no permite que exista ninguna interacción entre los predictores. MARS utiliza el procedimiento de validación cruzada generalizada (Generalized Cross Validation o GCV, por sus siglas en inglés) para identificar que predictores son significativos (Craven y Wahba, 1978). Durante el segundo paso se permiten interacciones de segundo orden entre los predictores, y la técnica GCV se utiliza nuevamente para identificar aquellos predictores que son significativos. El procedimiento se repite hasta llegar a interacciones de tercer orden.

En contraste con el resto de estadísticos, Beuchat et al. (2011) derivan la autocorrelación temporal (ρ) a partir de los resultados de varianza predicha por el modelo MARS mediante las siguientes ecuaciones matemáticas que relacionan la varianza y la covarianza:

$$\sigma^{2}[Y_{2h}] = \sigma^{2}[Y_{h}^{1}] + \sigma^{2}[Y_{h}^{2}] + 2Cov[Y_{h}^{1}, Y_{h}^{2}]$$
(4.4.4)

$$\rho = \frac{\sigma^2 \left[Y_{2h} \right]}{2\sigma^2 \left[Y_h \right]} - 1 \tag{4.4.5}$$

donde Y_h^1 y Y_h^2 corresponden a la cantidad de lluvia para dos intervalos *h*-horas adyacentes no superpuestos.

4.4.1.3. Modelo Random Forests

En la presente tesis se han propuesto algunos cambios respecto al modelo presentado en Beuchat et al. (2011) con el objetivo de mejorar los resultados de desagregación y también para simplificar en la medida de lo posible el modelo para futuras aplicaciones.

El primer cambio tiene que ver con la incorporación de técnicas de aprendizaje automatizado (ML) para establecer las relaciones de regresión. Las técnicas ML son capaces de encontrar relaciones no lineales entre predictores y predictandos. Además, no es necesario conocer cómo se distribuyen los datos a priori (Alizadeh et al., 2018) y no requieren de un procedimiento de ajuste de varios pasos para garantizar su funcionamiento. Los bosques aleatorios o *Random Forests* (RF) han sido utilizados en vez del modelo MARS para predecir los estadísticos subdiarios de precipitación (Breiman, 2001). Esta técnica (RF) ya ha sido utilizada con éxito en diferentes estudios de recursos hídricos (He et al., 2016; Muñoz et al., 2018; Sultana et al., 2018). Una ventaja de la RF, respecto a MARS, es que no requiere ninguna transformación (logarítmica o *logit*) de las variables de entrada (predictores), simplificando de esta manera la aplicación de los métodos. Dos hiperparámetros han sido analizados para la optimización del método RF: (1) el número total de árboles en el bosque y (2) el número mínimo de muestras (datos) requeridos para formar una hoja o nodo (ver Sección 3.5.1.2).

El segundo cambio se refiere a la forma en que el coeficiente de autocorrelación temporal (ρ) o ACF-lag1 es calculado. Beuchat et al. (2011) propuso calcular dicho estadístico de manera indirecta a través de la varianza predicha mediante el modelo MARS (ver ecuaciones 4.4.4 y 4.4.5). En su lugar, nosotros proponemos utilizar la misma metodología seguida para el resto de estadísticos. Es decir, ajustar de nuevo los modelos utilizando como predictores los estadísticos diarios y supradiaros de precipitación y la información atmosférica de reanálisis. También proponemos extender el trabajo a las probabilidades de transición $(\phi_T^{WW} \ge \phi_T^{DD})$, la probabilidad de tener dos períodos consecutivos de lluvia o de sequía, respectivamente, de una duración determinada T. Las probabilidades de transición son muy útiles, junto con el coeficiente de autocorrelación temporal, para informar a los modelos de lluvia sintética de la estructura temporal de las series de precipitación. El uso combinado de estos tres estadísticos ayuda a construir generadores sintéticos de lluvia más robustos. No obstante, Cowpertwait et al. (1996a) encontraron que cuando la autocorrelación era excluida del procedimiento de ajuste y los generadores sintéticos únicamente eran ajustados mediante las probabilidades de transición, las series sintéticas simuladas preservaban la autocorrelación temporal observada para la mayor parte de estaciones y meses de año.

El tercer cambio afecta a la selección de predictores. Para mantener el modelo lo más parsimonioso posible, el número de predictores considerados en el análisis se limitó al mínimo mediante el uso del criterio de información de Akaike (Akaike, 1974). El hecho de reducir el número de predictores ayuda a que los métodos puedan ser generalizados más fácilmente para, por ejemplo, estudios de cambio climático o para otras zonas climáticas del planeta.

El cuarto cambio se refiere a la base de datos de reanálisis atmosférica utilizada como predictor. Dos bases de datos diferentes serán comparadas para evaluar su efecto sobre los resultados. La base de datos NCEP, que es la que utilizan Beuchat et al. (2011) en sus análisis, y la base de datos CFSR que presenta una mayor resolución espacio-temporal.

De ahora en adelante, nos referiremos con la letra B al modelo presentado en Beuchat et al. (2011) y con las letras RFB al modelo propuesto en la presente tesis.

4.4.1.4. Evaluación de los modelos

Para evaluar y comparar la habilidad predictiva de los diferentes métodos se ha aplicado la técnica k-fold con k=10 (Markatou et al., 2005). La técnica 10-fold cross-validation divide el conjunto de datos en 10 partes del mismo tamaño. El modelo es entrenado utilizando nueve de las partes (conjunto de entrenamiento) y es validado en el conjunto de datos restante; es decir, el que no es usa durante el entrenamiento (test set). El procedimiento se repite 10 veces, cambiando en cada una de las iteraciones los datos utilizados para ajustar y validar. El rendimiento del modelo se calcula mediante el resultado promediado de las 10 iteraciones.

La capacidad predictiva de los modelos, para los diferentes estadísticos analizados, es evaluada a través del coeficiente de determinación R^2 , definido como:

$$R^2 = 1 - \frac{SS_{res}}{SS_{tot}} \tag{4.4.6}$$

donde $SS_{res} = \sum_{i} (f_i - y_i)^2$ es la suma de los cuadrados de los residuos, siendo f_i la predicción del modelo para el dato observado y_i ; y donde SS_{tot} es la suma total de cuadrados $SS_{tot} = \sum_{i} (y_i - \bar{y})^2$ que es proporcional a la varianza de los datos.

El coeficiente de determinación tomará un valor igual a 1 ($R^2 = 1$) para un modelo perfecto, y un valor igual a 0 ($R^2 = 0$) para un modelo que no es mejor que aquel que predice la media de los datos cada vez. El coeficiente de determinación también puede tomar un valor negativo ($R^2 < 0$), lo que indicaría que es peor que aquel que predice la media en cada ocasión.

4.4.1.5. Generación sintética de la precipitación

Como se comento en la Sección 4.1, uno de los objetivos del presente capítulo es establecer una metodología que sirva para predecir estadísticos de precipitación a agregaciones temporales por debajo del día en aquellas localizaciones de España donde únicamente se disponga de información diaria de precipitación. Los estadísticos predichos tienen muchas utilidades como por ejemplo: calibrar modelos numéricos, entender cómo se comporta la precipitación a agregaciones temporales más pequeñas, comprender los efectos del cambio climático sobre los eventos más extremos de precipitación, etc. Sin embargo, para la mayoría de aplicaciones de carácter ingenieril, como el cálculo de periodos de retorno o la gestión de recursos hídricos, por ejemplo, es necesario disponer de series de precipitación y no únicamente de sus estadísticos.

Dentro de este contexto existen diferentes métodos, conocidos como generadores sintéticos (*Stochastic Weather Generators* en inglés), que son ajustados mediante estadísticos de precipitación y sirven para generar series sintéticas de miles de años de duración que reproduzcan dichos estadísticos (Wilby, 1999). Una de las técnicas más utilizadas es aquella basada en procesos puntuales o modelos Poisson Cluster (PC). Los procesos puntuales son modelos matemáticos que fueron originalmente adaptados para su uso en hidrología por Rodriguez-Iturbe y Cox e Isham en el año 1987 (Onof et al., 2000). Son modelos paramétricos que se basan en tormentas que se distribuyen mediante un proceso de Poisson y que tienen asociadas un número de celdas de lluvia con una intensidad y un radio determinados. Una de las ventajas de esta técnica, frente a otras, es que es extremadamente flexible, ya que con ella podemos reproducir no solo la media y la varianza, sino también la asimetría, la proporción de intervalos secos, las probabilidades de transición y la correlación espacio-temporal de las series observadas de precipitación. Además, este tipo de modelos tienen la ventaja de poder ser ajustados a varias agregaciones temporales al mismo tiempo.

El modelo de generación de lluvia propuesto aquí es una extensión del modelo conocido como *Neyman-Scott Rectangular Pulse Model* (NSRPM) y permite la superposición de varios procesos puntuales independientes (Cowpertwait, 1995; Cowpertwait et al., 2013; Leonard et al., 2008). El modelo se describe de la siguiente manera:

El origen de las tormentas siguen un proceso de Poisson con parámetro λ . Asociado a cada tormenta hay un número aleatorio de celdas de lluvia (v) que presentan un retardo respecto al origen de la tormenta que sigue una distribución exponencial de parámetro β . La duración y la intensidad de cada celda de lluvia sigue también una distribución exponencial con parámetros ϵ y χ (parámetros de escala), respectivamente. La intensidad de cada celda de lluvia es constante durante el tiempo que permanece activa. La intensidad de lluvia en cualquier instante se compone de la suma de las intensidades de las celdas activas en ese mismo instante de tiempo. Se asume que la duración, intensidad y el tiempo de espera entre una tormenta y cada celda de lluvia es independiente (Cowpertwait, 1991). En la Figura 4.3 se muestra un ejemplo explicativo del funcionamiento del modelo NSRPM.

En la versión del modelo NSRPM utilizado durante la tesis se ajustaron dos procesos puntuales independientes superpuestos para permitir que los modelos capturasen mejor los diferentes tipos de tormentas (ej. lluvia convectiva y estratiforme); lo que nos conduce a un modelo con 10 parámetros (λ_1 , λ_2 , v_1 , v_2 , β_1 , β_2 , ϵ_1 , ϵ_2 , χ_1 , y χ_2). Los subíndices 1 y 2 corresponden a los parámetros de ajuste para cada uno de los dos modelos NSRPM independientes, respectivamente. Para tener en cuenta el comportamiento no estacionario de la precipitación a lo largo del año, se ha ajustado un modelo para cada mes del año (12 modelos diferentes). Las propiedades estadísticas del modelo fueron derivadas de Cowpertwait (1995), Cowpertwait (1998), Leonard et al. (2008) y Rodríguez– Iturbe y Eagleson (1987). Además, aunque no es uno de los objetivos del presente análisis, el modelo puede extenderse fácilmente en la dimensión espacial. Para ello únicamente habría que ajustar un nuevo parámetro (radio de las celda) e introducir una ecuación más con el objetivo de ajustar la correlación espacial (Cowpertwait et al., 2013).



Figura 4.3: Esquema explicativo del funcionamiento del modelo Neyman-Scott Rectangular Pulse Model. El origen de las tormentas siguen un proceso de Poisson con parámetro λ . Asociado a cada tormenta hay un número aleatorio de celdas de lluvia (v) que presentan un retardo respecto al origen de la tormenta y siguen una distribución exponencial de parámetro β . La duración y la intensidad de cada celda de lluvia también sigue una distribución exponencial con parámetros ϵ y χ , respectivamente.

4.4.2. Resultados

En esta Sección se presentan los resultados para los tres métodos de desagregación descritos en la Sección 4.4.1, 'Métodos", y que comprenden: (1) las leyes de escala, (2) el modelo B propuesto (Beuchat et al., 2011) y (3) el modelo RFB propuesto por los autores Diez-Sierra y del Jesus (2019). Una vez comparados los resultados para los tres enfoques, se seleccionará aquel que obtenga mejores resultados a la hora de predecir los estadísticos subdiarios observados de precipitación. Estos estadísticos serán utilizados más tarde para ajustar el modelo NSRPM en diferentes zonas de España y simular series sintéticas horarias de precipitación de miles de años de duración. Para ello el modelo NSRPM será ajustado y validado en 15 estaciones distribuidas a lo largo de España con regímenes climáticos completamente diferentes. Una vez validados los métodos, se extenderá el trabajo a todas las estaciones con información diaria disponibles en el territorio español. Los resultados son almacenados en una base de datos puesta a disposición pública.

4.4.2.1. Leyes de escala

Se ha analizado la habilidad de las leyes de escala para predecir la varianza subdiaria en todas las estaciones con información horaria (735) disponibles para España. La Figura 4.4, muestra el porcentaje de estaciones que mejor ajusta para cada tipo de clima y para cada ley de escala para el estadístico varianza a una agregación temporal T=[1-h, 3-h, 6-h, 12-h].

Si nos fijamos en el panel situado en el lado superior izquierdo de la Figura 4.4, que corresponde con la varianza horaria, podemos observar que la ley de escalado de memoria finita (ecuación 4.4.1) es la que mejores resultados obtiene para todos los climas en aproximadamente el 40 % de las estaciones. Para el clima Bwk el porcentaje de estaciones alcanza aproximadamente el 70 %. La ley de escala de memoria finita supera a los otros cinco modelos, pero no por un margen suficientemente grande como para considerar que es el mejor modelo. De hecho, el modelo Marani [$\epsilon = 3$] ajusta mejor en un 20 % de las estaciones para todos los climas, lo cual es un porcentaje para nada despreciable.

El dominio de la ley de escala de memoria finita desaparece para el resto de agregaciones temporales analizadas. Los resultados para la varianza de 3-horaria (3h) (panel situado en la esquina superior derecha de la Figura 4.4) muestran que el modelo Marani [$\epsilon = 3$] ofrece mejores resultados en el doble de estaciones que la ley de escala de memoria finita (a excepción de para el clima Bwk). Para agregaciones mayores, las diferencias entre la ley de escala de memoria finita y el modelo de Marani [$\epsilon = 3$] disminuyen hasta alcanzar una proporción similar de estaciones para la varianza 12-horaria. A dicha



Figura 4.4: Porcentaje de estaciones que ajusta mejor para cada ley de escala según el tipo de clima. La varianza horaria se muestra en el panel superior izquierdo, la varianza 3-h en el panel superior derecho, la varianza 6-h en el panel inferior izquierdo y la varianza 12-h en el panel inferior derecho. Cada ley de escala se representa en el eje abscisas. La altura de las barras representa la proporción de estaciones que mejor ajusta para cada ley de escala.

agregación temporal, la ley de escala potencial es la que mejor resultados presenta en una proporción de estaciones comparable a la obtenida con la ley de memoria finita y con la ley de escala de Marani [$\epsilon = 3$].

El clima Bwk parece ser el único para el cual la ley de escala de memoria finita siempre supera a los otros modelos. Este tipo de clima está representado principalmente por estaciones ubicadas en el sureste de Tenerife y en La Gomera, ambas en el archipiélago canario. Allí predominan las lluvias convectivas, lo que podría explicar por qué la ley de escala de memoria finita, que presenta una caída pronunciada de la autocorrelación temporal, es la que mejor resultados ofrece.

Estos resultados son comparables a los obtenidos por Beuchat et al. (2011) con las leyes de escala, sin embargo, el porcentaje relativo de estaciones es algo diferente que el obtenido en nuestro análisis. En lugar de existir un predominio del modelo Marani $[\epsilon = 3]$ sobre el resto, como sucede en el trabajo realizado por Beuchat et al. (2011), en nuestro análisis el modelo de memoria finita es el que mejor resultados consigue a



Figura 4.5: Varianza horaria (paneles superiores) y 12-horaria (paneles inferiores) predicha mediante las leyes de escala. La predicción se realizó con la ley de escala que mejor ajusta para cada estación. Los paneles situados en el lado izquierdo de la figura muestran los diagramas de dispersión para la varianza observada y predicha. Los colores indican el tipo de clima para cada estación. La línea negra discontinua corresponden al ajuste lineal. Los paneles del lado derecho de la figura muestran la distribución de errores relativos (%) para la varianza. μ y Mo corresponden a la media y a la moda de los errores relativos, respectivamente.

una agregación horaria. El modelo de Marani, con valores de $\epsilon \leq 3$, no parece capturar correctamente el comportamiento de la varianza para en las estaciones de España.

Las diferencias entre los resultados conseguidos para nuestro análisis y para el análisis realizado por Beuchat et al. (2011), puede explicarse por el uso de distintas bases de datos, y previsiblemente, porque probablemente habría que haber considerado otras variables explicativas a la hora de agrupar las estaciones (elevación, orientación, etc.). Según estos resultados, no parece existir una ley de escala que funcione mejor, ni si quiera cuando los resultados son agrupados por climas; lo cual limitaría considerablemente la generalización de las leyes de escala, ya que parece difícil conocer de antemano que ley de escala habría que seleccionar en cada caso.

A pesar de que no ha sido posible determinar, a priori, la ley de escala óptima en función del tipo de clima, se ha evaluado la capacidad de dichas leyes como una herramienta para predecir la varianza en todas las estaciones con datos horaria. La Figura 4.5 muestra los resultados obtenidos a una agregación temporal horaria (paneles situados en la parte superior) y 12-horaria (paneles situados en la parte inferior), partiendo de la hipótesis de que es conocido el tipo de ley de escala que mejor ajusta para cada estación y agregación temporal. Los paneles situados en la parte superior izquierda de la figura muestran el gráfico de dispersión para la varianza observada (eje de abscisas) y predicha (eje de ordenadas) a una resolución horaria. Como se puede observar, los valores de varianza horaria predichos sobrestiman los valores de varianza observados en muchas de las estaciones analizadas. Los paneles situados en la parte superior derecha representan el histograma de errores relativos obtenidos durante el proceso de reducción de escala. Se puede observar que los errores relativos pueden ser hasta 10 veces más grandes que los valores de varianza observados para la varianza horaria. El histograma muestra una moda (Mo) con una valor de 0.21 %, sin embargo, la asimetría tan marcada de la distribución hace que la media se sitúe en el -61 % y que la probabilidad de tener un error mayor que 50 % sea del 27.73 %. Los resultados mejoran considerablemente a una agregación 12-horaria con un valor de R^2 igual a 0.92 de promedio para todas las estaciones.

Los resultados obtenidos demuestran que las leyes de escala no parecen ser una herramienta suficientemente potente para salvar el rango de escalas que van desde las agregaciones temporales diarias a las horarias.

4.4.2.2. Comparación de los modelos B y RFB

En esta sección se comparan los resultados obtenidos mediante los modelos B y RFB descritos en la Sección 4.4.1 "Métodos". Las 735 estaciones con información horaria han sido utilizadas para ajustar y evaluar la capacidad predictiva de los métodos mediante la técnica de validación cruzada k-fold.

Los resultados presentados en la Tabla 4.3 muestran que el modelo RFB mejora las predicciones del modelo B en la mayoría de los climas para una agregación temporal horaria. Únicamente en los climas BWh y BSh, la predicción conseguida por el modelo B es mejor para la varianza horaria. Estos climas (BWh y BSh) corresponden a zonas desérticas y áridas donde los valores de TAS, en el conjunto de datos de validación, es mayor que en el de entrenamiento. En estos casos, el modelo B (basado en la técnica MARS) predice valores más elevados que los observados en el conjunto de datos de entrenamiento (extrapola), es por ello que en dichos climas (BWh y BSh) el modelo MARS obtiene mejores resultados que el modelo RF.

La limitada habilidad del modelo B para predecir el estadístico ACF-lag1 1-h se debe a que se calcula de manera indirecta mediante las ecuaciones 4.4.4 y 4.4.5, en lugar de ajustar un modelo de regresión específico como para el resto de estadísticos. Como se mencionó en la Sección 4.4.1.2, Beuchat et al. (2011) prefieren calcular dicho estadístico a partir de la varianza horaria y 2-horaria predicha.

TABLA 4.3: Resultados de coeficiente de determinación (R^2) calculados mediante la técnica de validación cruzada para la varianza, proporción de intervalos secos (Pdry), asimetría y coeficiente de autocorrelación para los modelos B y RFB. Las letras en negrita corresponde al mejor resultado para cada clima y estadístico. Las agregaciones 1-h y 12-h son analizadas en la tabla. Fuente: Tabla adaptada a partir del artículo Diez-Sierra y del Jesus (2019).

	Varianza Pdry					Α	simetr	a (Ske	w)	ACF-lag1						
	1	h	12	2 h	1	1 h 12 h		1 h		12	2 h	1 h		12 h		
	в	RFB	в	RFB	в	RFB	в	RFB	в	RFB	в	RFB	в	RFB	в	RFB
BWh	0.79	0.65	0.96	0.96	0.84	0.89	0.99	0.99	0.59	0.62	0.91	0.91	-0.13	0.40	-12.16	0.04
BWk	0.65	0.72	0.98	0.98	0.53	0.75	0.98	0.98	0.62	0.68	0.94	0.93	-0.54	0.00	-52.59	0.32
\mathbf{BSh}	0.73	0.63	0.96	0.96	0.92	0.94	0.99	0.99	0.69	0.65	0.91	0.92	-0.68	0.33	-7.89	0.34
\mathbf{BSk}	0.72	0.75	0.97	0.97	0.92	0.93	0.99	0.99	0.65	0.65	0.93	0.93	0.14	0.49	-13.83	0.38
\mathbf{Csa}	0.80	0.81	0.98	0.98	0.92	0.94	0.98	0.99	0.73	0.74	0.92	0.92	0.26	0.57	-11.51	0.53
\mathbf{Csb}	0.84	0.85	0.99	0.99	0.93	0.97	0.98	0.99	0.65	0.65	0.92	0.91	0.14	0.67	-8.11	0.65
Cfa	0.61	0.70	0.95	0.94	0.79	0.84	0.97	0.97	0.37	0.42	0.87	0.87	0.27	0.63	-11.45	0.44
\mathbf{Cfb}	0.69	0.72	0.97	0.97	0.93	0.95	0.99	0.99	0.59	0.62	0.93	0.93	0.29	0.65	-7.16	0.57
D	0.66	0.77	0.94	0.97	0.73	0.69	0.92	0.88	-0.56	0.21	0.78	0.79	0.26	0.43	-13.77	0.03
Total	0.78	0.83	0.98	0.98	0.94	0.96	0.99	0.99	0.71	0.73	0.93	0.93	0.24	0.61	-9.74	0.56

Los resultados para los estadísticos varianza, Pdry y asimetría mejoran significativamente a medida que nos desplazamos a agregaciones temporales superiores (ver Tabla 4.3). De hecho, se obtienen valores de R^2 alrededor de 0.9 sistemáticamente para todos los climas y estadísticos para una agregación temporal de 12 horas (12-h). En el caso del estadístico ACF-lag1, el modelo se ve ligeramente deteriorado para agregaciones superiores.

La Tabla 4.4 muestra los predictores y los predictandos seleccionados para los modelos B y RFB, respectivamente. Es importante señalar que el modelo RFB incluye solo un subconjunto de los predictores utilizados originalmente en el trabajo realizado por Beuchat et al. (2011). Como se puede observar en la Tabla 4.3, incluso con esta reducción en el número de predictores, el modelo RFB mejora los resultados conseguidos con el modelo B para todos los estadísticos. Es por eso que hemos preferido eliminar aquellos predictores que explican un porcentaje insignificante de la varianza de nuestros datos para obtener un modelo más robusto y parsimonioso. Las variables que fueron seleccionadas finalmente, fueron aquellas que al ser eliminadas durante el proceso de ajuste degradaron significativamente el rendimiento del modelo. Finalmente, la temperatura superficial del aire (TAS) fue la única variable atmosférica de gran escala seleccionada como predictor, excepto para el estadístico ACF-lag1, donde la varianza de la temperatura superficial del aire (σ_{TAS}), la humedad relativa del aire (HUR) y la elevación, fueron también seleccionadas como predictores durante el proceso de ajuste.

4.4.2.3. Resultados obtenidos con el modelo RFB

La Figura 4.6 muestra los valores observados y predichos por el modelo RFB para la varianza, la proporción de intervalos secos (Pdry), el coeficiente de asimetría (skew) y

TABLA 4.4: Predictores utilizados (primera columna) por los modelos B y RFB (encabezado) para predecir los estadísticos subdiarios de precipitación. Los predictores son: precipitación media diaria (μ_{24}), varianza diaria (σ_{24}), proporción de días secos (ϕ_{24}), proporción de dos días secos (ϕ_{48}), asimetría diaria (γ_{24}), coeficiente de autocorrelación diaria lag-1 (ρ_{24}^1), probabilidad de dos días húmedos consecutivos (ϕ_{24}^{WW}), probabilidad de dos días secos consecutivos (ϕ_{24}^{DD}), promedio mensual de la temperatura superficial del aire (TAS), varianza de la temperatura superficial del aire (σ_{TAS}), humedad relativa del aire (HUR) y elevación. Los predictandos son: varianza (σ_T), proporción de intervalos secos (ϕ_T), asimetría (γ_T), coeficiente de autocorrelación temporal lag-1 (ρ_T^1), probabilidad de dos intervalos húmedos consecutivos (ϕ_T^{WW}) y la probabilidad de dos intervalos secos consecutivos (ϕ_T^{DD}) para las agregaciones temporales T=[1-h, 2-h, 3-h, 6-h, 12-h]. Las celdas con color indican que esa variable ha sido utilizada como predictor para predecir un predictando determinado. El color rojo hace referencia al modelo B y el color verde hace referencia al modelo RFB. Fuente: Figura adaptada a partir del artículo Diez-Sierra y del Jesus (2019).



la autocorrelación lag-1 (ACF-lag1) para una agregación temporal horaria. Los valores de R^2 para cada uno de los climas están disponibles en la Tabla 4.3.

Como podemos observar, los resultados obtenidos para la varianza y para el estadístico Pdry fueron muy satisfactorios para todas las agregaciones temporales. Los resultados de R^2 , promediados para todas las estaciones y climas, alcanzaron un valor de 0.83 y 0.96, respectivamente (ver Tabla 4.3). Para la asimetría (skew) y para el estadístico ACF-lag1, los resultados fueron menos precisos, con valores de R^2 de 0.73 y 0.61, respectivamente. Como podemos observar, las distribuciones de errores no presentan prácticamente ningún sesgo, y además, el mayor porcentaje de los errores se concentran en torno al cero para todos los estadísticos.

La elevada dispersión que muestran los valores observados de asimetría (con valores comprendidos entre 0 y 125), en comparación con el resto de estadísticos, hace que sea



BWII BWK BSII BSK CSa CSb Cla Clb D

Figura 4.6: Resultados del modelo RFB de desagregación para la varianza, proporción de intervalos secos (Pdry), coeficiente de asimetría (Skew) y autocorrelación lag-1 (ACF-lag1) para una agregación temporal horaria (1-h). La primera y la tercera columnas muestran los gráficos de dispersión entre los valores observados y los predichos. Los colores indican el tipo de clima. La línea negra discontinua corresponde al ajuste de regresión lineal. La segunda y la cuarta columnas muestran las distribución de errores relativos (%) a través de funciones de densidad no paramétricas, representadas mediante el método Kernel ($err = (Obs^2 - Pred^2)/Obs^2$). Fuente: Figura adaptada a partir del artículo Diez-Sierra y del Jesus (2019).

una variable más difícil de predecir; lo que explicaría en parte la perdida de precisión de los modelos. El modelo presenta grandes dificultades para predecir la asimetría en el clima D (ver Tabla 4.3) que se localiza áreas montañosas de gran altitud (>1000 m). Es probable que en dicho clima las condiciones atmosféricas locales no sean capturadas adecuadamente por las variables atmosféricas de gran escala (Hu et al., 2016). De hecho, cuando analizamos la variable TAS para el clima D vemos que no está correlacionada con la asimetría horaria, razón por la cual el modelo presenta mayores dificultades para predecir dicho estadístico.

Los resultados obtenidos de R^2 para el estadístico ACF-lag1, a una agregación temporal horaria, fueron significativamente peores que para los otros tres estadísticos. Como vemos en la Tabla 4.4, a diferencia de en el resto de estadísticos, la ACF-lag1 supradiaria no fue seleccionada como predictor para predecir la ACF-lag1 horaria. Es decir, el mismo estadístico a una agregación temporal superior no es escogida como una variable explicativa con suficiente peso en el caso del estadístico ACF-lag1. En contraste con lo que sucede con la asimetría, los peores resultados para la ACF-lag1 horaria fueron obtenidos para los climas BWh, BWk, BSh y BSk (climas desérticos y semiáridos). Estos climas aparecen en pequeñas áreas al sureste de las provincias de Almería, Murcia, Alicante, y en algunas zonas de las Islas Canarias. Dichas áreas se ven afectadas por tormentas convectivas muy intensas y presentan valores de ACF-lag1 horaria muy cercanos a 0 para muchos de los meses del año.

La falta de precisión a la hora de predecir el estadístico ACF-lag1, a una agregación horaria, nos obligó a explorar otra forma de capturar la estructura temporal de las series de precipitación. Por ese motivo hemos extendido el trabajo realizado por Beuchat et al. (2011) para predecir también las probabilidades de transición (de un intervalo seco a un intervalo seco, $\phi_{1h}^{DD},$ y de un intervalo húmedo a un intervalo húmedo, $\phi_{1h}^{WW})$ mediante la misma metodología seguida para el resto de estadísticos. La Figura 4.7 muestra el diagrama de dispersión y la distribución de errores para los estadísticos ϕ^{DD}_{1h} y ϕ_{1h}^{WW} , respectivamente. Como se puede observar, en el caso del estadístico ϕ_{1h}^{DD} la mayor parte de los resultados muestran un error menor del 1%, mientras que para el estadístic
o ϕ_{1h}^{WW} los errores pueden alcanzar el 50 %. Las estaciones localizadas en el interior y en el sur de la península presentan valores muy reducidos de ϕ_{1h}^{WW} , que a su vez presentan una variabilidad muy elevada dependiendo del periodo temporal analizado, lo que convierte a ϕ_{1h}^{WW} en un estadístico más difícil de predecir. No obstante, los valores obtenidos de R^2 para las probabilidades de transición (0.97 y 0.77 para la ϕ_{1h}^{DD} y la ϕ_{1h}^{WW} , respectivamente) fueron significativamente mejores que para el estadístico ACFlag
1(0.61),por lo que parece un enfoque más adecuado para capturar la dependencia temporal de las series de precipitación. La Tabla 4.5 muestra los valores de \mathbb{R}^2 para los estadísticos ϕ_{1h}^{DD} y ϕ_{1h}^{WW} y para las agregaciones de 1 hora y 12 horas. A diferencia de en el caso de la ACF-lag1, los resultados para las probabilidades de transición mejoraron a medida que se aumentó su agregación temporal.

Por último, como se mencionó en la Sección 4.4.1 "Métodos", se ha realizado un análisis de sensibilidad para evaluar el efecto de utilizar dos bases de datos de reanálisis con diferente resolución espacio-temporal. Las bases de datos CFSR, con una resolución espacial de 0.312° y temporal horaria, y la base de datos NCEP, con una resolución espacial de 2.5° y temporal mensual, fueron comparadas entre si. A pesar de utilizar datos con una mayor resolución espacial, los resultados no se vieron afectados significativamente. Lo que podría sugerir, o bien que las condiciones atmosféricas de gran escala (2.5°) son suficientes para explicar la relación existente entre los estadísticos de precipitación a una resolución diaria y subdiaria; o que CFSR, con una resolución espacial de 0.312° grados y temporal de una hora, no añade ningún tipo de información adicional.

También se ha llevado a cabo una serie de análisis adicionales para evaluar la robustez del método de regresión RFB. En el primero de ellos se analizó la sensibilidad del modelo al número de estaciones utilizadas durante el ajuste. Se comenzó seleccionando un número reducido de estaciones durante el proceso de ajuste y se fue incrementado poco a poco hasta llegar al máximo (las 735 estaciones), evaluando en cada momento el rendimiento general del modelo. Los resultados obtenidos muestran que cuando dicho número es superior al 25 % de las estaciones disponibles (alrededor de 200), los resultados convergieron en términos de R^2 , y solo se observaron cambios menores en la distribución de errores. En segundo lugar, todas las estaciones presentes en un clima concreto fueron eliminadas durante el proceso de ajuste para comprobar si la capacidad predictiva del modelo resultaba gravemente deteriorada. El proceso se repitió para cada tipo de clima. En este caso la capacidad predictiva del modelo sí se vio gravemente deteriorada, lo que indicaría que no es aconsejable utilizar el método RFB en regímenes climáticos no presentes en España.



Figura 4.7: Resultados del modelo RFB para predecir las probabilidades de transición $(\phi^{DD} \ y \ \phi^{WW})$ para un intervalo temporal de 1 hora (1-h) y 12 horas (12-h), respectivamente. Los resultados se presentan en el mismo formato que los de la Figura 4.6. Fuente: Figura adaptada a partir del artículo Diez-Sierra y del Jesus (2019).

Un punto importante a tener en cuenta es que no hemos sido capaces de obtener resultados tan buenos como los que obtiene Beuchat et al. (2011) en las 340 estaciones con información horaria localizadas en Suiza, Estados Unidos y Reino Unido. Esta pérdida en el rendimiento podría explicarse porque quizá Beuchat utiliza un conjunto de estaciones más homogéneas desde el punto de vista de sus estadísticos. Sin embargo, esto no parece tener mucho sentido ya que sus estaciones están mucho más dispersas en el globo que las nuestras y presentan regímenes climáticos que a priori podrían parecer más heterogéneos. Sin embargo, si analizamos estadísticamente las estaciones seleccionados en Beuchat et al. (2011), rara vez superaron valores de asimetría de 60; mientras que en España este valor es superado por un gran porcentaje de las estaciones. La fuerte

	ϕ^{2}	DD	ϕ^V	VW
	1 h	12 h	1 h	12 h
BWh	0.97	0.99	0.59	0.72
BWk	0.97	0.97	0.12	0.83
\mathbf{BSh}	0.96	0.98	0.59	0.85
\mathbf{BSk}	0.98	0.99	0.67	0.87
\mathbf{Csa}	0.97	0.99	0.75	0.86
\mathbf{Csb}	0.96	0.99	0.80	0.90
$\mathbf{C}\mathbf{f}\mathbf{a}$	0.87	0.97	0.73	0.79
\mathbf{Cfb}	0.95	0.98	0.8	0.90
D	0.61	0.93	0.04	0.20
Total	0.97	0.98	0.77	0.89

TABLA 4.5: Coeficiente de determinación (R^2) calculado mediante la técnica de validación cruzada 10-fold cross-validation para las probabilidades de transición a una resolución temporal horaria (1-h) y 12-horaria (12-h) mediante el modelo RFB. Fuente: Tabla adaptada a partir del artículo Diez-Sierra y del Jesus (2019).

variabilidad climática presente en el conjunto de datos seleccionados para España, así como la incorporación de regímenes de precipitación más extremos podría explicar la disminución en el rendimiento del modelo RFB.

4.4.2.4. Simulación sintética de precipitación

En esta sección hemos investigado si los generadores sintéticos Neyman-Scott Rectangular Pulse Model (NSRPM), ajustados con los estadísticos subdiarios de precipitación predichos mediante el modelo RFB (con el método de validación cruzada), pueden ser utilizados para generar series sintéticas horarias que simulen las observadas para cualquier localización de España con información diaria.

Para ello se han seleccionado 15 de las estaciones con un mayor número de datos disponibles, con la condición de que además cubriesen las diferentes áreas y climas de España (ver Figura 4.8).

La capacidad de los NSRPM se ha evaluado para reproducir las series observadas horarias bajo tres escenarios diferentes. El primero de ellos, "escenario exacto", corresponde a la situación en la que NSRPM es ajustado con los estadísticos diarios y subdiarios observados. Este escenario sería el idóneo y corresponde a aquel en el que se dispone de información horaria de precipitación en la zona de estudio. En el segundo escenario, "escenario objetivo", los estadísticos subdiaros observados fueron reemplazados por los estadísticos predichos por el modelo RFB. Por último, en el "escenario simple", el modelo NSRPM es ajustado únicamente con los estadísticos diarios de precipitación. Este último



Figura 4.8: Ubicación de las estaciones de precipitación horarias utilizadas para validar los modelos de generación sintéticas Neyman-Scott Rectangular Pulse Model (NSRPM). Fuente: Diez-Sierra y del Jesus (2019).

escenario sería el más habitual y es el que solemos encontrarnos cuando no se dispone de series horarias de precipitación en nuestra zona de estudio. En este último escenario el modelo NSRPM se utiliza como desagregador sin informarle de ninguna manera del comportamiento de los estadísticos a agregaciones temporales por debajo del día. Los tres escenarios propuestos permiten evaluar, por un lado, si las series simuladas con los NSRPM se ven deterioradas cuando los modelos son ajustados con los estadísticos predichos mediante el modelo RBF. Y por el otro, si dichas series reproducen mejor las observadas que aquellas simuladas bajo el "escenario simple".

TABLA 4.6: Conjunto de estadísticos utilizados para ajustar el modelo NSRPM y sus pesos asociados. Las letras d y h indican una agregación diaria y horaria, respectivamente. Fuente: Tabla adaptada a partir del artículo Diez-Sierra y del Jesus (2019).

	Media	Vari	ianza Ske		Skew		Pdry		Correlación Lag-1		ϕ^{DD}		ϕ^{WW}	
Escala temporal	1 d	1 h	1 d	1 h	1 d	1 h	1 d	1 h	1 d	1 h	1 d	1 h	1 d	
Pesos	5	4	2	3	2	3	2	3	2	3	2	4	2	

Ajustar el modelo NSRPM implica minimizar una función objetivo que integra una suma ponderada de estadísticas de lluvia a diferentes agregaciones temporales. La Tabla 4.6 muestra el conjunto de estadísticos de lluvia ajustados, así como los pesos asignados en el proceso de ajuste del modelo NSRPM. En el caso del "escenario simple", solo se utilizaron los estadísticas a una agregación temporal diaria (1-d). Se ha ajustado un único modelo NSRPM para cada estación (ver Figura 4.8) y para cada uno de los escenarios; excepto en el caso del "escenario simple" donde se han ajustado 10 modelos NSRPM diferentes para cada estación. Como en el "escenario simple" el modelo NSRPM únicamente es informado de los estadísticos a una agregación diaria, este pueden obtener resultados completamente diferentes a agregaciones inferiores dependiendo de los parámetros seleccionados como óptimos en el proceso de calibración. Para garantizar la estabilidad de los resultados se han simulado 1000 años continuos de lluvia sintética horaria para cada escenario y estación.

Las Figuras 4.9 y 4.10 muestran los estadísticos observados y simulados mediante los modelos NSRPM para una agregación temporal horaria y para los 12 meses de año. La Figura 4.9 muestra los estadísticos observados y simulados para los estadísticos varianza, proporción de intervalos secos (Pdry) y asimetría (Skew). La Figura 4.10 muestra los estadísticos observados y simulados para el estadístico ACF-lag1 y para las probabilidades de transición ϕ^{DD} , y ϕ^{WW} . El color negro corresponde al "escenario exacto"; la línea y los cuadrados negros representan, respectivamente, los estadísticos observadas y simulados por el modelo NSRPM para una agregación temporal horaria. El color rojo corresponde al "escenario objetivo"; la línea discontinua y los cuadrados rojos representan, respectivamente, los estadísticos horarios predichos por el modelo RFB y los simulados por el modelo NSRPM. El área sombreada en azul muestra el rango de estadísticos obtenidos para las 10 simulaciones del modelo NSRPM y para el "escenario simple". Cada fila corresponde a una de las 15 estaciones. No se muestran los resultados para la precipitación media ya que todos los modelos NSRPM fueron capaces de reproducirla correctamente.

Como podemos observar en las Figuras 4.9 y 4.10, las simulaciones realizados por el modelo NSRPM son suficientemente flexibles para simular los valores de varianza, Pdry y Skew a los que fueron calibrados; excepto en algunos casos específicos como en Almería en el mes de mayo (5) y Barcelona en el mes julio (6). En estos casos, los cuadrados (estadísticos calculados mediante las series simuladas por los NSRPM) se alejan significativamente de las líneas (estadísticos observadas y predichos). Los modelos NSRPM presentan mayores dificultades para simular los estadísticos calibrados en el caso de las probabilidades de transición y del estadístico ACF-lag1. El estadístico ϕ^{WW} , por ejemplo, no fue simulado correctamente por el modelo NSRPM durante varios meses en las estaciones situadas en Granada, Huesca y Barcelona. Aunque pueda parecer que los errores son muy elevados para el estadístico ϕ^{DD} , estos nunca superan un $\pm 2\%$ del valor observado.

Si comparamos los estadísticos observados (líneas negras) con los simulados por el "escenario objetivo" (cuadrados rojos) y con los obtenidos durante las simulaciones para el "escenario simple" (área sombreada en azul), podemos concluir que mediante la metodología propuesta aquí somos capaces de reproducir correctamente los estadísticos



Capítulo 4. Desagregación temporal de la precipitación en España

Figura 4.9: Rendimiento del modelo NSRPM para la varianza (var), proporción de intervalos secos (Pdry) y asimetría (Skew) a una agregación horaria. El color negro corresponde al "escenario exacto"; la línea y los cuadrados de ese mismo color representan, respectivamente, los estadísticos observados y simulados por el modelo NSRPM a una agregación horaria. El color rojo corresponde al "escenario objetivo"; la línea discontinua y los cuadrados de ese mismo color representan, respectivamente, los estadísticos horarios predichos por el modelo RFB y simuladas mediante el modelo NSRPM. El área sombreada en azul muestra el rango de estadísticos obtenido para las 10 simulaciones por modelo NSRPM para el "escenario simple". Cada fila corresponde a una de las 15 estaciones. Fuente: Diez-Sierra y del Jesus (2019).



Figura 4.10: Los resultados se presentan en el mismo formato que los de la Figura 4.9 pero para los estadísticos: autocorrelación temporal lag=1 (ACF-lag1), y probabilidades de transición (ϕ^{DD} y ϕ^{WW}) a una agregación horaria. Fuente: Diez-Sierra y del Jesus (2019).



Figura 4.11: Curvas de intensidad-frecuencia empíricas derivadas de las series de precipitación observadas y simuladas mediante el modelo NSRPM a una agregación horaria. Los puntos negros corresponde a la probabilidad de excedencia de la serie de lluvia observada. Las líneas negras y rojas corresponden a la probabilidad de excedencia para las series sintéticas simuladas por el modelo NSRPM para el "escenario exacto" y para "escenario objetivo", respectivamente. El área de color azul representa el rango de valores de probabilidad de excedencia para las 10 simulaciones para el "escenario simple". Cada panel corresponde a una de las 15 estaciones de precipitación seleccionadas.

Fuente: Figura adaptada a partir del artículo Diez-Sierra y del Jesus (2019).

observados en la mayoría de las estaciones. No sucede lo mismo con el "escenario simple", donde las series simuladas subestiman en gran medida los valores de varianza y asimetría (Skew) observados para la mayoría de estaciones (León, Albacete, Zaragoza, Huesca, Baleares, Cantabria); lo que, como veremos más adelante, tendrá un efecto muy importante sobre los eventos más extremos de precipitación (ver Figura 4.11). El valor de Pdry observado también es subestimado por el "escenario simple" para la mayoría de las estaciones. Además, los resultados para cada una de las 10 calibraciones muestra una gran dispersión. Esto se debe a la libertad de la que dispone el modelo NSRPM durante el proceso de calibración cuando es ajustado únicamente con información diaria de precipitación. En estos casos, es más sencillo que el modelo encuentre soluciones con un número menor de tormentas (λ) y con una mayor duración (β), lo que conduce a series con valores más elevados de ACF-lag1 y ϕ^{WW} que los observados.

También encontramos resultados muy interesantes cuando comparamos las curvas empíricas de intensidad-frecuencia derivadas de las series observados y simuladas para los diferentes escenarios (ver Figura 4.11). Los puntos negros representan la probabilidad de excedencia de las series de precipitación observadas (mm/hora). Las líneas negras y rojas corresponden a la probabilidad de excedencia para el "escenario exacto" y el "escenario objetivo", respectivamente. El área de color azul representa el rango de resultados obtenidos para las 10 simulaciones realizadas por el modelo NSRPM para el "escenario simple". Cada panel corresponde a una de las 15 estaciones de precipitación analizadas.

En la Figura 4.11 podemos observar que los resultados obtenidos por el "escenario exacto" reproducen adecuadamente los valores observados. Lo mismo ocurre con el "escenario objetivo", excepto en Barcelona y Mallorca, donde los valores con una probabilidad de excedencia inferior a $0.001 \% (10^{-5})$ son ligeramente subestimados. A diferencia de lo que sucede con el "escenario exacto" y con el "escenario objetivo", las series simulados por el "escenario simple" no reproducen los valores de probabilidad de excedencia observada en la mayoría de los casos analizados. Los resultados promediados para las 10 calibraciones subestiman los valores observados en la mayoría de estaciones excepto en aquellas localizadas en Málaga y La Coruña. De hecho, si observamos el valor máximo simulado para el "escenario simple", este rara vez supera el valor máximo observado. Lo que parece muy poco probable teniendo en cuenta que las series observadas presentan de media una longitud temporal de 20 años y las series simuladas de 1000.

4.4.2.5. Base de datos de estadísticos de precipitación para el clima presente

Una vez validada la metodología en un número significativo de estaciones distribuidas a lo largo del territorio español, se ha querido extender el trabajo a todas aquellas estaciones con información diaria (en total 2896 estaciones). El objetivo es predecir los estadísticos subdiarios de precipitación en las estaciones con información diaria disponibles utilizando para ello el modelo RFB (presentado en la Sección 4.4.1 "Métodos") ajustado con todas las estaciones con información horaria. De esta manera se ha generado una base de datos de estadísticos de lluvia subdiaria y supradiaria en todas aquellas estaciones que resultan de la combinación de las estaciones diarias (d) con las horarias (h), como se muestra en el esquema metodológico de la Figura 4.12. Estos resultados son de gran utilidad para diferentes propósitos, como por ejemplo, para calibrar bases de datos de reanálisis o de satélite a una resolución temporal horaria, así como para ajustar generadores sintéticos de lluvia horaria como vimos en el apartado anterior.

La base de datos contiene para cada estación: las coordenadas geográficas referidas al elipsoide WGS84, la elevación y los estadísticos de precipitación para cada mes del año. Los estadísticos de precipitación incluidos en la base de datos son: la precipitación media (μ), la varianza (σ), la asimetría (γ), la proporción de intervalos secos (ϕ), la autocorrelación lag-1 (ρ) y las probabilidades de transición, de intervalos seco-seco y húmedo-húmedo (ϕ^{DD} y ϕ^{WW}) para las agregaciones temporales T=[1-h, 2-h, 3-h, 6-h, 12-h, 1-d, 2-d y 3-d]. Cada estación dispondrá por lo tanto de un total 591 valores que resultan de la combinación de la localización, elevación y estadísticos a las diferentes agregaciones temporales T.

Hay que tener en cuenta que la presencia de tendencias climáticas así como la propia variabilidad natural del clima puede hacer que los estadísticos de precipitación no sean estacionarios en el tiempo. Como estos estadísticos pueden variar de un período de referencia a otro, se han considerado tres períodos para la generación de la base de datos: 1976-1995, 1986-2005 y 1996-2015. Los períodos 1976-1995 y 1996-2015 corresponden a un período pasado y presente, respectivamente, mientras que el período 1986-2005 se usa normalmente como un período de referencia para estudios de cambio climático. Se han generado, por lo tanto, tres productos diferentes que resultan de aplicar la metodología para cada uno de los periodos. Únicamente aquellas estaciones con al menos 10 años completos para cada uno los periodos fueron consideradas. El número total de estaciones para los diferentes periodos de referencia es: 2771 (2771 diarias más 0 horarias) para el período 1976-1995, 2425 (2327 diarias más 98 horarias) para el período 1986-2005 y 2176 (1716 diarias más 460 horarias) para el período 1996-2015.

La Figuras 4.13 y 4.14 muestran un ejemplo de los estadísticos horarios predichos para el periodo 1986-2005 para los meses de enero y julio, respectivamente. Como se puede observar, gracias a la metodología que hemos aplicado, dispondríamos de información horaria homogéneamente distribuida a lo largo de todo el territorio español. Únicamente en algún área de la zona central de la península Ibérica y en la isla de Lanzarote, en las Islas Canarias, existe una densidad de estaciones algo menor.



Figura 4.12: Esquema metodológico seguido para generar la base de datos de estadísticos de precipitación en España. Primero se construye una base de datos de precipitación que combina las series originales diarias con las horarias agregadas a una resolución diaria. La base de datos horaria original, junto con la información atmosférica, será utilizada para calibrar el modelo RFB y extender la metodología a todas las estaciones con información diaria disponibles. Los estadísticos a una agregación diaria o supradiaria son calculados directamente mediante las series instrumentales.


Figura 4.13: Estadísticos horarios (1-h) predichos para el mes de enero mediante el modelo RFB para las estaciones diarias y horarias disponibles para el periodo 1986-2005.



Figura 4.14: Estadísticos horarios (1-h) predichos para el mes de julio mediante el modelo RFB para las estaciones diarias y horarias disponibles para el periodo 1986-2005.

Se puede observar también, en las Figuras 4.13 y 4.14, la alta variabilidad espacial y temporal de los diferentes estadísticos que comprenden la base de datos de precipitación para el clima presente. Los valores para la precipitación media diaria durante el mes de enero son inferiores a 1 mm diario para la costa mediterránea oriental, y son superiores a los 6 y 7 mm diarios en el norte de la península (Costa Cantábrica y Galicia). Mientras que por el contrario, para el mes de julio, los valores de precipitación raramente superan los 2 mm diarios en todo el territorio. Si nos fijamos en los valores de varianza horaria para el mes de enero podemos distinguir claramente algunos de los principales sistemas montañosos de España. Los valores más elevados de varianza aparecen en los Picos de Europa, Sistema Central, Sistema Ibérico y parte de los Pirineos. También se aprecian valores más elevados de varianza para algunas zonas del Mediterráneo y para la cuenca del Ebro en el mes de julio. Los valores de asimetría (skew) muestran un patrón espacial muy claro entre el norte y el sur de la península para el mes de julio. Los valores de asimetría (skew) son más elevados en la costa sur y este que en el norte de la Península. También podemos apreciar un patrón espacial muy claro en el mes de enero para la proporción de intervalos secos (Pdry). El valor de Pdry en el norte de la península (Costa Cantábrica) presenta valores inferiores al 75% en algunas estaciones situadas en la costa Gallega para el mes de enero; mientras que en la costa este del Mediterráneo y las Isla Canarias alcanza valores muy cercanos al 100%. Por último, si analizamos el patrón espacial y temporal de las probabilidades de transición (ϕ^{DD} y ϕ^{WW}), vemos que las tormentas son más persistentes en el mes de enero, en la Costa Cantábrica, y en general a medida que nos acercamos al océano Atlántico como efecto de las borrascas Atlánticas (lluvia frontal). También podemos observar, que como resultado de la lluvia orográfica, los principales sistemas montañosos presentan valores más elevados de ϕ^{WW} .

4.4.3. Conclusiones

Se ha presentado una metodología para generar series sintéticas de precipitación horarias en aquellos lugares de España donde solo se dispone de información diaria. Dicha metodología ha sido validada en más de 700 estaciones con registros instrumentales horarios homogéneamente distribuidos a lo largo del territorio español. El objetivo de la metodología es predecir diferentes estadísticos de precipitación a agregaciones temporales por debajo del día, usando como predictores los mismos estadísticos a una agregación diaria y variables atmosféricas. La metodología ha sido validada en todo el territorio mediante validación cruzada. Los estadísticos predichos son: varianza (σ), asimetría (γ), proporción de intervalos secos (ϕ), autocorrelación lag-1 (ρ) y probabilidad de transición de intervalos (ϕ^{DD} y ϕ^{WW}) para las agregaciones temporales de 1, 2, 3, 6 y 12 horas.

Se han propuesto algunos cambios con respecto al modelo presentado en Beuchat et al. (2011) que dieron como resultado las siguientes mejoras: (1) el uso de modelos de regresión basados en la técnica RF da como resultado distribuciones de errores menos sesgadas y valores más elevados de R^2 ; (2) se ha reducido el número de predictores al mínimo, evitando sobreajustar los modelos y limitando la incertidumbre de mismos en el caso en el que fueran utilizados para otras aplicaciones (como por ejemplo en estudios de cambio climático); (3) se ha propuesto otra manera de calcular la autocorrelación lag-1 que mejora significativamente los resultados predichos con respecto a la metodología original; (4) se ha ampliado el trabajo a las probabilidades de transición, las cuales pueden utilizarse también para caracterizar la dependencia temporal de las series de precipitación. La mayor capacidad predictiva de los algoritmos de aprendizaje automatizado hace que sean preferibles a métodos más tradicionales como MARS. Sin embargo, hay que tener mucha cautela cuando se utilice el modelo RF para extrapolar fuera del rango climático para el que se calibró.

Se han seleccionado 15 estaciones distribuidas a lo largo de diferentes regímenes climáticos de España para demostrar que mediante la metodología propuesta en la presente tesis somos capaces de simular series sintéticas horarias que reproducen los estadísticos de las series observadas. Los resultados obtenidos muestran que las series simuladas con los estadísticos predichos mediante el modelo RFB ("escenario objetivo") reproducen significativamente mejor los estadísticos horarios observados que aquellas simuladas mediante los modelos ajustados únicamente con estadísticos diarios ("escenario simple"). Las series simuladas con el modelo NSRPM, cuando este es calibrado únicamente mediante datos diarios, subestiman en gran medida la varianza, la asimetría y el Pdry horario (1-h) observado; y sobrestiman los valores observados de ACF-lag1 y ϕ^{WW} . Lo cual tiene un impacto directo sobre los valores más extremos de precipitación. Hay que tener en cuenta que cuando los modelos NSRPM son ajustados únicamente con información diaria, estos pueden encontrar infinitas soluciones a agregaciones por debajo del día. Lo que puede resultar en series que son completamente diferentes, desde un punto de vista estadístico, a dichas agregaciones.

Los resultados están restringidos a aplicaciones puntuales (es decir, a pequeñas cuencas). Sin embargo, el modelo NSRPM podría extenderse fácilmente para incorporar la dimensión espacial. Únicamente habría que introducir el término de la correlación espacial durante el proceso de ajuste. Este modelo, ampliado en el espacio, se conoce como STNSRP (*Spatial Temporal Neyman-Scott Rectangular Pulses*), y permite simular series de precipitaciones horarias en zonas no instrumentadas únicamente mediante la predicción del parámetro de escala (ξ); para lo que se utilizan variables geográficas para mejorar la predicción (por ejemplo, la elevación).

Los resultados obtenidos en la presente sección pueden ser de especial interés para el estudio de eventos extremos de precipitación, para desagregar series diaria de precipitación, para calibrar y validar modelos numéricos a una resolución horaria, y también, como se ha demostrado, para generar series sintéticas de precipitación que capturan adecuadamente la estructura de la lluvia, a una resolución horaria, en aquellas zonas de España donde únicamente existen registros diarios.

4.5. Desagregación temporal de la precipitación en España en un contexto de cambio climático

En la Sección 4.4 "Desagregación temporal de la precipitación en España para el clima presente", se ha presentado una metodología para predecir estadísticos subdiarios de precipitación en cualquier localización de España con información diaria mediante el método *Random Forests*. La metodología ha servido para generar una base de datos de estadísticos subdiarios y supradiarios de precipitación en aproximadamente 2500 estaciones homogéneamente distribuidas a lo largo del territorio español. Los resultados fueron validados en diferentes puntos de España con el propósito de alimentar a generadores sintéticos (NSRPM) y simular series horarias de miles de años que reproducen los estadísticos observados.

El objetivo de la presente sección es actualizar los resultados obtenidos en la Sección 4.4 para el clima futuro, utilizando para ello los resultados de los modelos climáticos regionales (RCMs) de las bases de datos de EURO-CORDEX y de AFR-CORDEX. Los escenarios RCP 4.5 y RCP 8.5 serán analizados. Los resultados obtenidos en la presente sección servirán para simular series sintéticas horarias de miles de años de precipitación para diferentes escenarios de cambio climático en cualquier estación que disponga de registros diarios. Además, se analizará también la magnitud y la significancia del cambio en los estadísticos de precipitación a una agregación horaria (1-h) y diaria (1-d) para el clima futuro respecto al presente, y se demostrará la influencia de la temperatura superficial de aire (TAS) sobre dichos estadísticos. Los resultados obtenidos demuestran la importancia de analizar los efectos del cambio climático a agregaciones temporales por debajo del día en aquellas áreas que presentan regímenes de precipitación con una elevada torrencialidad, como sucede en España, donde los eventos más intensos de precipitación pueden descargan grandes cantidades de agua en pocas horas (Diez-Sierra y del Jesus, 2017; Martin-Vide, 2004; Meseguer-Ruiz et al., 2017).

4.5.1. Métodos

La metodología se puede dividir de la siguiente manera. En primer lugar, se establece como base de datos de referencia para el clima presente, la base de datos de estadísticos de precipitación generada en el apartado 4.4.2.5 para el periodo 1986-2005. En segundo lugar, el método delta, basado en factores de cambio, propuesto por Burton et al. (2010), será utilizado para calcular el cambio relativo entre el clima presente y el clima futuro para los diferentes modelos y escenarios analizados a una agregación supradiaria (ver Figura 4.1). Los factores de cambio serán calculados para todos los estadísticos de precipitación y variables atmosféricas de reanálisis que conforman los predictores del modelo RFB (ver Tabla 4.4). En tercer lugar, los factores de cambio, o deltas, serán utilizados con el fin de actualizar los estadísticos calculados a partir de las series observadas para el clima presente y para los diferentes escenarios de cambio climático. Nuevamente, con el modelo RFB ajustado mediante la metodología propuesta en la Sección 4.4.1.3, pero en este caso incorporando los predictores actualizados mediante el método delta, se predecirán los estadísticos de precipitación subdiarios para el futuro. El análisis se ha repetido para 3 periodos diferentes del siglo XXI: 2016-2035 o periodo de corto plazo, 2046-2065 o de medio plazo y 2081-2100 o periodo de largo plazo.



Figura 4.15: Esquema metodológico seguido para generar la base de datos de estadísticos de precipitación en España para el clima futuro. La metodología es muy simular a la utilizada para el periodo presente (ver Sección 4.4.2.5), con la única diferencia de que en este caso los predictores utilizados en el método RFB para predecir lo estadísticos subdiarios de precipitación, fueron previamente actualizados para los diferentes escenarios de cambio climático mediante el método delta de corrección de sesgo.

La Figura 4.15 muestra el esquema metodológico seguido para generar la base de datos de estadísticos de precipitación en España para el clima futuro. Como podemos apreciar, la metodología es muy similar que aquella presentada en la Sección 4.4.2.5 (ver Figura 4.2), con la única diferencia de que en este caso los estadísticos de lluvia diarios y la variable TAS mensual son actualizados para los diferentes escenarios de cambio climático futuros.

Hay que tener en cuenta que muchos de los GCMs y RCMs no ofrecen resultados por debajo de una resolución 3-horaria. Además, los modelos climáticos no son, a día de hoy, capaces de capturar los procesos convectivos de menor escala que tienen lugar en pocas horas. Es por ello que los autores han creído más acertado prescindir de la información subdiaria de precipitación que ofrecen los modelos y en su lugar calcularla de manera indirecta mediante la misma metodología presentada en la Sección 4.4.

Los aspectos más técnicos de la metodología serán descritos en detalle a continuación.

4.5.1.1. Método delta de cambio

Los estadísticos de lluvia derivados de las series observadas para el periodo de referencia y para los diferentes RCMs, durante el siglo XXI, son combinados para obtener un conjunto de estadísticas de lluvia para cada mes del calendario (Burton et al., 2010). El método de corrección de sesgo utilizado para actualizar los estadísticos de precipitación para el clima futuro se basa en el enfoque delta o factores de cambio (Prudhomme y Nick Reynard, 2002). El método delta asume que los cambios en los estadísticos de precipitación sobre las series observadas para el clima futuro, son proporcionales a los cambios en los estadísticos de precipitación simulados por los RCMs.

Los factores de cambios, $\alpha_{s,m}^{RCM}$, Eq. 4.5.7, fueron calculados para cada estadístico (predictores mostrados en la Tabla 4.7), s, y para cada RCM (ver Tabla 4.2), entre el período de control (Con) y los diferentes periodos futuros (Fut) para cada mes calendario, m. Para cada estación pluviométrica se seleccionó la serie temporal de cada modelo RCM correspondientes a la celda de la malla CORDEX más cercana a la localización de la estación. El período de control (Con) se refiere al período 1986-2005, mientras que los período de referencia futuros (Fut) corresponden a los períodos 2016-2035 (corto-plazo), 2046-2065 (medio-plazo) y 2081-2100 (largo-plazo). Para cada estación y estadístico se obtendrá un vector de factores de cambio que son derivados de la combinación del total de modelos RCMs (n_{RCM}), períodos futuros (n_{Fut}) y RCPs (n_{RCPs}). En nuestro caso n_{RCM} toma el valor de 11 para las estaciones ubicados en la Península Ibérica y las Islas Baleares, y 10 para las estaciones ubicadas en las Islas Canarias. n_{Fut} y n_{RCPs} toman un valor de 3 y 2, respectivamente, para todas las estaciones.

Debido a que los estadísticos ϕ , ϕ^{DD} y ϕ^{WW} solo pueden tomar valores en un rango limitado (de 0 a 1); antes de calcular los factor de cambio para dichos estadísticos fueron transformados aplicando la transformación invertible de la ecuación 4.5.8 (Burton et al., 2010). Y y X representan el valor transformado y original para ϕ , ϕ^{DD} y ϕ^{WW} , respectivamente.

$$\alpha_{s,m}^{RCM} = \frac{s_{Fut,m}^{RCM}}{s_{Con,m}^{RCM}} \tag{4.5.7}$$

$$Y = \frac{X}{1 - X} \tag{4.5.8}$$

La ventaja de la técnica de corrección delta sobre otras, como la de escalado lineal o la técnicas de mapeo de cuantiles (Burton et al., 2010; Fang et al., 2015), es que con esta técnica se puede corregir no solo los momentos de primer y segundo orden de las series de precipitación, sino también otros estadísticos que afectan al comportamiento temporal de las series de precipitación, como por ejemplo las probabilidades de transición (Cowpertwait et al., 1996a; Maraun et al., 2016).

4.5.1.2. Base de datos de estadísticos de precipitaciones en España para el clima futuro

Se ha utilizado la misma metodología propuesta en la Sección 4.4.2.5 para generar la base de datos de estadísticos de precipitación para los diferentes escenarios de cambio climático futuro.

El método RFB, ajustado en el periodo histórico mediante toda la información instrumental horaria disponible (ver Sección 4.4.1.3), ha sido utilizado para predecir los estadísticos subdiarios de precipitación para los diferentes escenarios de cambio climático. Para ello, los predictores (estadísticos diarios de precipitación y variables atmosféricas de reanálisis a una resolución mensual) fueron actualizados previamente mediante el método delta para todos lo RCMs de la Tabla 4.2, y para todos los escenarios (RCP 4.5 y 8.5) y periodos (2016-2035, 2046-2065 y 2081-2100).

La única diferencia con respecto a la metodología propuesta para el clima presente, es que aquí, no hemos incluido el estadístico autocorrelación temporal (ρ) en el análisis. Este cambio permite eliminar los predictores HUR y σ_{TAS} del análisis y reducir la incertidumbre de los resultados. Además como se comentó anteriormente, en vez del estadístico ρ , pueden utilizarse en su defecto las probabilidades de transición para informar de la estructura temporal de la precipitación a los modelos NSRPM (Cowpertwait et al., 1996a). La temperatura superficial del aire (TAS) será por lo tanto la única variable atmosférica de gran escala utilizada como predictor en la presente sección.

La Tabla 4.7 muestra los predictores y predictandos utilizados para desagregar los estadísticos de precipitación para el clima futuro. Como se puede apreciar en la Tabla 4.7, únicamente se ha utilizado la variable TAS como predictor atmosférico. TABLA 4.7: Predictores utilizados (primera columna) por el modelo RFB para la predecir la precipitación subdiaria para el clima futuro. Los predictores son: precipitación media diaria (μ_{24}), varianza diaria (σ_{24}), proporción de días secos (ϕ_{24}), proporción de dos días secos (ϕ_{48}), asimetría diaria (γ_{24}), probabilidad de dos días húmedos consecutivos (ϕ_{24}^{WW}), probabilidad de dos días secos consecutivos (ϕ_{24}^{DD}), promedio mensual de la temperatura superficial del aire (TAS). Los predictandos son: varianza (σ_T), proporción de intervalos secos (ϕ_T), asimetría (γ_T), probabilidad de dos intervalos húmedos adyacentes (ϕ_T^{WW}) y la probabilidad de dos intervalos secos adyacentes (ϕ_T^{DD}) para las agregaciones temporales T=[1-h, 2-h, 3-h, 6-h, 12-h]. Las celdas sombreadas indican que la variable ha sido utilizada como predictor para predecir un estadístico determinado.

	Predictandos							
Predictores	$(T \in \{1, 2, 3, 6, 12\})$							
	σ_T	ϕ_T	γ_T	ϕ_T^{WW}	ϕ_T^{DD}			
μ_{24}								
σ_{24}								
ϕ_{24}								
γ_{24}								
ϕ^{WW}_{24}								
ϕ_{24}^{DD}								
TAS								

La base de datos de precipitación para el clima futuro tiene el mismo formato que para el clima presente (1986-2005). Para cada estación contiene: las coordenadas geográficas referidas al elipsoide WGS84, la elevación y los estadísticos de precipitación para cada mes del año. Los estadísticos de precipitación son: la precipitación media (μ), la varianza (σ), la asimetría (γ), la proporción de intervalos secos (ϕ) y las probabilidades de transición, de intervalos seco-seco y húmedo-húmedo (ϕ^{DD} y ϕ^{WW}), para las agregaciones temporales T=[1-h, 2-h, 3-h, 6-h, 12-h, 1-d, 2-d y 3-d].

La base de datos completa para el clima presente y futuro se compone de 127 ficheros, un único archivo para representar el clima presente para el período 1986-2005, y 126 archivos que proceden de la combinación de los 3 periodos futuros analizados (2016-2035, 2046-2065 y 2081-2100), los 2 RCPs (4.5 y 8.5) y los 21 RCMs (ver Tabla 4.2). Esta base de datos esta disponible para fines de investigación en Diez-Sierra y del Jesus (2019B2).

4.5.1.3. Análisis de incertidumbre

El método delta permite estimar la magnitud del cambio para cada estadístico y para cada modelo (RCM) por separado. Sin embargo, además de la magnitud en el cambio es esencial identificar si dicho cambio es o no significativo; es decir, si existe un acuerdo en la magnitud y el sentido de cambio entre los modelos para un escenario y un periodo concreto. El método Sgl (*Signal to noise ratio* en inglés) ha sido utilizado para evaluar la robustez en el cambio para todos los modelos (RCMs) al mismo tiempo (Jiang et al., 2015). Su formulación es la siguiente:

$$Sgl = \frac{|\overline{x}|}{STD} = \frac{|\overline{x}|}{\sqrt{\frac{1}{n-1}\sum_{i=1}^{n}(x_i - \overline{x})^2}},$$
(4.5.9)

donde x_i denota la simulación, i-ésima, de un modelo en particular; \overline{x} corresponde a la media del conjunto de los múltiples modelos (MME), y *n* corresponde a número de modelos utilizados. En este caso el término MME fue calculado asignando el mismo peso a cada uno de los modelos. Se ha asumido que el cambio proyectado es creíble (significante o robusto) si el valor de Sgl es mayor que 1 o menor que -1 (Tian et al., 2015). La robustez de los cambios ha sido evaluada para cada estadístico, mes del calendario, período futuro y RCP por separado.

4.5.2. Resultados

En esta sección se analizan los resultados de cambio climático en los estadísticos de precipitación desde tres enfoques diferentes. En primer lugar se investigará la magnitud del cambio en los estadísticos para todas las estaciones disponibles en España al mismo tiempo. Para ello analizaremos la forma de las distribuciones para cada uno de los estadísticos, tanto para el clima presente como para los diferentes escenarios para el futuro. En segundo lugar se analizará la significancia en el cambio mediante el método Sgl. En este caso los resultados se muestran por separado para cada uno de los principales tipos de climas presentes en España (ver Figura 4.1). En tercer y último lugar, analizaremos el efecto de la temperatura superficial del aire (TAS) sobre los eventos extremos de precipitación. Además, en este último apartado, se establecerá una relación entre las TAS, la varianza horaria y el percentil del 99% para la precipitación horaria.

4.5.2.1. Cambio en los estadísticos de precipitación

Las Figuras 4.16 y 4.17 muestran las funciones de densidad no paramétricas, calculadas mediante el método Kernel, para los 6 estadísticos de precipitación analizados para el clima presente (línea negra discontinua) y para los escenarios RCP 4.5 (línea verde continua) y RCP 8.5 (línea roja continua) a una agregación temporal diaria y horaria, respectivamente. Cada función de densidad, calculada mediante el método Kernel, corresponde a los valores de los estadísticos de precipitación para las 2636 (2176 estaciones diarias + 460 horarias) estaciones, calculados de manera independiente para cada mes del año y para cada RCMs (ver Tabla 4.2). Cada columna corresponde a un periodo



Figura 4.16: Los paneles muestran las distribuciones de los estadísticos de precipitación para el clima presente (línea negra discontinua) y para los escenarios RCP 4.5 (línea verde continua) y RCP 8.5 (línea roja continua) a una agregación temporal diaria. Cada una de las funciones densidad, representadas mediante el método Kernel, corresponde a los valores de los estadísticos de precipitación para todas las estaciones (horarias y diarias) calculados de manera independiente para cada mes del año y para todos los RCMs incluidos en la Tabla 4.2. Cada columna corresponde al periodo horizonte de corto-plazo (2016-2035), de medio-plazo (2046-2065) y de largo plazo (2081-2100), respectivamente, y cada fila corresponde a los estadísticos de precipitación: media (μ), varianza (σ), asimetría (γ), proporción de intervalos secos (Pdry) y probabilidades de transición (ϕ^{DD} y ϕ^{WW}). La línea negra discontinua corresponde a la distribución para el clima presente 1986-2005.



 $\label{eq:Figura 4.17: Los resultados se presentan en el mismo formato que los de la Figura 4.16 pero para una agregación temporal horaria.$



Figura 4.18: Varianza horaria (σ_{1-h}) para los cuantiles superiores al percentil 80. La línea negra discontinua corresponde al clima presente (1986-2005), mientras que las líneas de color verde y rojo corresponden a los escenarios RCP 4.5 y RCP 8.5, respectivamente.

horizonte y cada fila a cada uno de los 6 estadísticos analizados: media (μ), varianza (σ), asimetría (γ), proporción de intervalos secos (Pdry) y probabilidades de transición (ϕ^{DD} y ϕ^{WW}). Los resultados a una agregación diaria fueron obtenidos directamente aplicando el método delta (Figura 4.16). Por el contrario, los estadísticos subdiarios (ver Figura 4.17) fueron obtenidos aplicando las relaciones de regresión, calculadas para el clima presente (Diez-Sierra y del Jesus, 2019), actualizando primero los predictores de la Tabla 4.7 para el futuro.

Como se puede apreciar en la Figura 4.16, según los resultados obtenidos es esperable que la precipitación media (μ) se reduzca considerablemente tanto para el periodo de medio plazo como para el de largo plazo, siendo dicha reducción mucho más intensa para el escenario RCP 8.5 que para el RCP 4.5. Para el periodo de corto plazo, que corresponde al periodo 2016-2035, el cambio es prácticamente inapreciable. La forma de las funciones de densidad, calculadas mediante el método Kernel, para la precipitación media muestran que el número de estaciones con una intensidad de lluvia comprendida entre 0 y 1 mm/día aumentará significativamente respecto al clima actual; lo que podría indicar que una parte importante de las estaciones podrían migrar hacia climas áridos (BWh y BWk) y semiáridos (BSk y BSh) como consecuencia del aumento de la TAS. Como es lógico los mismos resultados has sido obtenidos para la precipitación media a una agregación horaria (4.17).

En el caso de la varianza diaria (ver Figura 4.16), es esperable que el número de estaciones con valores por encima de los $100 \text{ mm}^2/\text{d}^2$ y por debajo de los $4 \text{ mm}^2/\text{d}^2$ aumente para ambos RCPs y para los periodos de medio y largo plazo de manera similar. Para la

varianza horaria (ver Figura 4.17), las distribuciones de Kernel para los dos RCPs y para los tres periodos parecen desplazarse hacia valores inferiores, lo que indicaría una reducción en la varianza horaria para el clima futuro. Sin embargo, si analizamos los cuantiles para la varianza horaria (σ_{1-h}) para los valores más elevados de la distribución (por encima del percentil 80) y para el periodo de largo plazo (ver Figura 4.18), vemos que para un mismo percentil los valores de varianza horaria son mayores para los escenarios RCP 4.5 y RCP 8.5. Esto indicaría que aquellas estaciones con valores de varianza horaria ya de por si elevadas para el clima presente, y por lo tanto con un potencial mayor para generar eventos extremos de precipitación, serán las que sufran un incremento mayor en el clima futuro.

La asimetría (γ) es otro estadístico que indica de manera indirecta como podría cambiar la frecuencia de ocurrencia y la intensidad de los eventos más extremos de precipitación. Un valor de asimetría elevado indicaría que las distribuciones son más sesgadas y por lo tanto con regímenes de precipitación con mayor dispersión. Como podemos observar en las Figuras 4.16 y 4.17, el comportamiento de la asimetría para los diferentes escenarios de cambio climático es muy simular para ambas agregaciones temporales. Las funciones de densidad, calculadas mediante el método Kernel, se desplazan en ambos casos hacia valores de asimetría más elevados. No obstante, dicho comportamiento es mucho más marcado para una agregación temporal horaria que para una diaria. Al igual que para la precipitación media, el cambio es más pronunciado a medida que nos acercamos a finales del XXI y para el RCP 8.5.

Los resultados muestran cambios muy marcados para la proporción de intervalos secos (Pdry). Es esperable que el número de días y horas secas aumente significativamente en aquellas estaciones y meses del año ya de por sí muy secos (Pdry_{1-d} >97%) a medida que nos acerquemos a finales del siglo XXI. El cambio es mucho más pronunciado para el escenario RCP 8.5 que para el RCP 4.5. También se espera un ligero cambio en las probabilidades de transición, en parte como consecuencia del cambio en el estadístico Pdry. Como se puede apreciar en la forma de las distribuciones, los valores del estadístico ϕ^{DD} aumentan, mientras que los del estadístico ϕ^{WW} disminuyen ligeramente para el futuro. Lo que podría indicar que para el clima futuro habrá una probabilidad mayor de que se produzcan eventos más intermitentes y de corta duración (como aquellos de origen convectivo).

Por último, la Tabla 4.8 resume el cambio porcentual promediado para todas las estaciones y RCMs respecto al periodo de referencia 1986-2005. Los cambios en la precipitación media para el periodo de corto plazo son prácticamente despreciables, mientras que para el periodo de medio y largo plazo podrían alcanzar valores de entre el 4.79 % y el 8.12 %

y de entre el 7.72 % y el 17.72 % para los escenarios RCP 4.5 y RCP 8.5, respectivamente. La varianza aumenta para ambas agregaciones temporales, sin embargo, a diferencia de la precipitación media, no parece mostrar un patrón de comportamiento entre los distintos RCPs y periodos futuros; o dicho de otra manera, en vista de los resultados obtenidos no se puede afirmar que la varianza vaya a aumentar más para un escenario o periodo temporal en concreto. Para una agregación diaria, el aumento en la varianza será de entre un 14.86% y un 52%, dependiendo del escenario y del periodo analizado. En el caso de la varianza horaria el rango es algo menor, con un incremento comprendido entre el 13.9% y el 29.93%. En el caso de la asimetría el cambio es muy simular para ambas agregaciones temporales. Los valores de asimetría son más elevados para el RCP 8.5 que para el RCP 4.5, y también a medida que nos acercamos a finales del siglo XXI. El aumento en la asimetría para el periodo de largo plazo podría alcanzar un valor del 30% para el escenario RCP 8.5. El porcentaje de cambio para el estadístico Pdry es algo menor que para el resto de estadísticos anteriormente mencionados. En todos los RCPs y periodos analizados los valores del estadístico Pdry aumentan, con un incremento mayor para el RCP 8.5 y para finales de siglo. El incremento en el estadístico Pdry es algo mayor a una agregación diaria que a una horaria. Un comportamiento muy parecido al que muestra el estadístico Pdry, pero en sentido contrario, se puede observar para el estadístico ϕ^{WW} .

El aumento tan pronunciado en la varianza y en la asimetría podría deberse principalmente a tres motivos: (1) un aumento en la precipitación media que daría como resultado un incremento en la varianza; (2) un aumento en la proporción de intervalos secos que daría como resultado un incremento en la asimetría; o (3) un incremento en la intensidad y frecuencia de ocurrencia de los eventos más extremos de precipitación que daría como resultados un incremento tanto en la varianza como en la asimetría. Como la precipitación media se reduce y el aumento en la proporción de intervalos secos, en comparación con la asimetría, es prácticamente despreciable, podemos afirmar que parte del aumento en la varianza y en la asimetría se debe a una intensificación de los eventos más extremos de precipitación para el clima futuro.

4.5.2.2. Análisis de incertidumbre

Hasta ahora se ha analizado la variación en la magnitud de los estadísticos de precipitación para todas las estaciones y RCMs al mismo tiempo. Sin embargo, en España, con una diversidad climática tan grande es esperable que los efectos del cambio climático afecten de manera diferente a cada región y tipo de clima. Además, tan importante como la magnitud en el cambio de los estadísticos es comprobar si existe un acuerdo en la dirección de cambio y en la magnitud entre los diferentes RCMs.

TABLA 4.8: Cambio porcentual en los estadísticos de precipitación promediado para todas las estaciones y RCMs respecto al periodo de referencia 1986-2005. Los estadísticos analizados son: media (μ), varianza (σ), asimetría (γ), proporción de intervalos secos (ϕ) y probabilidades de transición (ϕ^{DD} y ϕ^{WW}). Los resultados han sido analizados a una agregación diaria y horaria, respectivamente.

	Diario					Horario							
Periodo	Corto-plazo Me		Media	edio-plazo		Largo-plazo		Corto-plazo		Medio-plazo		Largo-plazo	
RCPs	4.5	8.5	4.5	8.5	4.5	8.5	4.5	8.5	4.5	8.5	4.5	8.5	
μ	0.39	-1.12	-4.79	-8.12	-7.72	-17.72	0.39	-1.12	-4.79	-8.12	-7.72	-17.72	
σ	41.99	52.14	30.92	14.86	26.48	44.7	29.3	29.93	19.57	13.9	17.66	22.34	
γ	12.34	11.46	14.09	19.23	15.85	29.24	10.88	12.21	14.6	16.21	13.55	24.33	
ϕ	0.58	1.16	2.31	3.39	2.92	6.17	0.15	0.31	0.58	0.76	0.67	1.32	
ϕ^{DD}	0.11	0.68	1	1.58	1.17	2.93	0.02	0.07	0.15	0.22	0.18	0.41	
ϕ^{WW}	-0.82	-0.04	-2.1	-2.71	-3.65	-6.03	-1.09	-1.62	-2.1	-3.23	-2.25	-4.34	

Para abordar esta problemática se ha aplicado el método Sgl para cada una de las estaciones, estadísticos, RCPs y periodos temporales para una agregación diaria y horaria de manera independiente. Como se comento en la Sección 4.5.1.3, el método Sgl se usa para afirmar, con cierto rigor estadístico, que existe un acuerdo en la dirección de cambio y magnitud para una variable concreta entre los diferentes modelos climáticos (RCMs); o en otras palabras, que el cambio observado es robusto. Para facilitar la visualización de los resultados, estos han sido agrupados según el tipo de clima al que pertenecen según la clasificación climática de Köppen-Geiger (Peel et al., 2007). Las diferentes zonas climáticas fueron calculadas por AEMeT utilizando para ello miles de estaciones de precipitación y temperatura durante el periodo 1971–2000 (AEMeT, 2011). Las estaciones con valores de Sgl mayores de 1 o menores de -1 fueron clasificadas como estaciones cuyo cambio es robusto o significativo desde un punto de vista estadístico.

De la Figura 4.19 a la Figura 4.25 se muestra el porcentaje de estaciones con significancia en el cambio a una agregación diaria y horaria para los diferentes RCPs y periodos analizados por separado, respecto al periodo de referencia 1986-2005. Cada una de las figuras muestra los valores de Sgl para los 7 principales climas de España (BSh, BSk, BWh, Cfa, Cfb, Csa y Csb). Las barras de colores indican el porcentaje de estaciones con significancia en el cambio, según el método Sgl, para cada uno de los meses del año y para los tres periodos analizados. El color azul indicaría el porcentaje de estaciones con significancia positiva (Sgl>1) y el rojo indicaría el porcentaje de estaciones con significancia negativa (Sgl<-1). Cada color (azul y rojo) se divide a su vez en tres tonalidades: la más clara corresponde al periodo de corto plazo, la intermedia el periodo medio plazo y la de color más intenso el periodo de largo plazo. Una barra que alcanza un valor de 300 o de -300 indicaría que todas las estaciones muestran significancia en el cambio para ese mes concreto y para los tres periodos temporales analizados. Cada figura muestra el cambio en la media (μ), varianza (σ), asimetría (γ), proporción de intervalos secos (Pdry) y probabilidades de transición (ϕ^{DD} y ϕ^{WW}) a una agregación diaria y horaria,



Figura 4.19: Porcentaje de estaciones con significancia en el cambio (Sgl>1 o Sgl<-1) para el clima BSh (Semiárido cálido) a una agregación diaria y horaria para los escenarios RCP 4.5 y RCP 8.5. Las barras de colores indican el porcentaje de estaciones con valores de Sgl mayores a 1 o menores a -1 para cada uno de los meses del año y para los tres periodos analizados (2016-2035, 2046-2065 y 2081-2100) respecto al periodo de referencia 1986-2005. El color azul indica cambios positivos (Sgl>1) y el rojo negativos (Sgl<-1). Cada color (azul y rojo) se divide a su vez en tres tonalidades: la más clara corresponde al periodo de corto plazo, la que presente una tonalidad intermedia corresponde periodo medio plazo y la de color más intenso corresponde al periodo de largo plazo. Una barra que alcanza un valor de 300 o de -300 indicaría que todas las estaciones muestran significancia en el cambio para ese mes concreto y para los tres periodos temporales analizados. Cada panel muestra el cambio en la media (μ) , varianza (σ) , asimetría (γ) , proporción de intervalos secos (Pdry) y probabilidades de transición $(\phi^{DD} \neq \phi^{WW})$ a una agregación diaria y horaria.

respectivamente, para un tipo de clima concreto. La precipitación media horaria no ha sido analizada ya que sus resultados son los mismos que para una agregación temporal diaria. Tampoco se muestra el cambio en la asimetría diaria ya que el número de estaciones con significancia es prácticamente cero para todos los climas.

Lo primero que se puede observar es que el número de estaciones que muestran significancia para la precipitación media (μ_{1-d}) es mucho menor para el escenario RCP 4.5 que para el RCP 8.5 para la mayoría de climas. El clima Csa (Mediterráneo Típico) es el único donde existe un número considerable de estaciones con significancia para los meses comprendidos entre abril y noviembre para el escenario RCP 4.5. El patrón de comportamiento es muy similar para los climas Cfa, Cfb, Csa, BSk y Csb, donde un



Figura 4.20: La figura presenta la misma información que la Figura 4.19 pero para el clima BSk (Semiárido Cálido).

porcentaje elevado de estaciones muestran una reducción significativa entre los meses de abril y octubre para la precipitación media (μ_{1-d}). Es interesante observar que para los climas Cfa y Cfb aparecen valores positivos para la precipitación media en un porcentaje no despreciable de las estaciones para los meses de enero y febrero. Para el clima BWh, el número de estaciones que muestran una reducción en la precipitación media es mayor en otoño e invierno que en primavera y verano. Algo parecido sucede en el clima BSh donde el calentamiento global no parece afectar a la precipitación media en los meses de verano. Al comparar los resultados entre los diferentes periodos horizonte, vemos que prácticamente ningún clima muestra significancia para el periodo de corto plazo. Además, el número de estaciones con significancia es mayor para el periodo de largo plazo que para el de corto plazo.

Como se comentó anteriormente no mostramos los resultados para la asimetría a una agregación diaria ya que prácticamente ninguna estación muestra significancia a dicha agregación temporal. Sin embargo, no sucede lo mismo a una agregación horaria donde el número de estaciones con significancia positiva es bastante elevado para algunos climas. El hecho de que solo se pueda apreciar significancia en la asimetría a una agregación horaria (γ_{1-h}) indicaría que dicho cambio viene determinado por el aumento en la TAS y no por el cambio en la asimetría diaria. Algo parecido sucede para la varianza (σ),



Figura 4.21: La figura presenta la misma información que la Figura 4.19 pero para el clima BWh (Árido cálido).

donde el porcentaje de estaciones que muestra significancia a una agregación diaria es muy reducido en comparación con la agregación horaria. No obstante, un amento en la TAS no tiene por qué ir unido a un aumento en la asimetría y la varianza horaria para todos los climas y meses del año. En los climas más áridos, BSh y BWh, y para el resto de climas en los meses de verano, la varianza y la asimetría muestra valores negativos. En esas condiciones, un incremento en la TAS podría ir unido a un déficit en la cantidad de agua disponible en la atmósfera y por lo tanto a un descenso en al frecuencia de los eventos extremos.

Según su formulación matemática, un aumento en la varianza significaría una reducción en la asimetría. Es por ello que habrá que poner especial atención a aquellos climas y meses del año en los que ambos estadísticos (σ_{1-h} y γ_{1-h}) muestran cambios positivos al mismo tiempo (como sucede en los climas BSk, Cfa, Cfb, Csa y Csb), ya que esto podría estar unido a un amento en la torrencialidad. En contraposición, para los climas más áridos (BSh y BWh) la dirección de cambio entre ambos estadísticos (σ_{1-h} y γ_{1-h}) es inversa. Esto podría indicar que el aumento en la varianza horaria (σ_{1-h}) podría estar determinada por un cambio en la precipitación media (μ_{1-d}) o en el porcentaje de intervalos secos (Pdry), y no por variaciones en la frecuencia e intensidad de los eventos extremos de precipitación. Los resultados muestran significancia positiva para



Figura 4.22: La figura presenta la misma información que la Figura 4.19 pero para el clima Cfa (Subtropical húmedo o sin estación seca).

la asimetría horaria (γ_{1-h}) para la mayoría de regímenes climáticos para los periodos de medio y largo plazo. El número de estaciones con significancia es considerablemente mayor para el escenario RCP 8.5 que para el escenario RCP 4.5. Únicamente para los climas BSh y BWh se puden apreciar estaciones con valores de Sgl<-1 para los meses de verano, lo que refuerza la hipótesis de que en los climas más áridos un aumento en la TAS no tiene por qué ir unido a un aumento en los eventos extremos de precipitación. Del mismo modo que con la precipitación media (μ_{1-d}), el mayor número de estaciones con significancia estadística en la asimetría horaria (σ_{1-h}) se observa para los escenarios de medio y largo plazo.

La varianza muestra un comportamiento muy similar para los climas BSk, Cfa, Cfb, Csa y Csb. A una agregación diaria (σ_{1-d}) no se aprecia prácticamente ninguna estación con significancia. Sin embargo, para una agregación horaria (σ_{1-h}) el número de estaciones con significancia positiva es bastante elevado en algunos climas, sobre todo para los meses comprendidos entre octubre y marzo; mientras que para los meses de verano se puede apreciar cambios negativos. Dichos cambios son generalmente más intensos para el periodo de largo plazo y para el escenario RCP 8.5. Al igual que con la asimetría horaria, el aumento en la varianza horaria viene principalmente determinado por el aumento en la TAS y no por el aumento en la varianza diaria; ya que los únicos predictores utilizados



Figura 4.23: La figura presenta la misma información que la Figura 4.19 pero para el clima Cfb (Oceánico Templado).

para desagregar la varianza subdiaria fueron la varianza diaria y la TAS (ver Tabla 4.7). En los climas más áridos (BWh y BSh) la varianza horaria muestra valores de significancia negativos para la mayoría de meses de año.

El cuanto a los resultados para el estadístico Pdry, los climas BSk, Cfa, Cfb, Csa y Csb muestran un comportamiento similar para ambas agregaciones temporales, lo que indicaría que el predictor Pdry, a una agregación temporal diaria, presenta mucha mayor importancia en la regresión. El número de estaciones con significancia positiva es muy elevado para las estaciones de primavera y verano. La significancia en el cambio es mayor para el escenario RCP 8.5 y para los periodos de medio y largo plazo. Por el contrario, en los climas BSh y BWh, el número de estaciones con valores de Sgl> 1 es mayor para las estaciones de otoño e invierno. El estadístico ϕ^{DD} muestra un patrón de comportamiento muy parecido al del estadístico Pdry, lo que indicaría que el cambio en la probabilidad de que un periodo seco esté precedido de otro seco viene principalmente determinado por el cambio en el estadístico Pdry.

En el caso del estadístico ϕ^{WW} , el número de estaciones con significancia en el cambio es mucho mayor para un agregación horaria que diaria. En general, en los meses de primavera y verano los valores de ϕ_{1-h}^{WW} se reducen en gran parte de las estaciones. Dicho



Figura 4.24: La figura presenta la misma información que la Figura 4.19 pero para el clima Csa (Mediterráneo Típico).

comportamiento está más marcado en los climas situados en el norte de la Península, lo que podría estar determinado por una reducción en el número de horas de lluvia en dichos meses, así como también, por el aumento en la frecuencia de ocurrencia de tormentas de más corta duración. El estadístico ϕ_{1-h}^{WW} no muestra un patrón de comportamiento a lo largo de las estaciones del año para los climas más áridos (BSh, BSk y BWh). De hecho, en la mayoría de climas se intercalan los meses con significancia positiva y negativa. Al igual que en el resto de estadísticos el número de estaciones que muestran significancia es mayor para el escenario RCP 8.5 y para el periodo de medio y de largo plazo.



Figura 4.25: La figura presenta la misma información que la Figura 4.19 pero para el clima Csb (Mediterráneo Oceánico).

4.5.2.3. Efecto del incremento de la TAS en los eventos extremos de precipitación

Normalmente, el cambio en la frecuencia de ocurrencia y en la intensidad de los eventos más extremos de precipitación se suele estudiar a través de índices extremales, como por ejemplo a través de la intensidad media de los *n* valores más intensos en un periodo, por medio de percentiles, o por medio del cambio en los periodos de retorno de precipitación. Este último enfoque, sin embargo, puede presentar errores muy elevados ya que los periodos de retorno suelen calcularse con unos pocos valores de precipitación (Monjo et al., 2016). Esta sección tiene como objetivo investigar el efecto del aumento en la temperatura superficial del aire (TAS) en el estadístico varianza horaria que, como veremos, está altamente influenciado por la frecuencia e intensidad de eventos extremos de precipitación.

En los dos apartados previos (4.5.2.2 y 4.5.2.1), se ha analizado el cambio en los estadísticos de precipitación a una agregación temporal diaria y horaria. En dichos apartados hemos podido observar que el porcentaje de estaciones que muestran significancia en el cambio para la varianza y la asimetría, es mucho mayor para una agregación horaria que diaria; lo que previsiblemente se podría deber al aumento en la temperatura superficial del aire (TAS), ya que de no ser así, se debería de apreciar un comportamiento similar entre el mismo estadístico a ambas agregaciones (diaria y horaria). Lo que probablemente suceda es que el aumento en la TAS hace que algunas estaciones migren a regímenes climáticos diferentes. Sin embargo, hay que tener en cuenta que un incremento en la TAS muy probablemente afecte de manera diferente dependiendo del estadístico y estación analizada. De hecho, para los climas más calurosos (BSh y BWh), así como en los meses de verano para la mayoría de climas, la relación entre la varianza y la TAS es inversa.



Figura 4.26: Efecto del incremento en la temperatura superficial del aire (TAS) en la varianza horaria (%) para cada tipo de clima. Cada panel corresponde a un tipo de clima diferente. El panel situado en la esquina superior izquierda muestra el efecto del aumento en la TAS en todas las estaciones y climas al mismo tiempo.

La Figura 4.26 muestra el efecto de un incremento en la TAS de hasta 4°C en la varianza horaria (%). Los resultados se han obtenido aumentando de manera progresiva el valor del predictor TAS en el modelo RFB, ajustado en la Sección 4.4, con las series de precipitación observadas. El panel situado en la esquina superior izquierda muestra el resultado promediado para todas las estaciones y climas, mientras que el resto de paneles muestran el resultado para cada uno de los climas por separado. Como podemos observar en la Figura 4.26, la relación entre la varianza horaria y la TAS muestra un comportamiento no monotónico para los climas más áridos (BWh y BSh). En estos climas no se aprecia ningún tipo de tendencia, de hecho, dependiendo del incremento en la TAS el sentido de cambio puede ser negativo o positivo. Esto confirmaría los resultados obtenidos por otros autores en cuanto a que la relación ECC podría ser inversa para aquellos climas con valores más altos de TAS (Drobinski et al., 2018; Lenderink y Van Meijgaard, 2008). Como podemos apreciar, para el resto de los climas el aumento en la TAS está relacionado con un aumento en la varianza horaria, a excepción de para el clima Csb (Mediterráneo Oceánico). Sin embargo, hay que tener en cuenta que en el clima Csb encontramos estaciones con regímenes de precipitación totalmente diferentes,

lo que podría estar deteriorando los resultados. Cuando se observan los resultados de la varianza horaria para todos lo climas al mismo tiempo, se puede apreciar una relación monotónica entre la TAS y la varianza horaria. Por cada 0.5 °C de incremento en las TAS la varianza horaria aumentaría entre un 2.5 % y un 5 %, aproximadamente. Se puede apreciar también que el incremento en los eventos más extremos de precipitación de un 6-7 %, por cada incremento de un grado de TAS según la ecuación ECC, seguiría la misma relación para la varianza horaria.



Figura 4.27: Gráfico de dispersión entre la varianza horaria y el percentil del 99 % para la precipitación horaria (R99). La figura muestra el resultado para todas las estaciones horarias con información instrumental disponibles.

Por otro lado, está claro que existe una relación entre el aumento en la varianza horaria y el incremento los eventos más extremos de precipitación. Además, se ha demostrado que en la mayoría de los climas de España un aumento en las TAS estaría relacionado con un incremento en dicho estadístico. Sin embargo, para comprender de que manera el incremento en la varianza horaria podría afectar a la frecuencia e intensidad de los eventos más extremos de precipitación, sería aconsejable utilizar otro tipo de aproximación más directa, basada por ejemplo en el porcentaje de cambio en los percentiles (Monjo et al., 2016).

La Figura 4.27 muestra la relación entre la varianza horaria y el percentil del 99% (R99) para todas las estaciones horarias disponibles al mismo tiempo. El percentil del 99% equivaldría a un periodo de retorno de 100 años. La varianza horaria y el valor de R99 fueron calculados para cada estación y para cada uno de los 12 meses del año por separado. La línea negra discontinua muestra el ajuste entre la varianza horaria y el R99. La función que mejor ajusta ha sido una función logarítmica con un parámetro a=5.46.

Si asumimos que por cada incremento de 0.5° C en la TAS el porcentaje de varianza horaria aumenta aproximadamente un 2.5% de media para todas las estaciones y meses del año (ver Figura 4.27), podremos relacionar el incremento porcentual en el R99 con la varianza horaria y con el aumento en la TAS. La Figura 4.28 muestra el aumento porcentual en el R99 en función de la varianza horaria, para un incremento de la temperatura superficial del aire de de 0.5, 1, 1.5, 2, 2.5, 3, 3.5 y 4 °C. Según esta aproximación, para una incremento de la TAS determinado, el aumento en el R99 (%) sería diferente dependiendo del valor de varianza horaria inicial del que partamos. El incremento del 6-7% en el R99, para un incremento en las TAS de 1°C, únicamente se mantendría en aquellas estaciones con un valor de varianza horaria de 1 mm²/h². Para estaciones con valores pequeños de varianza horaria el porcentaje de cambio en el R99 sería mayor que para valores de varianza horaria elevados.



Figura 4.28: Incremento del percentil del 99 (%), para una varianza horaria dada, en función del aumento de la temperatura superficial del aire (TAS). Cada curva corresponde a un incremento en la TAS de 0.5, 1, 1.5, 2, 2.5, 3, 3.5 y 4 °C, respectivamente.

4.5.3. Conclusiones

En la presente sección (Sección 4.5) se ha ampliado el trabajo realizado en la Sección 4.4 "Desagregación temporal de la precipitación en España para el clima presente" para generar una base de datos de estadísticos de precipitación para diferentes escenarios de cambio climático en más de 2000 estaciones distribuidas a los largo de la Península Ibérica, Islas Canarias e Islas Baleares. La base de datos contiene información sobre la media, varianza, asimetría, proporción de intervalos secos y probabilidades de transición para las agregaciones temporales T = [1-h, 2-h, 3-h, 6-h, 12-h, 1-d, 2-d, 3-d]. El método delta de factores de cambio (Burton et al., 2010) ha sido utilizado para actualizar los estadísticos diarios y supradiarios para 11 modelos de EURO-CORDEX y 10 de AFR-CORDEX, para los escenarios RCP 4.5 y RCP 8.5, y para tres periodos horizonte (2016-2035, 2046-2065, 2081-2100). Los estadísticos diarios de precipitación, así como la TAS mensual, fueron proyectados al futuro mediante el método delta; mietras que el método basado en la técnica Random Forests, ajustado para el clima presente en la Sección 4.4, se utilizó para actualizar los estadísticos subdiarios de precipitación para los escenarios futuros. La base de datos está disponible para fines de investigación en Diez-Sierra y del Jesus (2019B2).

Como resultados se muestra la magnitud del cambio en los estadísticos para todas las estaciones al mismo tiempo y para los diferentes escenarios de cambio climático respecto el periodo de referencia. Los resultados muestran un cambio en la precipitación media de entre el 0.39% y el -17.72%, dependiendo del periodo y del escenario analizado. La precipitación se reduce más a medida que nos acercamos a finales del siglo XXI y para el escenario RCP 8.5. La varianza diaria, con un incremento de entre el 14.86% y el 52.14%, aumenta más que la varianza horaria, con valores comprendidos entre el 13.9%y el 29.93%. En el caso de la asimetría, el rango de variación es similar para ambas agregaciones temporales, con un incremento comprendido entre el 10% y el 30%. Los valores de Pdry aumentan entre un 0.11% y un 6% y entre un 0.15% y un 1.32% a una agregación diaria y horaria, respectivamente. Dicho incremento es más intenso para el escenario RCP 8.5 y para el periodo de largo plazo. Los valores de ϕ^{WW} se reducen de manera similar para ambas agregaciones temporales con valores de entre un 0.04% y un 6.03 %. Los valores de ϕ^{DD} aumentan entre un 0.11 % y un 2.93 % para una agregación diaria y de entre 0.02% y un 0.41% para una agregación horaria. Como sucede con el estadístico Pdry, los cambios para ϕ^{WW} y ϕ^{DD} son más intensos para el escenarios RCP 8.5 y para el periodo de largo plazo.

Los cambios en la varianza y en la asimetría, sumado a la reducción en la precipitación media y al aumento en la proporción de intervalos, podrían indicar que España presentará un clima más seco y extremo en el futuro. Según los resultados obtenidos, dicho cambio será más intenso a medida que nos acerquemos a finales del siglo XXI y para el escenario RCP 8.5 que para el RCP 4.5.

Se ha analizado también la significancia en el cambio para todos los RCMs al mismo tiempo y para todos los estadísticos y estaciones por separado mediante el método Sgl (Jiang et al., 2015). Los resultados muestran cambios con significancia negativa en la precipitación media (Sgl<-1) en un porcentaje muy elevado de estaciones y en la mayoría de climas de España entre los meses comprendidos entre abril y octubre. El porcentaje de estaciones con significancia es mucho mayor para el RCP 8.5 y para los periodos de medio y largo plazo. Los resultados para los estadísticos Pdry y ϕ^{DD} muestran un comportamiento similar que para la precipitación media para ambas agregaciones temporales (1-h y 1-d) pero en sentido opuesto. Para el estadístico ϕ^{WW} , se observan valores de Sgl<-1 en un porcentaje elevado de estaciones para la mayoría de estaciones y climas, siendo dicho cambio más intenso para los climas más áridos (BSh y BWh) durante los meses de invierno; mientras que en el resto de climas el mayor número de estaciones con valores de Sgl<-1 se presenta en los meses de verano. Para todos los climas el número de estaciones con significancia es mayor a una agregación horaria que diaria. En el caso de la asimetría únicamente se aprecian cambios significativos a una agregación horaria. Dichos cambios son positivos en la mayoría de climas y meses del año. El número de estaciones con significancia es mayor para el RCP 8.5 y para los periodos de medio y de largo plazo. Para la varianza, el número de estaciones con significancia es considerablemente mayor a una agregación horaria que a una agregación diaria. Para todos los climas, exceptuando los climas BSh y BWh, la varianza horaria aumenta (Sgl > 1) en otoño y en invierno, y disminuye (Sgl< 1) en primavera y en verano. Como sucede en la mayoría de estadísticos, el número de estaciones con significancia es mayor para los periodos de medio y de largo plazo y para el escenario RCP 8.5

A través los resultados obtenidos en la presente sección llegamos a las mimas conclusiones que otros autores en el pasado (Merino et al., 2018; Scoccimarro et al., 2015; Utsumi et al., 2011). La asimetría y la varianza, que son dos estadísticos que se ven altamente influenciados por los eventos más extremos de precipitación, aumentarán en los climas continentales para los meses menos calurosos (otoño e invierno). Sin embargo, dicho cambio únicamente muestra significancia a una agregación horaria. Por otro lado, en los climas más áridos (BSh y BWh), y en general en los meses de verano para todos los climas, la varianza se reduce. Estos resultados indicarían que los eventos más extremos de precipitación podrían intensificarse, en la mayor parte de climas (exceptuando los climas más calurosos, BSh y BWh), a una agregación horaria para las estaciones de otoño e invierno. El hecho de que no exista un acuerdo entre los estadísticos varianza y asimetría a una agregación diaria y horaria nos hace pensar que la significancia en el cambio tiene que estar determinada principalmente por el aumento en la TAS y no por el cambio en los estadísticos diarios. Según la ecuación ECC, un aumento en las TAS de 1°C podría suponer un incremente en la cantidad de vapor de agua disponible en la atmósfera de entre un 6-7 % y por consiguiente en los eventos extremos de precipitación (Drobinski et al., 2016). Sin embargo, algunos autores defienden que dicha relación podría no mantenerse o incluso ser inversa dependiendo del clima y agregación temporal analizada (Drobinski et al., 2018; Utsumi et al., 2011). Este mismo comportamiento lo hemos podido observar en España para los climas más áridos (BSh y BWh); la varianza horaria en estos climas se reduce en la mayoría de meses de año, mientras que en el resto de climas aumenta entre los meses de octubre y marzo. El número de estaciones con significancia en el cambio es mucho mayor a una agregación horaria que a una agregación diaria, lo que demuestra que en aquellos lugares con regímenes de precipitación como los de España, en los que en pocas horas puede precipitar una gran cantidad de agua, es fundamental analizar los efectos del cambio climático en los regímenes de precipitación a agregaciones temporales por debajo del día.

Por último, se ha demostrado la relación existente entre la varianza horaria y el percentil del 99% de la precipitación horaria (R99). A través de un análisis algo grosero se ha calculado el cambio porcentual en el R99, en función de la varianza horaria, para diferentes escenarios de aumento de la TAS (0.5, 1, 1.5, 2, 2.5, 3, 3.5 y 4 °C). Los resultados muestran un incremento mayor en el R99 a medida que se incrementa la TAS. Sin embargo, el porcentaje de cambio en el R99 dependerá del régimen de precipitación concreto que estemos analizando o de la varianza horaria de la que partamos.

Hay que tener en cuenta que los resultados están promediados para todos las estaciones y climas, y que además, únicamente se está teniendo en cuenta el efecto de la varianza horaria en el R99. Sería aconsejable utilizar un enfoque basado en generadores sintéticos (Diez-Sierra y del Jesus, 2019) con el objetivo de simular series de precipitación para el presente y para el futuro. Dicho enfoque permitiría evaluar el cambio en los extremos de precipitación, directamente en las series sintéticas de precipitación, teniendo en cuenta la interacción de los diferentes estadísticos.

Capítulo 5

Observaciones finales

5.1. Conclusiones principales

En esta sección se resumen las principales conclusiones obtenidas a lo largo de la tesis. Dichas conclusiones han sido organizadas en cuatro bloques que coinciden con los objetivos específicos presentados en la Sección 1.2. "Objetivos". A continuación se describen las conclusiones generales y específicas relativas a cada uno de los cuatro bloques centrales de la tesis.

En relación al **Objetivo 1**, que coincide a su vez con la Sección 3.4 "Predicción probabilística a corto plazo basada en tipos de tiempo", se ha desarrollado una herramienta de fácil manejo que sirve para evaluar el riesgo asociado a los eventos extremos de precipitación en un marco temporal de corto plazo (de 1 a 3 días vista). Dicha herramienta, que recibe el nombre de MENSEI-L, ha sido implementada en la isla de Tenerife (España) y se aprovecha de la amplia red de estaciones pluviométricas disponibles en la isla para calibrar y validar los diferentes métodos. La herramienta utiliza una metodología basada en tipos de tiempo atmosféricos para realizar predicciones de precipitación a corto plazo, descarga de manera automática los campos espaciales atmosféricos de la base de datos GFS (Global Forecast System) a 3 días vista y busca los tipos de tiempo más parecidos en el periodo histórico. Los resultados son facilitados según dos enfoques diferentes: (1) predicción cuantitativa, en base a los campos espaciales de precipitación promediados para todos los días en los que tuvo lugar el tipo de tiempo más parecido; o (2) predicción cualitativa, en el que se evalúa el riesgo de ocurrencia de un evento extremo de precipitación en base a los registros históricos que tuvieron lugar en Tenerife. Las conclusiones más relevantes son:

- Se ha investigado la eficiencia de diferentes técnicas geoestadísticas para reconstruir los datos de precipitación faltantes para el periodo 1979-2015, así como para generar resultados de precipitación en formato espacial. La técnica Kriging Universal, que utiliza como tendencia (*drift*) la elevación y la precipitación media anual, ha sido seleccionada como la mejor mediante la técnica de validación cruzada *leaveone-out*. El elevado número de estaciones pluviométricas disponibles en la isla de Tenerife da como resultado campos espaciales de precipitación de alta calidad, sin embargo, en aquellas áreas donde hay un bajo número de estaciones, o donde están muy alejadas entre sí, la calidad de la reconstrucción se ve fuertemente deteriorada por esta falta de información.
- El sistema de predicción basado en tipos de tiempo (WT) requiere un enfoque más sofisticado que aquel basado en la precipitación media asociada a cada WT. Un 50% de acierto en los días de lluvia, cuando la información de precipitación es agregada a una resolución tres-diaria, es aceptable pero aún no es suficientemente buena como sistema de predicción de precipitación cuantitativa. No obstante, se ha demostrado que la metodología basada en WT presenta un gran potencial como sistema de alerta ante eventos extremos, ya que identifica correctamente los tipos de clima que produjeron lluvias extremas (e inundaciones) en la isla de Tenerife en el pasado.
- Los WT constituyen una buena representación de los diferentes tipos de patrones sinópticos atmosféricos existentes en Tenerife. Los tipos de tormenta derivados de los WT muestran patrones de lluvia bastante homogéneos para cada WT, sin embargo, es necesario investigar una relación más sólida entre los WT y los tormentas tipo. Se ha realizado una clasificación ciega o no supervisada (sin información sobre los patrones de precipitación) para generar los WT. Sin embargo, para obtener unos resultados óptimos, la clasificación debe considerar el objetivo final: agrupar las situaciones atmosféricas en patrones de lluvia homogéneos.
- MENSEI-L constituye una herramienta muy útil para el análisis de redes de estaciones pluviométricas. Simplifica la aplicación de técnicas matemáticas avanzadas (geoestadística) y automatiza los diferentes procesos, permitiendo que cualquier usuario pueda hacer uso de ellas. Los diferentes análisis presentados en este apartado pueden utilizarse para evaluaciones de riesgo y diseño de infraestructura, entre otras aplicaciones. Los aspectos técnicos sobre MENSEI-L pueden encontrarse en Diez-Sierra y del Jesus (2017).

En relación al **Objetivo 2**, que coincide a su vez con la Sección 3.5. "Predicción a largo plazo mediante modelos estadísticos y máquinas de aprendizaje automatizado", se ha

comparado la habilidad de 8 métodos estadísticos y de aprendizaje automatizado para reconstruir la precipitación durante varias décadas en el pasado. Los métodos utilizan como predictores los campos espaciales de presión a nivel del mar (SLP) y de altura geopotencial (GH), a una resolución temporal diaria, para el área comprendida por las coordenadas 45°W y 5°E, y 20°N y 50°N. Los diferentes métodos han sido validados en 17 estaciones distribuidas a lo largo de la isla de Tenerife (España). La habilidad de los modelos fue evaluada comparando los valores observados y simulados a una agregación diaria, mensual y anual, respectivamente, para diferentes métricas sobre la ocurrencia de la lluvia y sobre la intensidad. Se ha determinado el mejor conjunto de hiperparámetros para cada modelo mediante la técnica de validación cruzada entre un rango de valores definido por un producto cartesiano de diferentes hiperparámetros. Las conclusiones más relevantes son:

- Los resultados muestran que la mayoría de métodos de aprendizaje automático son muy sensibles al conjunto de hiperparámetros elegidos. De hecho, una selección de hiperparámetros errónea podría dar como resultado modelos sin ninguna capacidad predictiva. Los modelos Random Forests (RF) y k-nearest neighbors (k-NN) son modelos que suelen sobreajustarse. Para evitarlo, los hiperparámetros que controlan el número de árboles en el bosque y al número mínimo de muestras requeridas para formar un nodo/hoja sobre el cual calcular la moda o la media, en el caso del método RF, y el parámetro que controla el número k de vecinos, para el método k-NN, deberían de tomar valores elevados incluso cuando su capacidad predictiva se viese degradada. Los resultados también muestran que la combinación de hiperparámetros seleccionada como óptima cambia considerablemente de una estación a otra; lo que demuestra que es fundamental buscar la mejor combinación de hiperparámetros antes de cualquier aplicación, en lugar de recurrir unos hiperparámetros predefinidos.
- El método Neural Network (NN), con un valor de f-score cercano a 0.4, promediado para todas las estaciones, es el método que ofrece los mejores resultados para predecir la ocurrencia de la precipitación. Los métodos Logistic Regression (LR) y Support Vector Machine (SVM) ofrecieron también buenos resultados. Todos los modelos conservan los valores observados para la probabilidad de transición de un intervalo seco a otro seco y subestiman los valores observados para la probabilidad de transición de un intervalo húmedo a otro húmedo. NN, de nuevo, presenta errores más pequeños al predecir las probabilidades de transición, principalmente debido a que presenta un valor más alto de f-score. La métrica exhaustividad aumenta a medida que incrementamos el umbral de la intensidad de lluvia; lo que indica que los eventos más intensos son más fáciles de predecir.

- Todos los métodos, a excepción de aquel basado en WT, alcanzan valores de R por encima de 0.8 a la hora de simular el número de días de lluvia por mes y por año. NN, SVM y LR son los únicos métodos capaces de simular meses con más de 20 días húmedos, lo que es excepcionalmente inusual en Tenerife.
- NN presenta resultados significativamente mejores que el resto de los modelos al predecir la intensidad de la lluvia. SVM, k-NN y RF ocupan el segundo puesto con valores ligeramente inferiores de R y superiores de RMSE que el método NN. WT presenta el peor resultado de todos los modelos. Todos los métodos subestiman ampliamente la varianza de las series observadas así como los eventos más intensos de precipitación. El modelo lineal generalizado (GLM), con una distribución de errores que sigue una función gamma (GLM-G), es el que mejor reproduce los índices extremos RX1 y R20. Cuando comparamos las series observadas y simuladas para agregaciones temporales por encima del día los resultados mejoran significativamente. Todos los modelos, excepto WT, presentan valores de correlación (R) cercanos a 0.8 cuando predicen la intensidad de la lluvia a una agregación temporal mensual y anual. GLM-G es el único método capaz de simular meses con intensidades superiores a los 500 mm. Los métodos de conjunto (*ensemble*) (RF, k-NN y WT) rara vez simulan años con valores de precipitación acumulados de más de 800 mm.
- Incorporar la estacionalidad como predictor adicional mejora la habilidad predictiva de los modelos, sin embargo, no sucede lo mismo con el índice climático NAO; lo cual probablemente se deba al hecho de que el predictor presión a nivel del mar (SLP) ya incorpora la información relativa a dicho índice climático.
- En general los métodos estadísticos y de aprendizaje automatizado supervisados ofrecen mejores resultados que los no supervisados. En general los métodos estadísticos capturan mejor la varianza de las series observadas.
- Aunque cada modelo es ajustado de manera independiente para cada estación, las series simuladas son capaces de preservar adecuadamente la correlación espacial observada a una agregación diaria, mensual y anual, respectivamente. A distancias inferiores y superiores a los 10 km las series simuladas subestiman y sobrestiman, respectivamente, los valores observados a una agregación temporal diaria. El método WT es el único capaz de preservar la correlación espacial observada para todas las agregaciones temporales; lo que se debe a que es un método en el que las predicciones se realizan al mismo tiempo para todas las estaciones.
- Los resultados obtenidos en esta sección demuestran que NN es el mejor método para predecir la ocurrencia y las intensidad de precipitaciones a una resolución

diaria, mensual y anual. Todos los métodos, excepto WT, presentan buenos resultados a una resolución mensual y anual. Ningún modelo es capaz de capturar la elevada variabilidad existente en las series de precipitación de un clima semiárido como el que presenta Tenerife, lo que sugiere que los métodos analizados aquí no son apropiados para reproducir los eventos más extremos de precipitación que tuvieron lugar en el pasado. Los buenos resultados logrados a la hora de predecir la precipitación a agregaciones temporales superiores al día demuestran que estos métodos son herramientas muy útiles para estudios de recursos hídricos.

En relación al **Objetivo 3**, que coincide a su vez con la Sección 4.4. "Desagregación temporal de la precipitación en España para el clima presente", se presenta una metodología para generar series sintéticas de precipitación horarias en aquellas localizaciones de España donde solo se dispone de información diaria. La metodología ha sido validada en más de 700 estaciones con registros horarios distribuidas a lo largo del territorio español. El objetivo de la metodología es predecir diferentes estadísticos de precipitación a agregaciones temporales por debajo de día, usando como predictores los mismos estadísticos a una agregación diaria, así como otros predictores externos (principalmente variables atmosféricas de reanálisis y elevación del terreno). La metodología ha sido validada en todo el territorio español mediante validación cruzada. Los estadísticos predichos son: varianza (σ), asimetría (γ), proporción de intervalos secos (ϕ), autocorrelación temporal (ρ) y probabilidades de transición $(\phi^{DD} \neq \phi^{WW})$ para las agregaciones temporales de 1, 2, 3, 6 y 12 horas. Los generadores sintéticos Neyman-Scott Rectangular Pulse Model (NSRPM) han sido utilizados para validar los métodos y para simular series sintéticas de lluvia horarias en la Península Ibérica, las Islas Baleares y las Islas Canarias. Las conclusiones alcanzadas más relevantes son:

• Se ha presentado un método de desagregación de los estadísticos de precipitación que propone algunos cambios con respecto al modelo presentado en Beuchat et al. (2011) que dieron como resultado las siguientes mejoras: (1) el uso de modelos de regresión basados en la técnica RF da como resultado distribución de errores menos sesgadas y valores más elevados de coeficiente de determinación (R^2) ; (2) se ha reducido el número de predictores al mínimo evitando el sobreajuste del modelo y aumentado su robustez para su aplicación en estudios de cambio climático; (3) se ha mejorado los resultados de autocorrelación lag-1 calculando dicho estadístico directamente mediante relaciones de regresión y no mediante su cálculo a través variables intermedias predichas; (4) se ha ampliado el trabajo a las probabilidades de transición, las cuales pueden utilizarse de la misma manera que la autocorrelación temporal para caracterizar la dependencia temporal de los series de precipitación.

- Los resultados muestra que la mayor capacidad predictiva de los algoritmos de aprendizaje automatizado hace que sean preferibles a métodos más tradicionales como el método *Multivariate Adaptive Regression Splines* (MARS). Sin embargo, habría que prestar especial atención cuando se utilice el modelo RF para extrapolar fuera del rango de climático para el que se calibró, ya que al ser un método combinado (*ensemble*) no es capaz de generar resultados fuera del rango observado.
- En general, el modelo RF es capaz de predecir adecuadamente los estadísticos varianza (σ), asimetría (γ), proporción de intervalos secos (ϕ), autocorrelación lag-1 (ρ) y probabilidad de transición (ϕ^{DD} y ϕ^{WW}) a una agregación horaria en todos los tipos de clima de España. Los resultados mejoran para agregaciones temporales superiores (2, 3, 6 y 12 horas).
- Se han seleccionado 15 estaciones distribuidas a lo largo de España para demostrar la capacidad de los generadores sintéticos NSRPM, informados por los estadísticos subdiarios predichos mediante el modelo RF, para simular series sintéticas horarias de lluvia en España. Los resultados muestran que las series simuladas con nuestra metodología reprodujeron significativamente mejor los estadísticos horarios observados que aquellas simuladas mediante el modelo NSRPM ajustado únicamente con estadísticos diarios. Estas últimas subestimaron en gran medida la varianza, la asimetría y el Pdry a una agregación horaria, y sobrestimaron los valores observados de ACF-lag1 y ϕ^{WW} . Además, dicho modelos, ajustados únicamente con información diaria, pueden encontrar infinitas soluciones a agregaciones por debajo del día.
- Se ha demostrado también que las series simuladas mediante los modelos NSRPM, ajustados a través de los estadísticos predichos mediante la metodología presentada en esta sección, reproducen adecuadamente los eventos más extremos de precipitación a una agregación horaria.
- Una vez validados los métodos, se ha utilizado toda la información de precipitación diaria disponible en España (aproximadamente 2500 estaciones) para generar una base de datos de estadísticos de precipitación subdiarios y supradiarios en España para el clima presente. La base de datos contiene información sobre la media, varianza, asimetría, proporción de intervalos secos y probabilidades de transición para las agregaciones temporales T=[1-h, 2-h, 3-h, 6-h, 12-h, 1-d, 2-d, 3-d]. La base de datos está disponible para fines de investigación en Diez-Sierra y del Jesus (2019B2).
- Los resultados obtenidos están restringidos a aplicaciones puntuales (es decir, a pequeñas cuencas). Sin embargo, los métodos también podrían extenderse fácilmente para incorporar la dimensión espacial. Únicamente habría que introducir el
término de la correlación espacial en los modelos NSRPM durante el proceso de ajuste.

 Los resultados obtenidos en esta sección son de especial interés para el estudio de eventos extremos, para la desagregación de series diarias de precipitación, para calibrar y validar modelos numéricos a una resolución horaria y para generar series sintéticas de precipitación que capturen adecuadamente la estructura de la lluvia en aquellas localizaciones de España donde únicamente existan datos de precipitación a una agregación diaria.

En relación al **Objetivo 4**, que coincide a su vez con la Sección 4.5 "Desagregación temporal de la precipitación en España en un contexto de cambio climático", se ha ampliado el trabajo realizado en la Sección 4.4 en un contexto de cambio climático. El método delta de corrección de sesgo ha sido utilizado para actualizar los estadísticos diarios y supradiarios para 11 modelos de EURO-CORDEX y 10 de AFR-CORDEX, para los escenarios RCP 4.5 y RCP 8.5, y para tres periodos horizonte (2016-2035, 2046-2065, 2081-2100). Los estadísticos diarios de precipitación, así como la variable TAS a una agregación temporal mensual, constituyen los predictores del modelo de desagregación basado en la técnica *Random Forests* (RF), ajustado en la Sección 4.4, y que es utilizado para predecir los estadísticos subdiarios para el clima futuro. Los estadísticos subdiarios y supradiarios han sido utilizados para generar una base de datos para diferentes escenarios de cambio climático futuros. La base de datos está disponible para fines de investigación en Diez-Sierra y del Jesus (2019B2). Las conclusiones alcanzadas más relevantes son:

• Se ha evaluado la intensidad de cambio en los diferentes estadísticos de precipitación para todas las estaciones pluviométricas al mismo tiempo y para los escenarios de cambio climático futuros respecto el periodo de referencia. Los resultados muestran una cambio en la precipitación media de entre el 0.39 % y el -17.72 %, dependiendo del periodo y del escenario analizado. La reducción es mayor a medida que nos acercamos a finales del siglo XXI y también para el escenario RCP 8.5 que para el RCP 4.5. La varianza diaria, con un incremento comprendido entre el 14.86 % y el 52.14 %, aumenta más que la varianza horaria, con valores comprendidos entre el 13.9 % y el 29.93 %. En el caso de la asimetría el rango de variación es muy similar entre ambas agregaciones temporales con un incremento comprendido entre el 10 % y el 30 %. La proporción de intervalos secos aumenta entre un 0.11 % y un 6 %, y entre 0.15 % y 1.32 %, a una agregación diaria y horaria, respectivamente. Dicho incremento es más intenso para el escenario RCP 8.5 y para el periodo de largo plazo. Los valores de ϕ^{WW} se reducen de manera similar para ambas agregaciones temporales con prendidos entre el 0.04 % y el 6.03 %. Los resultados para el estadístico de ϕ^{DD} aumentan entre un 0.11 % y un 2.93 % para una agregación diaria, y entre 0.02 % y un 0.41 % para una agregación horaria.

- Los cambios en la varianza y la asimetría a ambas agregaciones temporales, sumado a la reducción en la precipitación media, y al cambio en la proporción de intervalos secos, indicaría que es probable que España presente un clima más seco y extremo en el futuro; siendo dicho cambio más intenso a medida que nos acerquemos a finales del siglo XXI y para el escenario RCP 8.5.
- Se ha analizado también la significancia en el cambio entre los distintos modelos climáticos regionales (RCMs) al mismo tiempo y para todos los estadísticos y estaciones pluviométricas por separado mediante el método Sgl (Jiang et al., 2015). Los resultados muestran valores de significancia negativa para la precipitación media (Sgl<-1) en un porcentaje muy elevado de estaciones, y para la mayoría de climas de España, entre los meses comprendidos entre abril y octubre. El porcentaje de estaciones (con significancia) es mucho mayor para el escenario RCP 8.5 y para los periodos de medio y largo plazo. Los resultados para los estadísticos Pdry y ϕ^{DD} muestran un comportamiento similar que la precipitación media, para ambas agregaciones temporales, pero en sentido opuesto. Para el estadístico ϕ^{WW} se obtuvieron valores de significancia negativa en un porcentaje elevado de estaciones y en la mayoría de climas; siendo dicho cambio más intenso para los climas más áridos (BSh y BWh) durante el invierno. En el resto de climas, el mayor porcentaje de estaciones con valores de significancia positiva (para el estadístico ϕ^{WW}) se presenta en los meses de verano. El número de estaciones con significancia es mayor a una agregación horaria que diaria para todos los climas. Para la asimetría únicamente se aprecian cambios significativos a una agregación horaria. Dichos cambio son positivos (Sgl>1) en la mayoría de climas y meses del año. El número de estaciones que muestra significancia es mayor para el RCP 8.5 y para los periodos de medio y de largo plazo. En el caso de la varianza, el número de estaciones con significancia es considerablemente mayor a una agregación horaria que a una agregación diaria. En todos los climas, excepto en los climas BSh y BWh, la varianza horaria aumenta (Sgl> 1) en los meses de otoño y de invierno y disminuye (Sgl< 1) en los meses de primavera y de verano. Como sucede en la mayoría de estadísticos, el número de estaciones con significancia en el cambio es mayor para los periodos de medio y de largo plazo y para el escenario RCP 8.5.
- A través de los resultados obtenidos llegamos a las mismas conclusiones que otros autores en el pasado (Merino et al., 2018; Scoccimarro et al., 2015; Utsumi et al.,

2011). La asimetría y la varianza, que son dos estadísticos altamente influenciados por los eventos más extremos de precipitación, aumentarán en la mayoría de climas de España para los meses menos calurosos (otoño e invierno). Sin embargo, dicho cambio muestra significancia, en la mayoría de estaciones, únicamente a una agregación horaria. La varianza se reduce para los climas más áridos (BSh y BWh) y en general en los meses de verano para todos los climas. Estos resultados podrían indicar que es probable que los eventos más extremos de precipitación se intensifiquen en la mayor parte de climas (exceptuando los climas más calurosos BSh y BWh) a una agregación horaria para las estaciones de otoño e invierno.

- El hecho de que no exista un acuerdo entre los estadísticos varianza y asimetría a una agregación diaria y horaria indica que la significancia en el cambio tiene que estar determinada principalmente por el aumento en la TAS y no por el cambio en los estadísticos diarios.
- Según la ecuación ECC, un aumento en las TAS de 1°C podría suponer un incremente en la cantidad de vapor de agua disponible en la atmósfera de entre un 6-7% y por consiguiente en los eventos extremos de precipitación (Drobinski et al., 2016). Sin embargo, algunos autores defienden que dicha relación podría no mantenerse o incluso ser inversa dependiendo del clima y agregación temporal analizada (Drobinski et al., 2018; Utsumi et al., 2011). Este mismo comportamiento lo hemos podido observar en España para los climas más áridos (BSh y BWh); la varianza horaria en estos climas se reduce en la mayoría de meses de año, mientras que en el resto de climas aumenta entre los meses de octubre y marzo. El número de estaciones con significancia en el cambio es mucho mayor a una agregación horaria que a una agregación diaria, lo que demuestra que en aquellos lugares con regímenes de precipitación como los de España, en los que en pocas horas puede precipitar una gran cantidad de agua, es fundamental analizar los efectos del cambio climático en los regímenes de precipitación a agregaciones temporales por debajo del día.
- Por último, se ha investigado la relación existente entre la varianza horaria y el percentil del 99% para la precipitación horaria (R99). A través de un análisis simplificado se ha calculado el cambio porcentual entre el R99 y la varianza horaria para diferentes escenarios de aumento de la TAS (0.5, 1, 1.5, 2, 2.5, 3, 3.5 y 4 °C). Los resultados muestran un incremento mayor en el R99 a medida que se incrementa la TAS. Sin embargo, el porcentaje de cambio en el R99 dependerá del régimen de precipitación concreto que estemos analizando y de la varianza horaria de la que partamos.

5.2. Contribuciones científicas

Gran parte de los resultados obtenidos durante la elaboración de la presente tesis han sido publicados en revistas internacionales de relevancia en el campo de la hidrología, ingeniería y de las ciencias atmosféricas, así como en congresos nacionales e internacionales. Durante la tesis se han desarrollado también software específicos y bases de datos de acceso público. Además durante el transcurso de la tesis el autor ha colaborado activamente en proyectos de Investigación, Desarrollo e innovación (I+D+i) así como en proyectos de transferencia.

5.2.1. Artículos

Durante la elaboración de la tesis se han realizado los siguientes artículos:

- La Sección 3.4, del Capítulo 3 se basa en los resultados publicados en el artículo "Diez-Sierra, J., del Jesus, M. A rainfall analysis and forecasting tool (2017) *Environmental Modelling and Software*, 97, pp. 243-258."
- La Sección 3.5, del Capítulo 3, se basa en los resultados disponibles en el artículo "Diez-Sierra, J., del Jesus, M. Long-tern rainfall prediction using atmospheric synoptic patterns in semi-arid climates with statistical and machine learning methods". Enviado recientemente a la revista *Journal of Hydrology*.
- La Sección 4.4, del Capítulo 4, se basa en los resultados publicados en el artículo "Diez-Sierra, J., del Jesus, M. Subdaily rainfall estimation through daily rainfall downscaling using random forests in Spain (2019) Water (Switzerland), 11 (1), art. no. 125,."
- La Sección 4.5, del Capítulo 4, se basa en los resultados disponibles en el artículo "Diez-Sierra, J., del Jesus, M. Daily-to-sub-daily rainfall statistics downscaling in Spain in the context of CORDEX initiative.". Artículo que será enviado en un corto espacio de tiempo a la revista *Internation Journal of Climatology*.

Adicionalmente, otros artículos publicados durante el transcurso de la tesis pero que no tienen relación directa con la misma son:

 Espejo, A., Mendez, F.J., Diez, J., Medina, R., Al-Yahyai, S. Seasonal probabilistic forecasting of tropical cyclone activity in the North Indian Ocean (2016) Journal of Flood Risk Management, 9 (4), pp. 379-389.

5.2.2. Congresos

Durante el transcurso de la tesis se han presentado los siguientes trabajos en congresos nacionales e internacionales:

- Parte de los resultados de Capítulo 3 fueron presentados en el congreso EGU (*European Geosciences Union*) 2017: "Characterizing rainfall in the Tenerife island. J. Díez-Sierra, M. del Jesus, I Losada Rodriguez EGU General Assembly Conference Abstracts 19, 17082".
- Parte de los resultados de Capítulo 3 fueron presentados en las Jornadas de Ingeniería del Agua (JIA) 2017: "Caracterización de patrones espacio-temporales de precipitación en la isla de Tenerife. J. Diez-Sierra, P. Delgado Melián y M. del Jesus".
- Parte de los resultados de Capítulo 4 fueron presentado en el congreso IAHR (*International Association for Hydro-Environment Engineering and Research*) 2018:
 "Regular and extreme daily rainfall prediction by Machine Learning techniques.
 J. Díez-Sierra and M. del Jesus".
- Parte de los resultados de Capítulo 4 fueron presentados en el EGU (*European Geosciences Union*) 2018: "Downscaling from daily to subdaily rainfall through regression based on large-scale atmospheric variables. J. Diez-Sierra and M. del Jesus EGU General Assembly Conference Abstracts Vol. 20, EGU2018-15703, 2018".
- Parte de los resultados de Capítulo 4 fueron presentados en el AEC (Asociación Española de Climatología) 2018: "Generación sintética de series de precipitación horarias, mediante modelos puntuales, en zonas sin información sub-diaria. J. Diez-Sierra and M. del Jesus".
- Parte de los resultados del Capítulo 4 fueron presentados en el EGU (*European Geosciences Union*) 2019: "Sub-daily rainfall downscaling using EURO-CORDEX regional climatic models in Spain. J. Diez-Sierra and M. del Jesus EGU General Assembly Conference Abstracts, 2019".
- Parte de los resultados del Capítulo 4 han sido aceptados para ser presentados en las próximas Jornadas de Ingeniería de Agua (JIA) 2019: "Generación de series de precipitación horarias en España para el clima presente y futuro. J. Diez-Sierra y M. del Jesus".

5.2.3. Proyectos I+D+i y de transferencia

Durante la realización de la tesis el autor de la misma ha colaborado en diferentes proyectos de I+D+i y de transferencia donde ha aplicado muchas de las técnicas desarrolladas durante el transcurso de la misma. Los principales proyectos son:

- "Servicio de caracterización de fenómenos meteorológicos adversos en Tenerife para el desarrollo de aplicaciones hidrológicas".
- "Evaluación del impacto del cambio climático en el recurso hidroeléctrico en España".
- "Análisis sobre la vulnerabilidad al cambio climático y medidas de adaptación de sistemas hidroeléctricos en países Andinos".
- "Análisis de la vulnerabilidad de las centrales hidroeléctricas priorizadas ante los efectos del cambio climático".
- "Plan nacional GESDIVAH (Generación Sintética de Distribuciones de Vegetación para Aplicaciones Hidrológicas)".
- "IVERCAM Project: Developing an approach to Implement Green Infrastructure networks as an adaptive measure against climate Change in Mountain areas of the Iberian Peninsula".
- "Implementación de la estrategia nacional de adaptación al cambio climático en Paraguay".
- "Pre-feasibility studies for the climate vulnerability reduction loan program for Belize: hazard modeling and cost benefit analysis of coastal and flooding risk reduction works".
- "Estudios de factibilidad técnica para la selección de alternativas para un puerto en Bluefilds, Nicaragua: cambio climático, huracanes, inundabilidad fluvial y tsunamis".
- "Estudios de Cambio Climático y desarrollo urbano para Campeche".
- "Estudios de desarrollo urbano y cambio climático en Santiago de los Caballeros (República Dominicana) - BID 3 ciudades".
- "Estudios de desarrollo urbano y cambio climático en Huancayo".
- "Estudios de desarrollo urbano y cambio climático en Santa Marta".
- "Implementación de las ICES (Evaluación de la Iniciativa Ciudades Emergentes y Sostenibles) en Santiago de los Caballeros".
- "Preparación del perfil de riesgo multiamenaza y el plan de gestión de riesgos de Portmore".

- "Estudios de desarrollo urbano y cambio climático en Cumaná (Venezuela)".
- "Estudios de desarrollo urbano y cambio climático en Bridgetown (Barbados)".
- "Assessment of climate impacts on coastal system in EU".

5.2.4. Software desarrollado

Para la realización de la tesis se han desarrollado diferentes software que han servido para alcanzar los objetivos marcados. Los más importantes son:

- En el Capítulo 3 se presenta la aplicación MENSEI-L para el tratamiento, análisis y predicción de la precipitación. La aplicación ha sido implementada en el CIATF (Consejo Insular de Aguas de Tenerife) y permanece activa desde el verano de 2016. MENSEI-L está programada en los lenguajes de programación python (Python Software Foundation, 2016) y R (R Core Team, 2015) y ha sido desarrollada mediante la librería wxWidgets (Smart et al., 2005). La aplicación se distribuye para fines de investigación solicitándola a los autores (manuel.deljesus@unican.es, javier.diez@unican.es).
- En el Capítulo 4 se hace uso de se del generador sintético de precipitación NSRP (Neyman-Scott Rectangular Pulses; Burton et al. 2008). Para poder realizar los diferentes análisis el autor ha programado dicho modelo en el lenguaje de programación python (Python Software Foundation, 2016). La aplicación se distribuye para fines de investigación solicitándola a los autores (manuel.deljesus@unican.es, javier.diez@unican.es).

5.2.5. Bases de datos desarrolladas

Algunos de los análisis realizados durante el desarrollo de la tesis han dado como resultado bases de datos de acceso público que pueden ser utilizadas para fines de investigación. Las más importantes son:

- Los estadísticos de precipitación de las series instrumentales horarias utilizados para calibrar los modelos en el Capítulo 4 están publicados en Diez-Sierra y del Jesus (2019B1).
- Los estadísticos de precipitación simulados para el clima presente y para los diferentes escenarios de cambio climático están publicados en Diez-Sierra y del Jesus (2019B2).

5.3. Futuras líneas de investigación

La presente tesis doctoral cubre algunas de las carencias detectadas en las materias de la predicción de la precipitación, de la desagregación, y de la precipitación en un contexto de cambio climático. Sin embargo, aún quedan muchos frentes abiertos a los que sería conveniente dedicar tiempo y esfuerzo en el futuro para seguir avanzando en dichas materias. El aspecto más importante a tratar en un futuro próximo sería investigar la manera en la que incorporar la dimensión espacial en las diferentes técnicas y metodologías analizadas durante el documento. Aunque se ha demostrado que algunas de ellas son capaces de conservar las relaciones espaciales de las series observadas, dichas relaciones no han sido incluidas específicamente en los diferentes análisis.

De igual manera que en el apartado 5.1, "Conclusiones principales", a continuación se describen las principales líneas de investigación relativas a cada uno de los cuatro grandes bloques de la tesis.

En relación a la Sección 3.4 "Predicción probabilística a corto plazo basada en tipos de tiempo", se proponen las siguientes líneas de investigación:

- Una de las principales limitaciones de las técnicas geoestadísticas es que en aquellas áreas donde hay un bajo número de estaciones la calidad de las predicciones se ve fuertemente afectada por la ausencia de datos (Beguería et al., 2016). En dichas áreas, habría que utilizar técnicas de interpolación que además de información topográfica también integraran variables climáticas, como covariables, para capturar así la variabilidad espacial subyacente en la precipitación (Daly et al., 2008; Isotta et al., 2014). Una posible línea de investigación futura sería investigar la forma en la que se podría ajustar un variograma diferente para cada tipo de tormenta (frontal, convectiva, etc.).
- Las técnicas geoestadísticas de interpolación han sido validadas a nivel puntual mediante la técnica de validación cruzada *leave-one-out*. Sin embargo, con el objetivo de validar las técnicas de interpolación a nivel espacial sería más aconsejable utilizar modelos hidrológicos distribuidos.
- Para mejorar la predicción de la precipitación basada en tipos de tiempo, sería conveniente utilizar bases de datos atmosféricas de reanálisis con mayor resolución espacio-temporal que capturasen mejor los procesos locales que tienen lugar en la isla. Además, sería interesante ver qué otras variables atmosféricas podrían ayudar a los algoritmos a llevar a cabo una mejor clasificación de los tipos de tiempo.

• En cuanto al sistema de predicción de precipitación cualitativo, se investigarán nuevas técnicas de aprendizaje automatizado supervisadas que consideren el objetivo final, que no es otro que dar una mejor predicción del riesgo real de inundación.

En relación a la Sección 3.5 "Predicción a largo plazo mediante modelos estadísticos y máquinas de aprendizaje automatizado", se proponen las siguientes líneas de investigación:

- Se ha demostrado que los modelos (regresores y clasificadores) no son capaces de conservar la correlación espacial observada a distancias inferiores a los 10 km debido a que son ajustados de manera independiente para cada estación. La incorporación de modelos conceptuales de precipitación espacio-temporales mediante cópulas, o a través de otras técnicas de aprendizaje automatizado profundo (*deep learning*), podrían mejorar estos resultados y serán consideradas en futuros trabajos (Stehlík y Bárdossy, 2002; Yang et al., 2005).
- La misma metodología utilizada para la predicción a largo plazo de la precipitación podría ser utilizada en un contexto de cambio climático incorporando en los predictores los resultados de los diferentes modelos climáticos. Sería muy interesante analizar las diferencias entre los resultados de precipitación obtenidos mediante esta metodología con las propias salidas de precipitación de los modelos climáticos.
- Todas las técnicas analizadas para predecir la precipitación a largo plazo subestiman los valores de varianza de las series observadas así como lo eventos más extremos de precipitación. Otros enfoques como el uso de distribuciones mixtas (Jeffries y Pfeiffer, 2001; Mínguez et al., 2013) o mediante la incorporación de otro tipo de funciones de minimización serán investigadas en el futuro.

En relación a la Sección 4.4 "Desagregación temporal de la precipitación en España para el clima presente", se proponen las siguientes líneas de investigación:

- Se investigarán otras variables explicativas, como variables atmosféricas o geográficas, que puedan servir para entender mejor la relación entre los estadísticos de precipitación a diferentes agregaciones temporales.
- Los métodos han sido validados únicamente en España. Es por ello que sería interesante tratar de generalizarlos utilizando estaciones con información horaria distribuidas por todo el mundo.

Se ha investigado las relaciones entre los estadísticos de precipitación a diferentes agregaciones temporales a nivel puntual para cada pluviómetro por separado. En el futuro extenderemos el trabajo en su dimensión espacial mediante la incorporación de la correlación espacial en los diferentes análisis. Esto permitiría simular campos espaciales sintéticos de precipitación mediante el modelo espacial STNSRP (Spatial-Temporal Neyman-Scott Rectangular Pulses, Burton et al. 2008).

En relación a la Sección 4.5 "Desagregación temporal de la precipitación en España en un contexto de cambio climático", se proponen las siguientes líneas de investigación:

- La clasificación climática de Köppen-Geiger no parece agrupar correctamente los diferentes regímenes de precipitación presentes en España, lo que podría estar deteriorando los resultados. Sería aconsejable buscar otro tipo de criterio de agrupación basado en técnicas de clusterización, o en base a los propios estadísticos de las series de precipitación, para clasificar las estaciones en función de su régimen de precipitación.
- Se ha demostrado la relación existente entre la varianza horaria, el percentil del 99% de la precipitación horaria (R99) y la temperatura superficial del aire (TAS) a través de un análisis simplificado. Habría que investigar si realmente dicha relación permanecerá constante en el futuro y como podría variar dependiendo del clima analizado.
- Hay que tener en cuenta que los resultados están promediados para todos las estaciones y climas, y que además únicamente se está teniendo en cuenta el afecto de la varianza horaria en el percentil R99. Sería aconsejable utilizar un enfoque basado en generadores sintéticos (Diez-Sierra y del Jesus, 2019) para evaluar el cambio en los extremos de precipitación directamente sobre las series sintéticas simuladas.
- La hipótesis de partida, que se basa en que para el clima futuro la relación entre los estadísticos a diferentes agregaciones temporales es la misma que para el clima presente, podría tener sentido en España, donde muchas de las estaciones analizadas podrían migrar hacia climas más áridos. Sin embargo, habría que investigar si realmente están cambiando los patrones de precipitación y si dicho cambio es como consecuencia directa del calentamiento global.
- Las bases de datos de estadísticos de precipitación desarrolladas para el clima presente y los diferentes escenarios de cambio climático son muy interesantes desde un punto de vista científico, pero no desde un punto de vista práctico. En el futuro se desarrollará una aplicación web, que se alimente de los estadísticos de precipitación

generados en la presente tesis, y que simule series sintéticas horarias de miles de años en cualquier localización de España con información diaria mediante el uso de generadores sintéticos.

Bibliografía

- Abdi, H., Williams, L.J., 2010. Principal component analysis. Wiley Interdisciplinary Reviews: Computational Statistics 2, 433–459.
- AEMeT, Agencia Estatal de Meteorología. http://www.aemet.es/en/portada. Accessed: 2018-07-04.
- AEMeT, 2011. Iberian climate atlas. Agencia Estatal de Meteorología (España) and Instituto de Meteorología (Portugal), Madrid, Spain.
- Aissia, M.A.B., Chebana, F., Ouarda, T.B., 2017. Multivariate missing data in hydrology – review and applications. Advances in Water Resources 110, 299 – 309.
- Akaike, H., 1974. A new look at the statistical model identification. IEEE transactions on automatic control 19, 716–723.
- Alizadeh, Z., Yazdi, J., Kim, J.H., Al-Shamiri, A.K., 2018. Assessment of machine learning techniques for monthly flow prediction. Water 10.
- Allamano, P., Croci, A., Laio, F., 2015. Toward the camera rain gauge. Water Resources Research 51, 1744–1757.
- Altunkaynak, A., Nigussie, T., 2015. Prediction of daily rainfall by a hybrid waveletseason-neuro technique. Journal of Hydrology 529, 287–301.
- Appelhans, T., Mwangomo, E., Hardy, D., Hemp, A., Nauss, T., 2015. Evaluating machine learning approaches for the interpolation of monthly air temperature at mt. kilimanjaro, tanzania. Spatial Statistics 14, 91–113.
- Austin, G., Seed, A., 2005. Special issue on the hydrological applications of weather radar guest editors' preface. Atmospheric Science Letters 6, 1.
- Baarsch, J., Celebi, M., 2012. Investigation of internal validity measures for k-means clustering, pp. 471–476.
- Beguería, S., Angulo-Martínez, M., Vicente-Serrano, S., López-Moreno, J., El-Kenawy, A., 2011. Assessing trends in extreme precipitation events intensity and magnitude

using non-stationary peaks-over-threshold analysis: A case study in northeast spain from 1930 to 2006. International Journal of Climatology 31, 2102–2114.

- Beguería, S., Vicente-Serrano, S., Tomás-Burguera, M., Maneta, M., 2016. Bias in the variance of gridded data sets leads to misleading conclusions about changes in climate variability. International Journal of Climatology 36, 3413–3422.
- Ben Alaya, M., Ouarda, T., Chebana, F., 2017. Non-gaussian spatiotemporal simulation of multisite daily precipitation: downscaling framework. Climate Dynamics , 1–15.
- Beuchat, X., Schaefli, B., Soutter, M., Mermoud, A., 2011. Toward a robust method for subdaily rainfall downscaling from daily data. Water Resources Research 47.
- Bosilovich, M., Chen, J., Robertson, F., Adler, R., 2008. Evaluation of global precipitation in reanalyses. Journal of Applied Meteorology and Climatology 47, 2279–2299.
- Breiman, L., 2001. Random forests. Machine Learning 45, 5–32.
- Burlando, P., Rosso, R., 1996. Scaling and multiscaling models of depth-durationfrequency curves for storm precipitation. Journal of Hydrology 187, 45–64.
- Burton, A., Fowler, H., Blenkinsop, S., Kilsby, C., 2010. Downscaling transient climate change using a neyman-scott rectangular pulses stochastic rainfall model. Journal of Hydrology 381, 18–32.
- Burton, A., Kilsby, C., Fowler, H., Cowpertwait, P., O'Connell, P., 2008. Rainsim: A spatial-temporal stochastic rainfall modelling system. Environmental Modelling and Software 23, 1356 – 1369.
- Cáceres, M.D., Martin-StPaul, N., Turco, M., Cabon, A., Granda, V., 2018. Estimating daily meteorological data and downscaling climate models over landscapes. Environmental Modelling and Software 108, 186 – 196.
- Camus, P., Mendez, F., Medina, R., Cofiño, A., 2011a. Analysis of clustering and selection algorithms for the study of multivariate wave climate. Coastal Engineering 58, 453–462.
- Camus, P., Mendez, F.J., Medina, R., Cofiño, A.S., 2011b. Analysis of clustering and selection algorithms for the study of multivariate wave climate. Coastal Engineering 58, 453–462.
- Cannon, A., Sobie, S., Murdock, T., 2015. Bias correction of gcm precipitation by quantile mapping: How well do methods preserve changes in quantiles and extremes? Journal of Climate 28, 6938–6959.

- CHC, Confederación Hidrográfica del Cantábrico. https://www.chcantabrico.es/. Accessed: 2018-07-04.
- CHE, Confederación Hidrográfica del Ebro. http://www.chebro.es/. Accessed: 2018-07-04.
- Cherkassky, V., Ma, Y., 2004. Practical selection of svm parameters and noise estimation for svm regression. Neural networks : the official journal of the International Neural Network Society 17 1, 113–26.
- CHJ, . Confederación Hidrográfica del Jucar. https://www.chj.es/es-es/Organismo/ Paginas/Organismo.aspx. Accessed: 2018-07-04.
- CHMS, . Confederación Hidrográfica del Miño-Sil. https://www.chminosil.es/es/. Accessed: 2018-07-04.
- CHS, . Confederación Hidrográfica del Segura. https://www.chsegura.es/chs/index. html. Accessed: 2018-07-04.
- CMA, . Cuenca Mediterránea Andaluza. http://hispagua.cedex.es/instituciones/ confederaciones/andalucia. Accessed: 2018-07-04.
- Coe, R., Stern, R., 1982. Fitting models to daily rainfall data., pp. 1024–1031.
- Cowpertwait, P., 1991. Further developments of the neyman-scott clustered point process for modeling rainfall. Water Resources Research 27, 1431–1438.
- Cowpertwait, P., 1995. A generalized spatial-temporal model of rainfall based on a clustered point process. Proceedings Royal Society of London, A 450, 163–175.
- Cowpertwait, P., 1998. A poisson-cluster model of rainfall: High-order moments and extreme values. Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences 454, 885–898.
- Cowpertwait, P., 2006. A spatial-temporal point process model of rainfall for the thames catchment, uk. Journal of Hydrology 330, 586–595.
- Cowpertwait, P., Kilsby, C., O'Connell, P., 2002. A space-time neyman-scott model of rainfall: Empirical analysis of extremes. Water Resources Research 38, 61–614.
- Cowpertwait, P., Ocio, D., Collazos, G., De Cos, O., Stocker, C., 2013. Regionalised spatiotemporal rainfall and temperature models for flood studies in the basque country, spain. Hydrology and Earth System Sciences 17, 479–494.
- Cowpertwait, P., O'Connell, P., Metcalfe, A., Mawdsley, J., 1996a. Stochastic point process modelling of rainfall. i. single-site fitting and validation. Journal of Hydrology 175, 17–46.

- Cowpertwait, P., O'Connell, P., Metcalfe, A., Mawdsley, J., 1996b. Stochastic point process modelling of rainfall. ii. regionalisation and disaggregation. Journal of Hydrology 175, 47–65.
- Craven, P., Wahba, G., 1978. Smoothing noisy data with spline functions. Numerische mathematik 31, 377–403.
- Daly, C., Halbleib, M., Smith, J., Gibson, W., Doggett, M., Taylor, G., Curtis, J., Pasteris, P., 2008. Physiographically sensitive mapping of climatological temperature and precipitation across the conterminous united states. International Journal of Climatology 28, 2031–2064.
- De Michele, C., Kottegoda, N., Rosso, R., 2001. The derivation of areal reduction factor of storm rainfall from its scaling properties. Water Resources Research 37, 3247–3252.
- Dee, D., Uppala, S., Simmons, A., Berrisford, P., Poli, P., Kobayashi, S., Andrae, U., Balmaseda, M., Balsamo, G., Bauer, P., Bechtold, P., Beljaars, A., van de Berg, L., Bidlot, J., Bormann, N., Delsol, C., Dragani, R., Fuentes, M., Geer, A., Haimberger, L., Healy, S., Hersbach, H., Hólm, E., Isaksen, L., Kållberg, P., Köhler, M., Matricardi, M., Mcnally, A., Monge-Sanz, B., Morcrette, J.J., Park, B.K., Peubey, C., de Rosnay, P., Tavolato, C., Thépaut, J.N., Vitart, F., 2011. The era-interim reanalysis: Configuration and performance of the data assimilation system. Quarterly Journal of the Royal Meteorological Society 137, 553–597.
- Diez-Sierra, J., del Jesus, M., 2017. A rainfall analysis and forecasting tool. Environmental Modelling and Software 97, 243–258.
- Diez-Sierra, J., del Jesus, M., 2019. Subdaily rainfall estimation through daily rainfall downscaling using random forests in spain. Water (Switzerland) 11.
- Diez-Sierra, J., del Jesus, M.B., 2019B1. Sub-daily rainfall statistic database for spain. https://osf.io/2vhn9/?view_only=7fb00bb7356443a39743520ec1b80a56.
- Diez-Sierra, J., del Jesus, M.B., 2019B2. Sub-daily and supra-daily rainfall database for the present and for future climate change scenarios for spain. https://osf.io/ 3t7gs/?view_only=7101075da8be49da902d05968edcba00.
- Donat, M., Sillmann, J., Wild, S., Alexander, L., Lippmann, T., Zwiers, F., 2014. Consistency of temperature and precipitation extremes across various global gridded in situ and reanalysis datasets. Journal of Climate 27, 5019–5035.
- Drobinski, P., Alonzo, B., Bastin, S., Da Silva, N., Muller, C., 2016. Scaling of precipitation extremes with temperature in the french mediterranean region: What explains the hook shape? Journal of Geophysical Research 121, 3100–3119.

- Drobinski, P., Silva, N., Panthou, G., Bastin, S., Muller, C., Ahrens, B., Borga, M., Conte, D., Fosser, G., Giorgi, F., Güttler, I., Kotroni, V., Li, L., Morin, E., Önol, B., Quintana-Segui, P., Romera, R., Torma, C., 2018. Scaling precipitation extremes with temperature in the mediterranean: past climate assessment and projection in anthropogenic scenarios. Climate Dynamics 51, 1237–1257.
- Eagleson, P., 1972. Dynamics of flood frequency. Water Resources Research 8, 878–898.
- Eum, H.I., Cannon, A., Murdock, T., 2017. Intercomparison of multiple statistical downscaling methods: multi-criteria model selection for south korea. Stochastic Environmental Research and Risk Assessment 31, 683–703.
- Fang, G., Yang, J., Chen, Y., Zammit, C., 2015. Comparing bias correction methods in downscaling meteorological variables for a hydrologic impact study in an arid area in china. Hydrology and Earth System Sciences 19, 2547–2559.
- Friedman, J., Roosen, C., 1995. An introduction to multivariate adaptive regression splines. Statistical Methods in Medical Research 4, 197–217.
- Friedman, J.H., 1991. Multivariate adaptive regression splines. The annals of statistics , 1–67.
- García-Herrera, R., Gallego, D., Hernández, E., Gimeno, L., Ribera, P., Calvo, N., 2003. Precipitation trends in the canary islands. International Journal of Climatology 23, 235–241.
- Garijo, C., Mediero, L., 2018. Quantification of the expected changes in annual maximum daily precipitation quantiles under climate change in the iberian peninsula. Proceedings of 3rd International Electronic Conference on Water Sciences (ECWS-3), 1 doi:10.3390/ECWS-3-05819.
- Geiger, R., 1961. Überarbeitete neuausgabe von geiger, r.: Köppen-geiger/klima der erde (revised new edition of climate of the earth). Überarbeitete Neuausgabe von Geiger, R.: Köppen-Geiger/Klima der Erde .
- Glasbey, C., Cooper, G., McGechan, M., 1995. Disaggregation of daily rainfall by conditional simulation from a point-process model. Journal of Hydrology 165, 1–9.
- Glenis, V., Pinamonti, V., Hall, J.W., Kilsby, C.G., 2015. A transient stochastic weather generator incorporating climate model uncertainty. Advances in Water Resources 85, 14 – 26.
- Gonçalves, M., Barrera-Escoda, A., Guerreiro, D., Baldasano, J., Cunillera, J., 2014. Seasonal to yearly assessment of temperature and precipitation trends in the north

western mediterranean basin by dynamical downscaling of climate scenarios at high resolution (1971-2050). Climatic Change 122, 243–256.

- Goovaerts, P., 1997. Geostatistics for natural resources evaluation. Oxford University Press on Demand.
- Goovaerts, P., 2000. Geostatistical approaches for incorporating elevation into the spatial interpolation of rainfall. Journal of hydrology 228, 113–129.
- Guanche, Y., Guanche, R., Camus, P., Mendez, F., Medina, R., 2013. A multivariate approach to estimate design loads for offshore wind turbines. Wind Energy 16, 1091– 1106.
- Gupta, D., Ghose, U., 2015. A comparative study of classification algorithms for forecasting rainfall.
- Gupta, V., Waymire, E., 1993. A statistical analysis of mesoscale rainfall as a random cascade. Journal of Applied Meteorology 32, 251–267.
- Gutiérrez, J., Cofino, A., Cano, R., Rodríguez, M., 2004. Clustering methods for statistical downscaling in short-range weather forecasts. Monthly Weather Review 132, 2169–2183.
- Gómez-navarro, J., Montávez, J., Jimenez-Guerrero, P., Jerez, S., García-valero, J., GonzáLez-Rouco, J., 2010. Warming patterns in regional climate change projections over the iberian peninsula. Meteorologische Zeitschrift 19, 275–285.
- Haerter, J., Berg, P., 2009. Unexpected rise in extreme precipitation caused by a shift in rain type? Nature Geoscience 2, 372–373. doi:10.1038/ngeo523.
- Hastie, T., Friedman, 2009. The Elements of Statistical Learning (2nd edition).
- Hawkins, E., Sutton, R., 2011. The potential to narrow uncertainty in projections of regional precipitation change. Climate Dynamics 37, 407–418.
- He, X., Chaney, N., Schleiss, M., Sheffield, J., 2016. Spatial downscaling of precipitation using adaptable random forests. Water Resources Research 52, 8217–8237.
- He, X., Guan, H., Qin, J., 2015. A hybrid wavelet neural network model with mutual information and particle swarm optimization for forecasting monthly rainfall. Journal of Hydrology 527, 88 100.
- He, Y., Zhang, Y., Kuligowski, R., Cifelli, R., Kitzmiller, D., 2018. Incorporating satellite precipitation estimates into a radar-gauge multi-sensor precipitation estimation algorithm. Remote Sensing 10.

- Herrera, R.G., Puyol, D.G., MartÍn, E.H., Presa, L.G., Rodríguez, P.R., 2001. Influence of the north atlantic oscillation on the canary islands precipitation. Journal of climate 14, 3889–3903.
- Herrera, S., Gutiérrez, J.M., Ancell, R., Pons, M., Frías, M., Fernández, J., 2012a. Development and analysis of a 50-year high-resolution daily gridded precipitation dataset over spain (spain02). International Journal of Climatology 32, 74–85.
- Herrera, S., Gutiérrez, J., Ancell, R., Pons, M., Frías, M., Fernández, J., 2012b. Development and analysis of a 50-year high-resolution daily gridded precipitation dataset over spain (spain02). International Journal of Climatology 32, 74–85.
- Hershenhorn, J., Woolhiser, D., 1987. Disaggregation of daily rainfall. Journal of Hydrology 95, 299–322.
- Hofstra, N., Haylock, M., New, M., Jones, P., Frei, C., 2008. Comparison of six methods for the interpolation of daily, european climate data. Journal of Geophysical Research Atmospheres 113.
- Holm, S., 1979. A simple sequentially rejective multiple test procedure. Scandinavian Journal of Statistics 6, 65–70.
- Hong, W.C., 2008. Rainfall forecasting by technological machine learning models. Applied Mathematics and Computation 200, 41–57. doi:10.1016/j.amc.2007.10.046.
- Horton, P., Obled, C., Jaboyedoff, M., 2017. The analogue method for precipitation prediction: Finding better analogue situations at a sub-daily time step. Hydrology and Earth System Sciences 21, 3307–3323.
- Hu, Z., Hu, Q., Zhang, C., Chen, X., Li, Q., 2016. Evaluation of reanalysis, spatially interpolated and satellite remotely sensed precipitation data sets in central asia. Journal of Geophysical Research 121, 5648–5663.
- Huffman, G., Adler, R., Bolvin, D., Gu, G., Nelkin, E., Bowman, K., Hong, Y., Stocker, E., Wolff, D., 2007. The trmm multisatellite precipitation analysis (tmpa): Quasiglobal, multiyear, combined-sensor precipitation estimates at fine scales. Journal of Hydrometeorology 8, 38–55.
- Huffman, G., Adler, R., Bolvin, D., Nelkin, E., 2010. The TRMM Multi-satellite Precipitation Analysis (TMPA).
- Huth, R., Beck, C., Philipp, A., Demuzere, M., Ustrnul, Z., Cahynová, M., Kyselý, J., Tveito, O.E., 2008. Classifications of atmospheric circulation patterns. Annals of the New York Academy of Sciences 1146, 105–152.

- Isotta, F., Frei, C., Weilguni, V., Perčec Tadić, M., Lassègues, P., Rudolf, B., Pavan, V., Cacciamani, C., Antolini, G., Ratto, S., Munari, M., Micheletti, S., Bonati, V., Lussana, C., Ronchi, C., Panettieri, E., Marigo, G., Vertačnik, G., 2014. The climate of daily precipitation in the alps: Development and analysis of a high-resolution grid dataset from pan-alpine rain-gauge data. International Journal of Climatology 34, 1657–1675.
- Iturbide, M., Bedia, J., Herrera, S., Baño-Medina, J., Fernández, J., Frías, M., Manzanas, R., San-Martín, D., Cimadevilla, E., Cofiño, A., Gutiérrez, J., 2019. The r-based climate4r open framework for reproducible climate data access and post-processing. Environmental Modelling and Software 111, 42–54.
- Izaguirre, C., Menéndez, M., Camus, P., Méndez, F., Mínguez, R., Losada, I., 2012. Exploring the interannual variability of extreme wave climate in the northeast atlantic ocean. Ocean Modelling 59-60, 31–40.
- Jacob, D., Petersen, J., Eggert, B., Alias, A., Christensen, O., Bouwer, L., Braun, A., Colette, A., Déqué, M., Georgievski, G., Georgopoulou, E., Gobiet, A., Menut, L., Nikulin, G., Haensler, A., Hempelmann, N., Jones, C., Keuler, K., Kovats, S., Kröner, N., Kotlarski, S., Kriegsmann, A., Martin, E., van Meijgaard, E., Moseley, C., Pfeifer, S., Preuschmann, S., Radermacher, C., Radtke, K., Rechid, D., Rounsevell, M., Samuelsson, P., Somot, S., Soussana, J.F., Teichmann, C., Valentini, R., Vautard, R., Weber, B., Yiou, P., 2014. Euro-cordex: New high-resolution climate change projections for european impact research. Regional Environmental Change 14, 563–578.
- Jeffries, N., Pfeiffer, R., 2001. A mixture model for the probability distribution of rain rate. Environmetrics: The official journal of the International Environmetrics Society 12, 1–10.
- del Jesus, M., Rinaldo, A., Rodríguez-Iturbe, I., 2015. Point rainfall statistics for ecohydrological analyses derived from satellite integrated rainfall measurements. Water Resources Research 51, 2974–2985.
- Jiang, Z., Li, W., Xu, J., Li, L., 2015. Extreme precipitation indices over china in cmip5 models. part i: Model evaluation. Journal of Climate 28, 8603–8619.
- Journel, A.G., Huijbregts, C.J., 1978. Mining geostatistics. Academic press.
- Kalnay, E., Kanamitsu, M., Kistler, R., Collins, W., Deaven, D., Gandin, L., Iredell, M., Saha, S., White, G., Woollen, J., Zhu, Y., Chelliah, M., Ebisuzaki, W., Higgins, W., Janowiak, J., Mo, K., Ropelewski, C., Wang, J., Leetmaa, A., Reynolds, R., Jenne, R., Joseph, D., 1996. The ncep/ncar 40-year reanalysis project. Bulletin of the American Meteorological Society 77, 437–471.

- Kannan, S., Ghosh, S., 2013. A nonparametric kernel regression model for downscaling multisite daily precipitation in the mahanadi basin. Water Resources Research 49, 1360–1385. doi:10.1002/wrcr.20118.
- Kidd, C., Levizzani, V., Laviola, S., 2010. Quantitative precipitation estimation from Earth observation satellites. pp. 127–158.
- Kim, J.E., Joan Alexander, M., 2013. Tropical precipitation variability and convectively coupled equatorial waves on submonthly time scales in reanalyses and trmm. Journal of Climate 26, 3013–3030.
- Kohonen, T., 1990. The self-organizing map. Proceedings of the IEEE 78, 1464–1480. doi:10.1109/5.58325.
- Krajewski, W., Smith, J., 2002. Radar hydrology: Rainfall estimation. Advances in Water Resources 25, 1387–1394.
- Krzysztofowicz, R., 1995. Recent advances associated with flood forecast and warning systems. Reviews of Geophysics 33, 1139–1147.
- Kun, Y., Giuliano, D.B., Florian, P., 2018. Flood Hazard Mapping in Data-Scarce Areas. American Geophysical Union (AGU). chapter 5. pp. 79–86.
- Laprise, R., Hernández-Díaz, L., Tete, K., Sushama, L., Šeparović, L., Martynov, A., Winger, K., Valin, M., 2013. Climate projections over cordex africa domain using the fifth-generation canadian regional climate model (crcm5). Climate Dynamics 41, 3219–3246.
- Lenderink, G., Barbero, R., Loriaux, J., Fowler, H., 2017. Super-clausius-clapeyron scaling of extreme hourly convective precipitation and its relation to large-scale atmospheric conditions. Journal of Climate 30, 6037–6052.
- Lenderink, G., Van Meijgaard, E., 2008. Increase in hourly precipitation extremes beyond expectations from temperature changes. Nature Geoscience 1, 511–514.
- Lenderink, G., Van Meijgaard, E., 2009. Unexpected rise in extreme precipitation caused by a shift in rain type? Nature Geoscience 2, 373.
- Leonard, M., Lambert, M., Metcalfe, A., Cowpertwait, P., 2008. A space-time neymanscott rainfall model with defined storm extent. Water Resources Research 44.
- Li, J., Johnson, F., Evans, J., Sharma, A., 2017. A comparison of methods to estimate future sub-daily design rainfall. Advances in Water Resources 110, 215 – 227.

- Li, X., Meshgi, A., Wang, X., Zhang, J., Tay, S., Pijcke, G., Manocha, N., Ong, M., Nguyen, M., Babovic, V., 2018. Three resampling approaches based on method of fragments for daily-to-subdaily precipitation disaggregation. International Journal of Climatology 38, e1119–e1138.
- Liu, J., Bray, M., Han, D., 2013. A study on wrf radar data assimilation for hydrological rainfall prediction. Hydrology and Earth System Sciences 17, 3095–3110.
- Lu, Y., Qin, X., 2014. Multisite rainfall downscaling and disaggregation in a tropical urban area. Journal of Hydrology 509, 55–65.
- López-Franca, N., Sánchez, E., Losada, T., Domínguez, M., Romera, R., Gaertner, M., 2015. Markovian characteristics of dry spells over the iberian peninsula under present and future conditions using escena ensemble of regional climate models. Climate Dynamics 45, 661–677.
- Mandelbrot, B.B., Wallis, J.R., 1968. Noah, joseph, and operational hydrology. Water Resources Research 4, 909–918.
- Marani, M., 2005. Non-power-law scale properties of rainfall in space and time. Water Resources Research 41, 1–10.
- Marani, M., Zanetti, S., 2007. Downscaling rainfall temporal variability. Water Resources Research 43.
- Maraun, D., Huth, R., Gutiérrez, J.M., Martín, D.S., Dubrovsky, M., Fischer, A., Hertig,
 E., Soares, P.M.M., Bartholy, J., Pongrácz, R., Widmann, M., Casado, M.J., Ramos,
 P., Bedia, J., 2016. The value perfect predictor experiment: evaluation of temporal variability. International Journal of Climatology 0.
- Markatou, M., Tian, H., Biswas, S., Hripcsak, G., 2005. Analysis of variance of crossvalidation estimators of the generalization error. Journal of Machine Learning Research 6.
- Martin-Vide, J., 2004. Spatial distribution of a daily precipitation concentration index in peninsular spain. International Journal of Climatology 24, 959–971.
- Mattera, D., Haykin, S., 1999. Advances in kernel methods, MIT Press, Cambridge, MA, USA. chapter Support Vector Machines for Dynamic Reconstruction of a Chaotic System, pp. 211–241.
- Melián, P.D., Ruiz, J.J.B., Díez, A.M., Salete, E.G., 2011. "Módulo de gestión de tormentas" en la modelización hidrológica de superficie de tenerife, in: II Jornadas de Ingeniería del Agua, Fundación para el Fomento de la Ingeniería del Agua, Barcelona, Spain.

- Méndez, F., Menéndez, M., Luceño, A., Losada, I., 2007. Analyzing monthly extreme sea levels with a time-dependent gev model. Journal of Atmospheric and Oceanic Technology 24, 894–911.
- Menne, M., Durre, I., Vose, R., Gleason, B., Houston, T., 2012. An overview of the global historical climatology network-daily database. Journal of Atmospheric and Oceanic Technology 29, 897–910.
- Merino, A., Fernández-González, S., García-Ortega, E., Sánchez, J., López, L., Gascón, E., 2018. Temporal continuity of extreme precipitation events using sub-daily precipitation: application to floods in the ebro basin, northeastern spain. International Journal of Climatology 38, 1877–1892.
- Merino, A., Fernández-Vaquero, M., López, L., Fernández-González, S., Hermida, L., Sánchez, J., García-Ortega, E., Gascón, E., 2016. Large-scale patterns of daily precipitation extremes on the iberian peninsula. International Journal of Climatology 36, 3873–3891.
- Meseguer-Ruiz, O., Olcina Cantos, J., Sarricolea, P., Martín-Vide, J., 2017. The temporal fractality of precipitation in mainland spain and the balearic islands and its relation to other precipitation variability indices. International Journal of Climatology 37, 849–860.
- Michaud, J., Sorooshian, S., 1994. Effect of rainfall sampling errors on simulations of desert flash floods. Water Resources Research 30, 2765–2775.
- Mínguez, R., Tomás, A., Méndez, F., Medina, R., 2013. Mixed extreme wave climate model for reanalysis databases. Stochastic Environmental Research and Risk Assessment 27, 757–768.
- Monira, S., Faisal, Z., Hirose, H., 2010. Comparison of artificially intelligent methods in short term rainfall forecast, pp. 39–44.
- Monjo, R., Gaitán, E., Pórtoles, J., Ribalaygua, J., Torres, L., 2016. Changes in extreme precipitation over spain using statistical downscaling of cmip5 projections. International Journal of Climatology 36, 757–769.
- Moser, B., Gallus, W.A., J., Mantilla, R., 2015. An initial assessment of radar data assimilation on warm season rainfall forecasts for use in hydrologic models. Weather and Forecasting 30, 1491–1520.
- Muller, K., Peterson, B., 1984. Practical methods for computing power in testing the multivariate general linear hypothesis. Computational Statistics and Data Analysis 2, 143–158.

- Muñoz, P., Orellana-Alvear, J., Willems, P., Célleri, R., 2018. Flash-flood forecasting in an andean mountain catchment—development of a step-wise methodology based on the random forest algorithm. Water 10.
- Neiman, P., White, A., Ralph, F., Gottas, D., Gutman, S., 2009. A water vapour flux tool for precipitation forecasting. Proceedings of the Institution of Civil Engineers: Water Management 162, 83–94.
- Ninyerola, M., Pons, X., Roure, J., 2007. Monthly precipitation mapping of the iberian peninsula using spatial interpolation tools implemented in a geographic information system. Theoretical and Applied Climatology 89, 195–209.
- Noor, M., Ismail, T., Chung, E.S., Shahid, S., Sung, J.H., 2018. Uncertainty in rainfall intensity duration frequency curves of peninsular malaysia under changing climate scenarios. Water 10. doi:10.3390/w10121750.
- OAPN, . Organismo Autónomo Parques Nacionales. http://www.mapama.gob.es/es/ parques-nacionales-oapn/. Accessed: 2018-07-04.
- O'Gorman, P., Schneider, T., 2009. The physical basis for increases in precipitation extremes in simulations of 21st-century climate change. Proceedings of the National Academy of Sciences of the United States of America 106, 14773–14777.
- Olsson, J., Uvo, C., Jinno, K., Kawamura, A., Nishiyama, K., Koreeda, N., Nakashima, T., Morita, O., 2004. Neural networks for rainfall forecasting by atmospheric downscaling. Journal of Hydrologic Engineering 9, 1–12.
- Onof, C., Chandler, R., Kakou, A., Northrop, P., Wheater, H., Isham, V., 2000. Rainfall modelling using poisson-cluster processes: A review of developments. Stochastic Environmental Research and Risk Assessment 14, 384–411.
- Osca, J., Romero, R., Alonso, S., 2013. Precipitation projections for spain by means of a weather typing statistical method. Global and Planetary Change 109, 46–63.
- Overeem, A., Leijnse, H., Uijlenhoet, R., 2016. Two and a half years of country-wide rainfall maps using radio links from commercial cellular telecommunication networks. Water Resources Research 52, 8039–8065.
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M., Duchesnay, E., 2011. Scikit-learn: Machine learning in python. Journal of Machine Learning Research 12, 2825–2830.
- Peel, M., Finlayson, B., McMahon, T., 2007. Updated world map of the köppen-geiger climate classification. Hydrology and Earth System Sciences 11, 1633–1644.

- Pérez-Rodríguez, P., Gianola, D., González-Camacho, J., Crossa, J., Manès, Y., Dreisigacker, S., 2012. Comparison between linear and non-parametric regression models for genome-enabled prediction in wheat. G3: Genes, Genomes, Genetics 2, 1595–1605.
- Pfeifroth, U., Mueller, R., Ahrens, B., 2013a. Evaluation of satellite-based and reanalysis precipitation data in the tropical pacific. Journal of Applied Meteorology and Climatology 52, 634–644.
- Pfeifroth, U., Mueller, R., Ahrens, B., 2013b. Evaluation of satellite-based and reanalysis precipitation data in the tropical pacific. Journal of Applied Meteorology and Climatology 52, 634–644.
- Phillips, D.L., Dolph, J., Marks, D., 1992. A comparison of geostatistical procedures for spatial analysis of precipitation in mountainous terrain. Agricultural and Forest Meteorology 58, 119–141.
- Pons, M., Herrera, S., Gutiérrez, J., 2016. Future trends of snowfall days in northern spain from ensembles regional climate projections. Climate Dynamics 46, 3645–3655.
- Powers, D., 2011. Evaluation: From precision, recall and f-measure to roc, informedness, markedness correlation. Journal of Machine Learning Technologies 2, 37–63. Cited By 1499.
- Prakash, S., Mitra, A., Pai, D., AghaKouchak, A., 2016. From trmm to gpm: How well can heavy rainfall be detected from space? Advances in Water Resources 88, 1–7.
- Prudhomme, C., Nick Reynard, S., 2002. Downscaling of global climate models for flood frequency analysis: Where are we now? Hydrological Processes 16, 1137–1150.
- Pui, A., Sharma, A., Mehrotra, R., Sivakumar, B., Jeremiah, E., 2012. A comparison of alternatives for daily to sub-daily rainfall disaggregation. Journal of Hydrology 470-471, 138–157.
- Pumo, D., Arnone, E., Francipane, A., Caracciolo, D., Noto, L., 2017. Potential implications of climate change and urbanization on watershed hydrology. Journal of Hydrology 554, 80–99.
- Python Software Foundation, 2016. Python language reference, version 2.7. URL: http://www.python.org.
- Qiu, J., Wu, Q., Ding, G., Xu, Y., Feng, S., 2016. A survey of machine learning for big data processing. Eurasip Journal on Advances in Signal Processing 2016.
- R Core Team, 2015. R: A language and environment for statistical computing. URL: https://www.R-project.org.

- R Core Team, 2017. R: A Language and Environment for Statistical Computing. R Foundation for Statistical Computing. Vienna, Austria. URL: https://www.R-project. org/.
- Ribalaygua, J., Pino, R., Pórtoles, J., Roldán, E., Gaitán, E., Chinarro, D., Torres, L., 2013. Climate change scenarios for temperature and precipitation in aragón (spain). Science of the Total Environment 463-464, 1015–1030.
- Rodríguez– Iturbe, I., Eagleson, P., 1987. Mathematical models of rainstorm events in space and time. Water Resources Research 23, 181–190.
- Rodríguez–Iturbe, I., Mejía, J., 1974. The design of rainfall networks in time and space. Water Resources Research 10, 713–728.
- Saha, S., Moorthi, S., Pan, H.L., Wu, X., Wang, J., Nadiga, S., Tripp, P., Kistler, R., Woollen, J., Behringer, D., et al., 2010. The ncep climate forecast system reanalysis. Bulletin of the American Meteorological Society 91, 1015–1057.
- Schamm, K., Ziese, M., Raykova, K., Becker, A., Finger, P., Meyer-Christoffer, A., Schneider, U., 2016. Gpcc full data daily version 1.0: Daily land-surface precipitation from rain gauges built on gts based and historic data. Research Data Archive at the National Center for Atmospheric Research, Computational and Information Systems Laboratory 29, 897–910.
- Scoccimarro, E., Villarini, G., Vichi, M., Zampieri, M., Fogli, P., Bellucci, A., Gualdi, S., 2015. Projected changes in intense precipitation over europe at the daily and subdaily time scales. Journal of Climate 28, 6193–6203.
- Seo, D.J., Seed, A., Delrieu, G., 2013. Radar and Multisensor Rainfall Estimation for Hydrologic Applications.
- Serrano-Notivoli, R., Beguería, S., Saz, M., de Luis, M., 2018a. Recent trends reveal decreasing intensity of daily precipitation in spain. International Journal of Climatology 38, 4211–4224.
- Serrano-Notivoli, R., Beguería, S., Saz, M., de Luis, M., 2018b. Recent trends reveal decreasing intensity of daily precipitation in spain. International Journal of Climatology 38, 4211–4224.
- Sharma, A., Srikanthan, R., 2006. Continuous rainfall simulation: A nonparametric alternative. In: 30th Hydrology and Water Resources Symposium, Launceston, Tasmania, 4-7 December, 2006.
- Sheskin, D., 2003. Handbook of Parametric and Nonparametric Statistical Procedures: Third Edition. CRC Press.

- SIAR, . Sistema de Información Agroclimática pra el Regadio. http://eportal. mapama.gob.es/websiar/SeleccionParametrosMap.aspx?dst=1. Accessed: 2018-07-04.
- Smart, J., Csomor, S., et al., 2005. Cross-platform GUI programming with wxWidgets. Prentice Hall Professional.
- SMC, . Servei Meteorològic de Catalunya. http://en.meteocat.gencat.cat/?lang= en. Accessed: 2018-07-04.
- Smith, J., Baeck, M., Meierdiercks, K., Miller, A., Krajewski, W., 2007. Radar rainfall estimation for flash flood forecasting in small urban watersheds. Advances in Water Resources 30, 2087–2097.
- Stehlík, J., Bárdossy, A., 2002. Multivariate stochastic downscaling model for generating daily precipitation series based on atmospheric circulation. Journal of Hydrology 256, 120–141.
- Stephenson, D., Rupa Kumar, K., Doblas-Reyes, F., Royer, J.F., Chauvin, F., Pezzulli, S., 1999. Extreme daily rainfall events and their impact on ensemble forecasts of the indian monsoon. Monthly Weather Review 127, 1954–1966.
- Stern, R.D., Coe, R., 1984. A model fitting analysis of daily rainfall data. Journal of the Royal Statistical Society. Series A (General) 147, 1–34.
- Stocker, T.F., Qin, D., Plattner, G.K., Tignor, M., Allen, S.K., Boschung, J., Nauels, A., Xia, Y., Bex, V., Midgley, P.M., 2013. Climate Change 2013: The Physical Science Basis. Technical Report. 1535 pp.
- Sultana, Z., Sieg, T., Kellermann, P., Müller, M., Kreibich, H., 2018. Assessment of business interruption of flood-affected companies using random forests. Water 10.
- Sumi, S., Zaman, M., Hirose, H., 2012. A rainfall forecasting method using machine learning models and its application to the fukuoka city case. International Journal of Applied Mathematics and Computer Science 22, 841–854.
- Tabios, G.Q., Salas, J.D., 1985a. A comparative analysis of techniques for spatial interpolation of precipitation. JAWRA Journal of the American Water Resources Association 21, 365–380.
- Tabios, G.Q., I., Salas, J., 1985b. A comparative analysis of techniques for spatial interpolation of precipitation. JAWRA Journal of the American Water Resources Association 21, 365–380.

- Taylor, K., Stouffer, R., Meehl, G., 2012. An overview of cmip5 and the experiment design. Bulletin of the American Meteorological Society 93, 485–498.
- Tian, D., Guo, Y., Dong, W., 2015. Future changes and uncertainties in temperature and precipitation over china based on cmip5 models. Advances in Atmospheric Sciences 32, 487–496.
- Tian, Y., Peters-Lidard, C., Eylander, J., 2010. Real-time bias reduction for satellitebased precipitation estimates. Journal of Hydrometeorology 11, 1275–1285.
- Toth, E., Brath, A., Montanari, A., 2000. Comparison of short-term rainfall prediction models for real-time flood forecasting. Journal of Hydrology 239, 132–147.
- Tullot, I.F., 1959. El clima de las islas canarias. Anuario de estudios atlánticos 1, 57-103.
- Turco, M., Sanna, A., Herrera, S., Llasat, M.C., Gutiérrez, J., 2015. Evaluation of the Ensembles Transient RCM Simulations Over Spain: Present Climate Performance and Future Projections.
- Utsumi, N., Seto, S., Kanae, S., Maeda, E., Oki, T., 2011. Does higher surface temperature intensify extreme precipitation? Geophysical Research Letters 38.
- Valverde Ramírez, M., De Campos Velho, H., Ferreira, N., 2005. Artificial neural network technique for rainfall forecasting applied to the são paulo region. Journal of Hydrology 301, 146–162.
- Vicente-Serrano, S., Zabalza-Martínez, J., Borràs, G., López-Moreno, J., Pla, E., Pascual, D., Savé, R., Biel, C., Funes, I., Azorin-Molina, C., Sanchez-Lorenzo, A., Martín-Hernández, N., Peña-Gallardo, M., Alonso-González, E., Tomas-Burguera, M., El Kenawy, A., 2017. Extreme hydrological events and the influence of reservoirs in a highly regulated river basin of northeastern spain. Journal of Hydrology: Regional Studies 12, 13–32.
- Wadoux, A.M.C., Brus, D.J., Rico-Ramirez, M.A., Heuvelink, G.B., 2017. Sampling design optimisation for rainfall prediction using a non-stationary geostatistical model. Advances in Water Resources 107, 126 – 138.
- Wagner, P., Fiener, P., Wilken, F., Kumar, S., Schneider, K., 2012. Comparison and evaluation of spatial interpolation schemes for daily rainfall in data scarce regions. Journal of Hydrology 464-465, 388–400.
- Wasko, C., Sharma, A., 2017. Continuous rainfall generation for a warmer climate using observed temperature sensitivities. Journal of Hydrology 544, 575 – 590.

- Werner, A., Cannon, A., 2016. Hydrologic extremes an intercomparison of multiple gridded statistical downscaling methods. Hydrology and Earth System Sciences 20, 1483–1508.
- Westra, S., Alexander, L., Zwiers, F., 2013. Global increasing trends in annual maximum daily precipitation. Journal of Climate 26, 3904–3918.
- Wikipedia, 2019a. Escala sinóptica Wikipedia, the free encyclopedia. http://es.wikipedia.org/w/index.php?title=Escala%20sin%C3%B3ptica& oldid=117321393. [Online; accessed 11-July-2019].
- Wikipedia, 2019b. Inversión térmica Wikipedia, the free encyclopedia. http://es.wikipedia.org/w/index.php?title=Inversi%C3%B3n%20t%C3% A9rmica&oldid=116645334. [Online; accessed 11-July-2019].
- Wikipedia, 2019c. Microescala Wikipedia, the free encyclopedia. http://es. wikipedia.org/w/index.php?title=Microescala&oldid=110100979. [Online; accessed 11-July-2019].
- Wikipedia, 2019d. Riada de Tenerife de 2002 Wikipedia, the free encyclopedia. http://es.wikipedia.org/w/index.php?title=Riada%20de%20Tenerife% 20de%202002&oldid=114968933. [Online; accessed 05-July-2019].
- Wikipedia, 2019e. Riada de Tenerife de 2010 Wikipedia, the free encyclopedia. http://es.wikipedia.org/w/index.php?title=Riada%20de%20Tenerife% 20de%202010&oldid=114076043. [Online; accessed 05-July-2019].
- Wilby, R., 1999. The weather generation game: A review of stochastic weather models. Progress in Physical Geography 23, 329–357.
- Wilby, R., Wigley, T., 1997. Downscaling general circulation model output: A review of methods and limitations. Progress in Physical Geography 21, 530–548.
- Wright, D., Mantilla, R., Peters-Lidard, C., 2017. A remote sensing-based tool for assessing rainfall-driven hazards. Environmental Modelling and Software 90, 34–54.
- Yang, C., Chandler, R., Isham, V., Wheater, H., 2005. Spatial-temporal rainfall simulation using generalized linear models. Water Resources Research 41, 1–13.
- Yu, P.S., Yang, T.C., Chen, S.Y., Kuo, C.M., Tseng, H.W., 2017. Comparison of random forests and support vector machine for real-time radar-derived rainfall forecasting. Journal of Hydrology 552, 92 – 104.
- Zhang, Z., Switzer, P., 2007. Stochastic space-time regional rainfall modeling adapted to historical rain gauge data. Water Resources Research 43.