



UNIVERSITAT  
POLITÈCNICA  
DE VALÈNCIA

UNIVERSITAT POLITÈCNICA DE VALÈNCIA

Dpto. de Ingeniería Hidráulica y Medio Ambiente

Evaluación de los pronósticos de sequía a escala  
estacional

Trabajo Fin de Máster

Máster Universitario en Ingeniería Hidráulica y Medio Ambiente

AUTOR/A: Vargas Mora, Tatiana

Tutor/a: Pulido Velázquez, Manuel Augusto

Cotutor/a: Macián Sorribes, Héctor

CURSO ACADÉMICO: 2021/2022

# Trabajo Fin de Máster

## *EVALUACIÓN DE LOS PRONÓSTICOS DE SEQUÍA A ESCALA ESTACIONAL*

**Intensificación:**

***ANÁLISIS DE SISTEMAS DE RECURSOS HÍDRICOS***

**Autor:**

***TATIANA ANDREA VARGAS MORA***

**Tutor:**

***DR. MANUEL PULIDO VELÁZQUEZ***

**Cotutor/es:**

***DR. HÉCTOR MACIÁN SORRIBES***

***JUNIO, 2022***



UNIVERSITAT  
POLITÈCNICA  
DE VALÈNCIA

máster en ingeniería  
hidráulica y medio ambiente  
**mihma**



## Resumen del Trabajo de Fin de Máster

Datos del proyecto
<b>Título del TFM en español:</b> Evaluación de los pronósticos de sequía a escala estacional.
<b>Título del TFM en inglés:</b> Drought forecast evaluation over seasonal timescales.
<b>Título del TFM en Valenciano:</b> Avaluació dels pronòstics de sequera a escala estacional.
<b>Alumno:</b> Tatiana Andrea Vargas Mora.
<b>Tutor:</b> DR. Manuel Pulido Velázquez
<b>Cotutor/es:</b> DR. Héctor Macián Sorribes
<b>Director experimental:</b>
<b>Fecha de Lectura:</b> junio de 2022

Resumen
<p>Los evidentes cambios sobre las condiciones normales del clima prevén un agravamiento de las sequías en regiones con climas áridos y semiáridos donde son una amenaza recurrente, pero también en climas húmedos donde no son frecuentes, pero en donde su ocurrencia puede ocasionar daños aún más graves. Esta amenaza latente representa un riesgo sobre la disponibilidad del agua, los ecosistemas terrestres, la producción agroalimentaria, la lucha contra la desertificación y pérdida de la biodiversidad.</p> <p>Aunque recientemente existe un auge de los sistemas de predicción que anticipan los eventos de sequía meteorológica para los siguientes días e inclusive hasta para los siguientes meses, no existen servicios equivalentes para sequías edáficas y/o hidrológica. El uso de este tipo de sequías se ha reducido al monitoreo a través de indicadores estandarizados basados en observaciones históricas, esto se debe en gran parte a que la capacidad que tiene los modelos de predecir las sequías en escenarios futuros, aún es altamente incierta.</p>



Es ahí donde se requiere entender la influencia de la variación de factores espaciales y temporales en la predicción de datos climáticos e hidrológicos y de capturar la tendencia de las sequías. Lo anterior considerando que los usuarios de la información requieren datos que no estén sesgados, fiables y coherentes para apoyar los procesos de planificación hídrica local y regional, enmarcados en la gestión integral del agua, en el marco de Sendai para la reducción de riesgos de desastres 2012-2030 y los objetivos de desarrollo sostenible. Por consiguiente se abre un espacio importante para la investigación, en donde disponer de un servicio integrado de información que tenga en cuenta todos los tipos de sequía (meteorológica, edáfica e hidrológica) permitiría anticiparse con estrategias dirigidas a prevenir y mitigar los impactos de las sequías.

Para contribuir con información para avanzar en el conocimiento entorno a la capacidad de predicción de este tipo de fenómenos, el objetivo de esta investigación es evaluar los límites en la predictibilidad estacional de sequías, así como los factores que afectan a la bondad de las predicciones tanto en el espacio como en el tiempo para diferentes indicadores de sequía. Esto se hará para el modelo hidrológico E-HYPE, con datos de 617 subcuencas. Para alcanzar este objetivo se calcularán indicadores de impacto (Standardized Precipitation Index, Standardized Precipitation-Evapotranspiration Index entre otros) que miden la duración, frecuencia e intensidad con la que se presentan las sequías.

El modelo E-HYPE (Hydrological Predictions for the Environment) elaborado por el Swedish Meteorological and Hydrological Institute (SMHI) es un modelo hidrológico semidistribuido y físicamente basado que describe los procesos hidrológicos a escala de subcuenca para toda Europa con un modelo desarrollado para aproximadamente 35.408 subcuencas.

Los datos extraídos por el SMHI del modelo E-HYPE para este proyecto cuentan con los ajustes sobre el sesgo de las predicciones del modelo ECMWF SEAS5 y se han suministrado información de variables meteorológicas (precipitación medida en mm/d, evapotranspiración medida en mm/d), variables edáficas (humedad del suelo medida en



porcentaje) y variables hidrológicas (caudal medido en m<sup>3</sup>/s) para una muestra de 617 subcuencas. Para esta muestra se calcularán índices de sequía meteorológicos, edáficos e hidrológicos, para posteriormente comparar la bondad de ajuste de los índices y de las variables con el periodo de referencia del modelo E-HYPE.

**Palabras clave:** sequías, predicciones estacionales, índices estandarizados, bondad de ajuste

### Resum

Els evidents canvis sobre les condicions normals del clima preveuen un agreujament de les sequeres en regions amb climes àrids i semiàridos on són una amenaça recurrent, però també en climes humits on no són freqüents, però on la seua idea pot ocasionar danys encara més greus. Esta amenaça latent representa un risc sobre la disponibilitat de l'aigua, els ecosistemes terrestres, la producció agroalimentària, la lluita contra la desertificació i perduda de la biodiversitat.

Encara que recentment hi ha un auge dels sistemes de predicció que anticipen els esdeveniments de sequera meteorològica per als següents dies i inclusivament fins per als següents mesos, no hi ha servicis equivalents per a sequeres edàfiques y/o hidrològica. L'ús d'este tipus de sequeres s'ha reduït al monitoreo a través d'indicadors estandarditzats basats en observacions històriques, açò es deu en gran part a què la capacitat que té els models de predir les sequeres en escenaris futurs, encara és altament incerta.

És ací on es requerix entendre la influència de la variació de factors espacials i temporals en la predicció de dades climàtiques i hidrològics i de capturar la tendència de les sequeres. L'anterior considerant que els usuaris de la informació requerixen dades que no estiguen esbiaixats, fiables i coherents per a recolzar els processos de planificació hídrica local i regional, emmarcats en la gestió integral de l'aigua, en el marc de Sendai per a la reducció de riscos de desastres 2012-2030 i els objectius de desenvolupament sostenible. Per consegüent s'obri un espai important per a la investigació, on disposar d'un servici integrat d'informació que tinga en compte tots els tipus de sequera



(meteorològica, edàfica i hidrològica) permetria anticipar-se amb estratègies dirigides a previndre i mitigar els impactes de les sequeres.

Per a contribuir amb informació per a avançar en el coneixement entorn de la capacitat de predicció d'este tipus de fenòmens, l'objectiu d'esta investigació és avaluar els límits en la predicibilitat estacional de sequeres, així com els factors que afecten la bondat de les prediccions tant en l'espai com en el temps per a diferents indicadors de sequera. Açò es farà per al model hidrològic E-HYPE, amb dades de 617 subconques. Per a aconseguir este objectiu es calcularan indicadors d'impacte (Standardized Precipitation Index, Standardized Precipitation-Evapotranspiration Index entre altres) que mesuren la duració, freqüència i intensitat amb què es presenten les sequeres.

El model E-HYPE (Hydrological Predictions for the Environment) elaborat pel Swedish Meteorological and Hydrological Institute (SMHI) és un model hidrològic semidistribuido i físicament basat que descriu els processos hidrològics a escala de subconca per a tota Europa amb un model desenrotllat per a aproximadament 35.408 subconques.

Les dades extrets pel SMHI del model E-HYPE per a este projecte compten amb els ajustos sobre el caire de les prediccions del model ECMWF SEAS5 i s'han subministrat informació de variables meteorològiques (precipitació mesura en mm/d, evapotranspiració mesura en mm/d), variables edàfiques (humitat del sòl mesura en percentatge) i variables hidrològiques (cabal mesurat en m<sup>3</sup>/s) per a una mostra de 617 subconques. Per a esta mostra es calcularan índexs de sequera meteorològics, edàfics i hidrològics, per a posteriorment comparar la bondat d'ajust dels índexs i de les variables amb el període de referència del model E-HYPE.

**Paraules clau:** s sequeres, prediccions estacionals, índexs estandarditzats, bondat d'ajust.

## Summary

The evident changes in normal climate conditions foresee a worsening of droughts in regions with arid and semi-arid climates where they are a recurrent threat, but also in humid climates where they are not frequent,



but where their occurrence may cause even more serious damage. This latent threat represents a risk to water availability, terrestrial ecosystems, agrifood production, the fight against desertification, and the loss of biodiversity.

Although recently there has been a boom in forecasting systems that anticipate meteorological drought events for the following days and even for the following months, there are no equivalent services for edaphic or hydrological droughts. The use of this type of drought has been reduced to monitoring through standardized indicators based on historical observations, largely because the ability of models to predict droughts in future scenarios is still highly uncertain.

This is where it is necessary to understand the influence of the variation of spatial and temporal factors in the prediction of climatic and hydrological data and to capture the trend of droughts. Considering that information users require unbiased, reliable, and consistent data to support local and regional hydrological planning processes, framed in integrated water management, in the Sendai framework for disaster risk reduction 2012-2030 and the Sustainable Development Goals. Therefore, an important space for research is opened. An integrated information service that considers all types of drought (meteorological, edaphic, and hydrological) would allow anticipating strategies to prevent and mitigate the impacts of droughts.

To contribute with information to advance the knowledge about the predictive capacity of this type of phenomena, the objective of this research is to evaluate the limits in the seasonal predictability of droughts, as well as the factors that affect the goodness of predictions both in space and time for different drought indicators. This will be done for the hydrological model E-HYPE, with data from 617 sub-basin. To achieve this objective, impact indicators will be calculated (Standardized Precipitation Index, Standardized Precipitation-Evapotranspiration Index, among others) that measure the duration, frequency, and intensity of droughts.

The E-HYPE model (European Hydrological Predictions for the Environment) developed by the Swedish Meteorological and



Hydrological Institute (SMHI) is a semi-distributed, physically-based hydrological model that describes hydrological processes at the sub-basin scale for Europe with approximately 35,408 sub-basins.

The data extracted by the SMHI from the E-HYPE model for this project are bias-adjusted for ECMWF SEAS5 model predictions and information on meteorological variables (precipitation measured in mm/d, evapotranspiration measured in mm/d), edaphic variables (soil moisture measured in percent) and hydrological variables (flow measured in m<sup>3</sup>/s) has been provided for a sample of 617 sub-basins. Meteorological, edaphic, and hydrological drought indices will be calculated for this sample and the goodness of fit of the indices and variables will be compared with the reference period of the E-HYPE model.

**Palabras clave:** Drought, seasonal forecasts, standardized index, skill.





## Agradecimientos

Este estudio conto con el apoyo del proyecto ADAPTAMED (RTI2018-101483-B-I00), financiado por el Ministerio de Economía y Competitividad de España (MINECO), incluyendo los fondos FEDER de la UE; y las subvenciones del Programa para la promoción de la investigación científica, el desarrollo tecnológico y la innovación en la Comunitat Valenciana (PROMETEO) en el marco del proyecto WATER4CAST.

Agradecemos al SMHI por los datos extraídos del modelo E-HYPE para este proyecto; y en particular a Ilias Pechlivanidis, por la orientación, las comentarios y correcciones al trabajo realizado.

Agradecemos al profesor Sergio Vicente Serrano por la guía y la información compartida en relación con la selección y ajustes de las funciones de distribución de los índices de sequía.

De mi parte, agradezco en primer lugar al profesor Manuel Pulido Velázquez, por la confianza, las enseñanzas y el esfuerzo puesto en este proyecto de investigación que han hecho aún más valioso todo el proceso de aprendizaje y que me motivaron siempre a seguir trabajando. A Luis Medina Jaimes por las aclaraciones y tutorías en las partes más complicadas de la programación en Python que permitieron que este proyecto avanzara; y en especial quiero agradecer al profesor Héctor Macián Sorribes por el ánimo, la dedicación y por sobre todo la paciencia con la que dirigió este proyecto, realmente este trabajo es una extensión de su conocimiento.



## Tabla de contenido

Capítulo 1. Introducción.....	0
1.1 Modelos hidrológicos e índices de sequía. ....	0
1.2 Objetivo de la investigación.....	4
Capítulo 2. Marco de referencia.....	5
2.1 Índices de sequía .....	5
2.2 Sistemas de monitorización de sequía hidrometeorológica a gran escala.....	8
2.3 Predicciones meteorológicas e hidrológicas .....	12
2.4 Modelo hidrológico E-HYPE.....	16
Capítulo 3. Caso de estudio e información .....	19
3.1 Área de Estudio.....	19
3.2 Datos de E-HYPE .....	21
Capítulo 4. Metodología .....	23
4.1 Funciones de distribución de probabilidad .....	25
4.1.1 Estimación de parámetros .....	30
4.2 Test de bondad de ajuste .....	31
4.3 Índices estandarizados de sequía .....	34
4.3.1 Escala de agregación del cálculo del índice de sequía. ....	35
4.3.2 Índice estandarizado de Precipitación SPI.....	37
4.3.3 Índice estandarizado de Precipitación-Evapotranspiración (SPEI) -	40
4.3.4 Índice estandarizado de humedad del suelo (SSMI) .....	42
4.3.5 Índice estandarizado de caudal (SRI) .....	42
4.4 Evaluación de la capacidad de predicción.....	43
Capítulo 5. Resultados y discusión .....	46
5.1 Ajuste de funciones de distribución teóricas a distribuciones empíricas.....	46
5.1.1 Precipitación .....	46
5.1.2 Precipitación – Evapotranspiración Potencial. ....	51



5.1.3	Humedad del suelo .....	54
5.1.4	Caudal .....	57
5.2	Análisis histórico de índices estandarizados de sequías .....	60
5.2.1	Índice estandarizado de Precipitación SPI .....	61
5.2.2	Índice estandarizado de Precipitación-Evapotranspiración (SPEI) 66	
5.2.3	Índice estandarizado de humedad del suelo (SSMI) .....	69
5.2.4	Índice estandarizado de caudal (SRI) .....	73
5.3	Evaluación de la capacidad de predicción estacionales de variables e índices de sequía por el modelo E-HYPE .....	76
5.3.1	Capacidad de predicción de índices de sequía de 1 mes de agregación .....	78
5.3.2	Capacidad de predicción de índices de sequía de 3 meses de agregación .....	81
5.3.3	Capacidad de predicción de índices de sequía 6 de meses de agregación .....	84
5.3.4	Capacidad de predicción de índices de sequía para 12 meses de agregación .....	86
Capítulo 6.	Síntesis, conclusiones y futuras líneas de investigación .....	90
6.1	Síntesis y conclusiones .....	90
6.2	Líneas de investigación futuras .....	93
	Referencias bibliográficas .....	95



## Índice de Figuras

Figura 1 Modelación índices de sequía .....	1
Figura 2 Monitor de sequía meteorológica .....	10
Figura 3 Herramientas cartográficas para la evaluación de sequía .....	11
Figura 4 Interacción entre los componentes del IFS.....	14
Figura 5 Elementos del modelo hidrológico HYPE. ....	18
Figura 6 Clústeres del Modelo E-HYPE para las subcuencas de estudio ..	20
Figura 7 Marco de referencia.....	24
Figura 8 relaciones entre funciones de distribución univariante .....	26
Figura 9 Ajuste de distribuciones teóricas a distribuciones empíricas.....	29
Figura 10 Ejemplo en el ajuste de las colas de la distribución .....	32
Figura 11 tiempos de agregación de índices de sequía .....	37
Figura 12 Ejemplo de transformación de una distribución teórica a la distribución normal estándar. ....	39
Figura 13 Ejemplo de distribución de la precipitación para diferentes niveles de agregación temporal .....	47
Figura 14 selección de las mejores funciones de distribución del SPI .....	48
Figura 15 p-value del test DA obtenidos para SPI .....	50
Figura 16 Ejemplo de distribución de la P-PEPOT para diferentes niveles de agregación temporal.....	51
Figura 17 selección de las mejores funciones de distribución para el SPEI .....	52
Figura 18 p-value del test DA obtenidos para SPEI .....	53
Figura 19 Ejemplo de distribución de la humedad del suelo para diferentes niveles de agregación temporal .....	54
Figura 20 selección de las mejores funciones de distribución para el SSMI .....	55
Figura 21 p-value del test DA obtenidos para SSMI.....	56
Figura 22 Ejemplo de distribución de la caudal para diferentes niveles de agregación temporal.....	57
Figura 23 selección de las mejores funciones de distribución para el SRI	58
Figura 24 p-value del test DA obtenidos para SRI.....	59
Figura 25 Características de los índices de sequía .....	60
Figura 26 Frecuencia decadal de las sequías meteorológicas según el índice SPI.....	62
Figura 27 Intensidad decadal de las sequías meteorológicas según el índice SPI.....	64



Figura 28 Frecuencia decadal de las sequías meteorológicas según el índice SPEI.....	67
Figura 29 Intensidad decadal de las sequías meteorológicas según el índice SPEI.....	68
Figura 30 Frecuencia decadal de las sequías edáficas según el índice SSMI .....	71
Figura 31 Intensidad decadal de las sequías edáficas según índice SSMI .....	72
Figura 32 Frecuencia decadal de las sequías hidrológicas según el índice SRI .....	74
Figura 33 Intensidad decadal de las sequías hidrológicas según el índice SRI .....	75
Figura 34 Calidad de predicciones 1 mes de agregación para los clústeres del 1 al 5. ....	79
Figura 35 Calidad de predicciones 1 mes de agregación para los clústeres del 6 al 11. ....	81
Figura 36 Calidad de predicciones 3 meses de agregación para los clústeres del 1 al 5. ....	82
Figura 37 Calidad de predicciones 3 meses de agregación para los clústeres del 6 al 11. ....	83
Figura 38 Calidad de predicciones 6 meses de agregación para los clústeres del 1 al 5. ....	85
Figura 39 Calidad de predicciones 6 meses de agregación para los clústeres del 6 al 11. ....	86
Figura 40 Calidad de predicciones 12 meses de agregación para los clústeres del 1 al 5. ....	87
Figura 41 Calidad de predicciones 12 meses de agregación para los clústeres del 6 al 11. ....	88

## Índice de Tablas

Tabla 1 Características de las subcuencas de E-HYPE.....	19
Tabla 2 Variables suministradas del modelo E-HYPE .....	22
Tabla 3 función de distribución de probabilidad.....	30
Tabla 4 Valores del SPI y su correspondiente probabilidad .....	40



## Capítulo 1. Introducción

### 1.1 Modelos hidrológicos e índices de sequía.

Sequía es una palabra empleada para describir un periodo de reducción de lluvias y que puede ser perjudicial para la vegetación si afecta a los sistemas hídricos, tales como arroyos, ríos o lagos (Samaniego, 2021). Otra definición ampliamente aceptada es la propuesta por la World Meteorological Organization (WMO) (2011) que define la sequía como una amenaza natural caracterizada por una precipitación por debajo de lo normal que se extiende en el tiempo y es insuficiente para cubrir las demandas de agua tanto humanas, como ecológicas. En otras palabras, es descrita como un estado natural y transitorio de la atmósfera.

Esta definición de la WMO está directamente relacionada con los impactos causados por las sequías, debido a que es una de las amenazas naturales más graves y pueden causar daños y pérdidas comparables con otro tipo de amenazas relacionados con el clima, tales como inundaciones, deslizamientos y terremotos. Es así que históricamente en España, y en Europa en general, se han experimentado fuertes sequías combinadas con olas de calor y climas propios de veranos que han venido en incremento desde 1980 (Samaniego, 2021). Un ejemplo es el verano de 2015, que ha sido registrado como el más caliente desde 1950 y que afectó gran parte del oriente y suroccidente de Europa (Hanel et al., 2018).

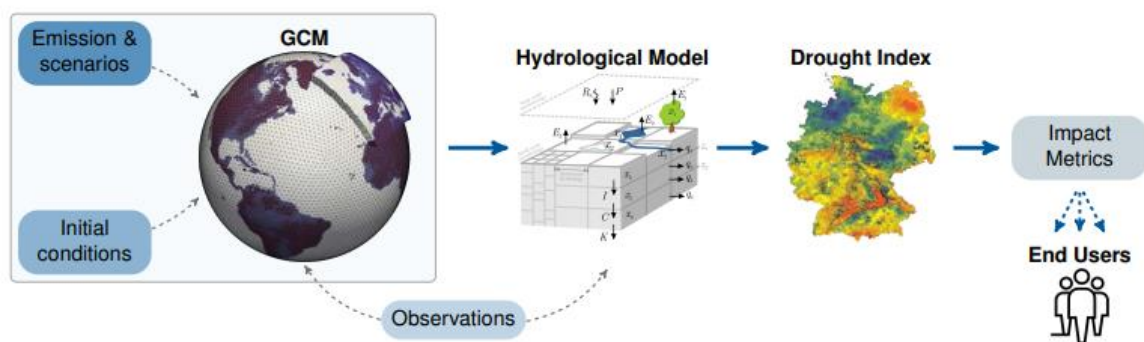
La gravedad de la ocurrencia de este tipo de amenazas, radica en las implicaciones que estos climas extremos pueden tener sobre sistemas como la agricultura, la hidrología y los ecosistemas. En 2007 el IPCC identificó las sequías como el desencadenante de una red de impactos que provocan la degradación de la tierra, la migración de especies y elevados costes socioeconómicos (Samaniego, 2021).

Existe una amplia cantidad de sectores afectados por variaciones del clima y por tanto existe una necesidad de manejar las sequías de forma que la comprensión del fenómeno permita tomar acciones concretas y acertadas. Dichas decisiones se soportan en estudios, modelos hidrológicos e indicadores que se encargan de reproducir lo que ha ocurrido en los sistemas naturales. En particular desde el enfoque de la

planificación y la gestión del recurso hídrico, tomar estas decisiones de manera anticipada requiere de modelos matemáticos que puedan predecir la ocurrencia de las sequías.

En los últimos 20 años, se ha tenido un enorme desarrollo en el campo, a través de la formulación de índices, herramientas y bases de datos que se encargan de establecer la probabilidad de ocurrencia de sequías, incluyendo investigaciones sobre reconstrucciones y análisis de sequías a través de su modelación desde una base física, con aplicación en el campo de las predicciones de sequías (Vicente Serrano, 2021).

Estos modelos para predecir las sequías, a su vez, se alimentan de los resultados de otros modelos; de esta manera se obtienen datos meteorológicos y/o hidrológicos de modelos de circulación general (GCM) o modelos climáticos regionales (RCMS), ver Figura 1. Obtener esta información involucra muchos componentes: pre-procesamiento, estimación de condiciones iniciales, calibración, actualización, generación, evaluación de la calidad, visualización y reproducción de los datos, etc. Ello está estrechamente asociados a múltiples fuentes de error y es precisamente ahí donde se ha evidenciado que existe una gran fuente de incertidumbre en los pronósticos de sequía, que en parte es ocasionada por la dificultad de medir el fenómeno en sí.



**Figura 1 Modelación índices de sequía**

Fuente: (Samaniego, 2021).

Las sequías son difíciles de caracterizar, inclusive con modelos robustos, por lo tanto, algunos estudios se han enfocado en modelos para representar la sequía y su propagación en diferentes partes del ciclo hidrológico; pero la capacidad de dichos modelos de predecir las sequías es bastante baja. Inclusive se ha observado que las predicciones



de sequía realizadas a través de modelos estadísticos y dinámicos muestran una parte predecible que corresponde al carácter autoregresivo de los datos (Vicente Serrano, 2021), pero que no puede ser atribuida al propio modelo, por lo cual se habla de una capacidad reducida de predicción.

También se ha observado que estos estudios de predicción de sequía emplean en su mayor parte únicamente variables meteorológicas como precipitación y la evapotranspiración, que incluye el efecto de la temperatura, lo que se conoce como sequías meteorológicas. Sin embargo, se han evidenciado que otros tipos de sequías como la sequía edáfica (déficit de humedad del suelo) y la sequía hidrológica (descarga de los ríos por debajo de lo normal) suelen ser más heterogéneos en el espacio y en el tiempo (Hanel et al., 2018) si se compara con las sequías meteorológicas. De ahí la necesidad de estudiar su evolución de manera conjunta.

Entre las metodologías que se emplean para el análisis de las sequías se encuentran los índices estandarizados, ampliamente empleados en el monitoreo de las sequías en regiones como España, Estados Unidos y Chile. Sin embargo actualmente solo se calculan estos indicadores para datos históricos y su uso en pronósticos de sequía ha sido bastante limitado, principalmente porque como afirma Vicente Serrano (2021) la capacidad que tienen los modelos de predecir las sequías aún es altamente incierta, con un amplio debate en el uso de variables de modelos globales y/o de indicadores de sequía que no han sido calibrados.

Mishra & Singh (2011) describen los modelos que se emplean para predecir las sequías. Entre ellos se incluyen: modelos de regresión que consideran una variable dependiente cuyo valor se quiere predecir y una independiente de la cual se dispone información; modelos de series temporales como son modelos de media móvil ARIMA y SARIMA; modelos probabilísticos mediante los cuales se puede cuantificar la incertidumbre de las variables que generan las sequías, generalmente se emplean las cadenas de Markov, pero son bastante complejos de emplear. También se encuentran las redes neuronales que pueden descubrir patrones y tendencias de forma adaptativa (entrenamiento) a partir de los mismos datos, y finalmente los modelos hidrológicos. En el caso de la modelación de sequías en escenarios de cambio climático, se hace mención especial





a los modelos hidrológicos de gran escala, que emplean como insumo observaciones meteorológicas corregidas de modelos GCM o RCMS, a partir de las cuales se obtienen simulaciones de variables hidrológicas.

Es ahí donde se requiere entender la influencia de la variación de factores espaciales y temporales en la predicción de datos climáticos e hidrológicos y de capturar la tendencia de las sequías. Teniendo en cuenta lo anterior, considerando que los usuarios requieren datos que no estén sesgados y sean fiables y coherentes para apoyar los procesos de planificación hídrica local y regional, enmarcados en la gestión integral del agua, se define el marco de Sendai para la reducción de riesgos de desastres 2012-2030 y los objetivos de desarrollo sostenible.

El modelado a gran escala tiene la capacidad de abarcar muchas cuencas, calibradas y no calibradas, incluyendo cuencas compartidas entre regiones y cuencas transfronterizas, en donde se presentan una gran diversidad de condiciones geográficas, zonas climáticas, y dinámicas socio-económicas. Este tipo de modelación ha surgido recientemente gracias a las nuevas bases de datos regionales y globales y los avances en la capacidad de computación, que permiten una alta resolución espacio-temporal cubriendo amplias regiones. Se cree que los modelos a gran escala tienen el potencial para hacer avanzar la ciencia debido a que permite hacer un análisis comparativo de los sistemas hidrológicos, con el objetivo de mejorar la comprensión procesos hidrológicos, así como una mejor armonización y coordinación de las acciones necesarias para hacer frente a sequías.

Los evidentes cambios sobre las condiciones normales del clima prevén un agravamiento de las sequías en regiones con climas áridos y semiáridos, donde ya son una amenaza recurrente; pero también en climas húmedos donde por ahora no son frecuentes, pero en donde su ocurrencia puede ocasionar daños aún más graves. Esta amenaza latente representa un riesgo sobre la disponibilidad del agua, los ecosistemas terrestres, la producción agroalimentaria y la lucha contra la desertificación y pérdida de la biodiversidad.

Predecir a gran escala (nacional, continental o global) permite la evaluación de múltiples regiones para diferentes periodos de anticipación. Uno de ellos son las predicciones estacionales, los cuales proporcionan información del clima que se espera para los próximos meses (tiempos de anticipación). La predicción estacional se diferencia

de las predicciones del tiempo, según afirma la Unión Europea (2021), debido que las predicciones del tiempo presentan cambios continuos en la atmósfera, mientras que las predicciones estacionales son un resumen estadístico de los eventos que pueden ocurrir en el futuro. El uso de estas predicciones estacionales es relevante para las sequías ya que éstas suelen ser fenómenos que se extienden en el tiempo, al contrario de por ejemplo las inundaciones, que se caracterizan por presentarse con periodos de anticipación muy cortos.

Aunque recientemente existe un auge de sistemas de predicción que anticipan los eventos de sequía meteorológica para los siguientes meses, no existen servicios equivalentes para sequías edáficas o hidrológica. En la práctica, la predicción de sequías se basa fundamentalmente en el monitoreo de las mismas a través de sistemas de indicadores basados en observaciones pasadas. En consecuencia, se abre un espacio importante en donde disponer de un servicio integrado que tenga en cuenta todos los tipos de sequía (meteorológica, edáfica e hidrológica) apoyaría la gestión del agua.

## 1.2 Objetivo de la investigación

Para contribuir con información para avanzar en el conocimiento entorno a mejorar la capacidad de predicción de los diferentes tipos de sequía, el objetivo de la investigación es evaluar de forma integral la calidad de la predicción estacional de sequías, tanto meteorológicas, edáficas como hidrológicas; así como analizar los factores que afectan a la bondad en las predicciones tanto en el espacio como en el tiempo empleando diferentes indicadores de sequía.

Para lograr este objetivo este trabajo se dividió en tres componentes cada uno con un objetivo específico:

- Seleccionar las funciones de distribución que permitieran la estandarización y normalización de las variables
- Analizar la frecuencia e intensidad del periodo histórico de los índices estandarizados de sequía
- Evaluar la capacidad de predicción estacional de los índices de sequía.

## Capítulo 2. Marco de referencia

### 2.1 Índices de sequía

Una de las principales dificultades del monitoreo de las sequías, es que no existe una variable física directa que pueda medirse para caracterizarla. Por esta razón la comunidad científica ha desarrollado una serie de índices e indicadores que permiten estimar la duración, frecuencia y magnitud de las sequías empleando variables hidrometeorológicas (Podestá, 2020). A través de estos índices se puede obtener un punto de comparación de las sequías aplicados a una gran cantidad de regiones con diversos climas.

El uso de índices estandarizados, se emplea para evaluar la probabilidad de amenaza de sequía. Un índice hace referencia a un único valor que es más fácil de interpretar que el dato de la variable crudo; y en particular los índices de sequía agrupan importantes cantidades de datos a partir de los cuales es posible obtener una noción del déficit hídrico de una región en concreto (Cortez et al., 2019)

Para tener una idea, los primeros índices de sequía de los cuales se tienen referencias son el índice de severidad de sequías de Palmer (PDSI) y The surface water supply index (SWSI). El primero, desarrollado por Palmer en 1965, es un índice que usa la precipitación y la temperatura para estimar un balance de agua en el suelo. El índice es una medida de la humedad (valores positivos) o sequía (valores negativos) en el suelo, y es ampliamente usado para estimar sequías agrícolas (Palmer, 1965). El segundo índice, desarrollado por Shafer y Dezman en 1982, tiene el propósito de monitorear anomalías en las fuentes de suministro de agua superficial. Emplea la misma metodología del PDSI, pero, como variables de entrada, incluye la información de agua almacenada en forma de nieve, caudales, precipitación y almacenamiento de embalses. Se considera que es un buen indicador de impacto de sequías hidrológicas en suministros de agua urbanos e industriales (Mishra & Singh, 2010).

Después del PDSI y SWSI se desarrolló el Standardized Precipitation Index (SPI). Formulado por McKee (1993), este índice estima el percentil asociado a la probabilidad de ocurrencia de un evento de precipitación. Se usa para cuantificar y comparar los déficits de precipitación a

diferentes escalas temporales en zonas con climas diferentes (AEMET, 2016). Otro índice a tener en cuenta es el Standardized Drought-Precipitation Index (IESP), formulado por Pita (2001), basado en el cálculo de anomalías mensuales acumuladas (Peña-Gallardo et al., 2016). El IESP se diferencia del SPI, entre otras cosas, debido a que no estima la anomalía para diferentes escalas de tiempo (Vicente Serrano, 2021). Estos indicadores emplearon la normalización de la variable precipitación y dieron la base para el desarrollo de los demás indicadores que emplean la misma metodología. En esa misma época también se desarrolló el Drought frequency index (DFI) formulado por González & Valdés (2006) el cual identifica los eventos extremos de sequía basados en la característica estocástica del fenómeno, en función de la frecuencia media de ocurrencia.

Los índices de sequía anteriormente descritos, excluyendo al PDSI, se encuentran basados únicamente en la precipitación y no consideran el efecto de variables como la temperatura, evapotranspiración y humedad del suelo. Ello es debido a que estudios han demostrado que la precipitación es la variable principal que determina el inicio, la duración, intensidad y fin de la sequía. Esta afirmación es más cierta para regiones con precipitaciones considerables, dado el hecho que los índices que consideran la precipitación como única variable de entrada realizan dos hipótesis básicas; en primer lugar, que la variabilidad de la precipitación es mucho más alta que otras variables; y en segundo que las otras variables son estacionarias, por lo que la sequía se puede caracterizar por la variabilidad temporal de la precipitación (Vicente-Serrano et al., 2010).

Sin embargo, es conocido que, en lugares con baja precipitación, el efecto de la temperatura toma mucha relevancia, debido a que un incremento sobre esta variable tiene un efecto más marcado sobre la severidad de la sequía. Abramopoulos (1988) demostró que la evaporación y la transpiración puede llegar a consumir el 80% de la lluvia, por lo que un índice de sequía basado únicamente en la precipitación tendría en cuenta la cantidad de lluvia que se registró para un periodo en concreto, pero no considera que parte de la lluvia se perdió por evapotranspiración y si el efecto de la evapotranspiración es importante. Es así, que, en regiones con climas áridos y semiáridos, se evidenció la necesidad de emplear otros tipos de índices para caracterizar la sequía. Una de las alternativas, en zonas con climas secos es emplear el PDSI, que

incluye el efecto de la temperatura y explica mejor el déficit de agua en la vegetación que el SPI. A pesar de ello, una de las limitaciones del PDSI es que carece del carácter multiescalar el SPI, es decir que solo se puede calcular para una escala temporal y no permite establecer los impactos de la propagación de las sequías en los diferentes componentes de los sistemas hidrológicos.

Por esta razón Vicente-Serrano et al. (2010) desarrollaron el Standardized Precipitation-Evapotranspiration Index (SPEI). Este índice es una medida del déficit o excedente de agua basado en la diferencia de la precipitación y evapotranspiración de referencia; esta última variable incluye el efecto de la temperatura sobre la severidad de las sequías. Una de las ventajas del SPEI es que permite agrupar en diferentes escalas temporales una variedad de impactos posibles ocasionadas por las sequías. Complementario al SPEI, se formuló el Standardization of the evapotranspiration deficit (SEDI) (Vicente-Serrano et al., 2018) el cual se basa en el déficit de evapotranspiración, es decir la evapotranspiración real menos evapotranspiración de referencia, para identificar condiciones de estrés en las plantas y reducción en el crecimiento de la vegetación.

Existen otro tipo de indicadores que también realizan una combinación de variables que representan el estado del clima, suelo, caudales, humedad e información de vegetación. Entre ellos cabe mencionar: (i) el Crop Moisture Index (CMI) también formulado por Palmer (1968) para medir semana a semana la producción de los cultivos; (Mishra & Singh, 2010); (ii) el standardized runoff index (SRI) (Shukla & Wood, 2008) y el streamflow drought index (SDI) (Nalbantis & Tsakiris, 2009), que se emplean para caracterizar sequías hidrológicas y comparar los resultados con el SPI. Los dos utilizan la estandarización y normalización de la variable hidrológica y se diferencian entre sí debido a que el SDI considera en la metodología el año hidrológico y no año normal, es decir inicia la acumulación de la variable en octubre; y (iii) el soil moisture deficit index (SMDI) y el evapotranspiration deficit index (ETDI) creados por Narasimhan and Srinivasan (2005), miden el déficit de humedad en el suelo y el déficit de agua en la atmósfera (Mishra & Singh, 2010).

Entre los objetivos de los índices estandarizados de sequía se encuentra identificar el inicio y fin de las sequías, las áreas afectadas, además de otras características de las sequías como son la frecuencia, duración e



intensidad. En las últimas décadas asociada a las sequías se ha introducido otro concepto que es el estrés hídrico y se han desarrollado indicadores de escasez que incluyen los usos y la demanda de agua en la cuantificación del déficit de agua. En consecuencia, la sequía se puede definir desde el punto de vista conceptual y operativo, la sequía conceptual que se aborda a través de los índices estandarizados determina una desviación de la variable de su valor medio que se puede asociar con un déficit en la lluvia, la demanda atmosférica, la humedad del suelo, el caudal, el agua subterránea, etc. Mientras que la sequía operacional o de escasez determina el déficit sobre el suministro de agua, teniendo en cuenta entre otros factores la asignación de prioridades en el uso del agua (Palop-Donat et al., 2020). Entre los indicadores que se emplean para analizar los impactos de la sequía operativa se encuentran el índice de estado de la sequía (IES) que emplea como insumo el SPI y el índice de estado de la escasez que emplea como insumo la precipitación, los niveles piezométricos, aforos, entradas y volúmenes de embalses.

Finalmente se identificaron una serie de índices que emplean información de sensores remotos para medir el déficit de agua y las anomalías en la actividad de las plantas, entre ellos se encuentran el vegetation condition index (VCI), el soil moisture agricultural drought index (SMADI) los cuales emplea datos de la resolución radiométrica, este último del sensor MODIS, y el soil Moisture and Ocean Salinity (SMOS) (Vicente Serrano, 2021).

## **2.2 Sistemas de monitorización de sequía hidrometeorológica a gran escala.**

La relevancia de las sequías en Europa ha cambiado desde el último siglo debido a las implicaciones económicas y ambientales que conlleva afrontar una sequía. Dado el incremento sobre la frecuencia y severidad con la que se presenta este fenómeno observado recientemente, es plausible pensar que las sequías se ven influenciadas tanto por fenómenos de cambio climático como por intervenciones antrópicas más directas como cambios en el uso de suelo. Asimismo, el aumento en el uso del agua para actividades humanas ha aumentado la exposición a estos fenómenos de sequía.

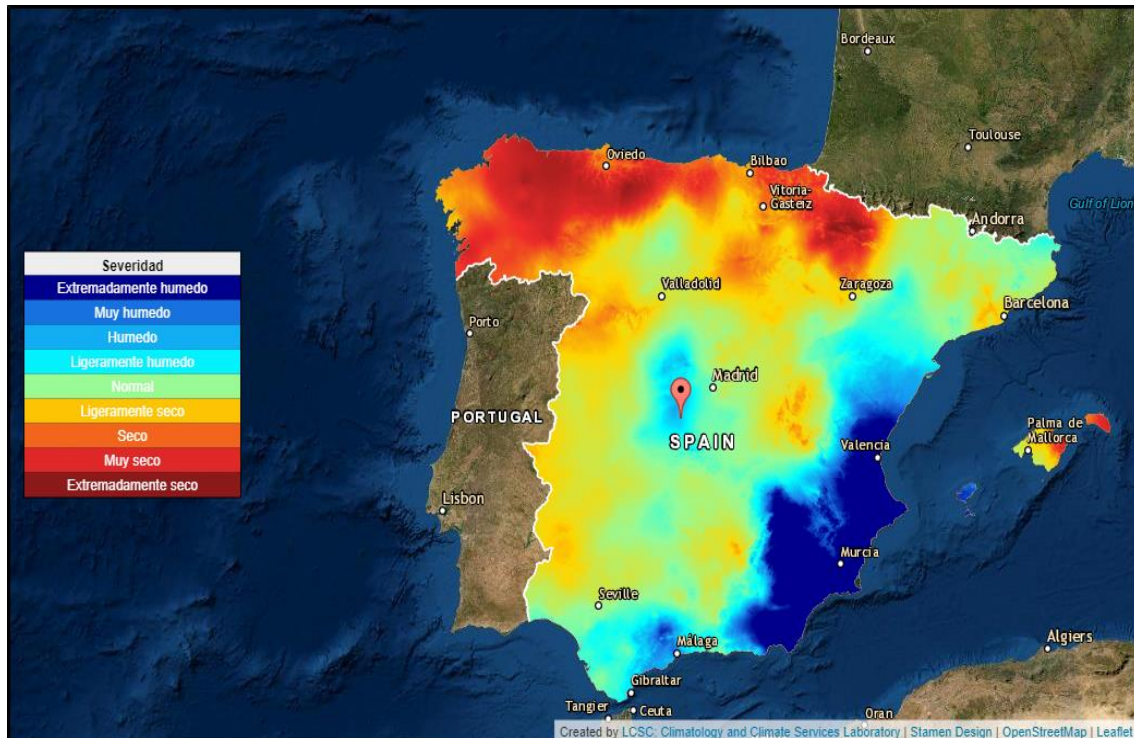
Es así que para los últimos años la producción científica que estudia el efecto de las sequías va en aumento. Vicente Serrano (2021) indica que una gran parte de estos estudios se enfocan en:



- (i) Reproducir los efectos de las sequías sobre el ciclo hidrológico
- (ii) El desarrollo de índices estandarizados de sequía
- (iii) La evaluación de políticas de sequía y su desarrollo en los planes de manejo
- (iv) Alertas tempranas sobre sequías y medidas de gestión para hacerles frente.
- (v) Análisis del impacto de las sequías sobre la vegetación
- (vi) Impacto sobre las aguas subterráneas
- (vii) Evaluación de las sequías usando sensores remotos
- (viii) Impactos sobre la degradación de la tierra.

Ello evidencia un gran campo de aplicación. España es uno de los países que lidera la investigación y la práctica en referencia a las sequías. Diferentes investigaciones que analizan los patrones de las sequías han identificado que en regiones tales como la Comunidad Valenciana, Andalucía, la cuenca central del Ebro, Cataluña, las Islas Baleares y el Norte de España, la ocurrencia de sequías es cada vez más frecuente, y en cada una de las regiones el comportamiento de las sequías y los patrones se pueden identificar en diferentes escalas de tiempo (Vicente Serrano, 2021).

Por esta razón, hace varios años; el Consejo superior de investigaciones científicas (CSIC), en colaboración con otras instituciones y científicos del país, ha desarrollado un monitor de sequías meteorológicas, el cual proporciona información sobre severidad de las sequías con un intervalo de tiempo semanal, ver Figura 2. El sistema de monitoreo de sequías recibe la información de dos redes: la primera la red meteorológica de AEMET y la segunda la red SIAR del Ministerio de agricultura de España. Una vez recibidos los datos, se procesan y se calculan la severidad, duración e intensidad de dos índices de sequía: el SPI (índice de precipitación estándar) y el SPEI (índice de precipitación evapotranspiración estándar) (CSIC, 2015).



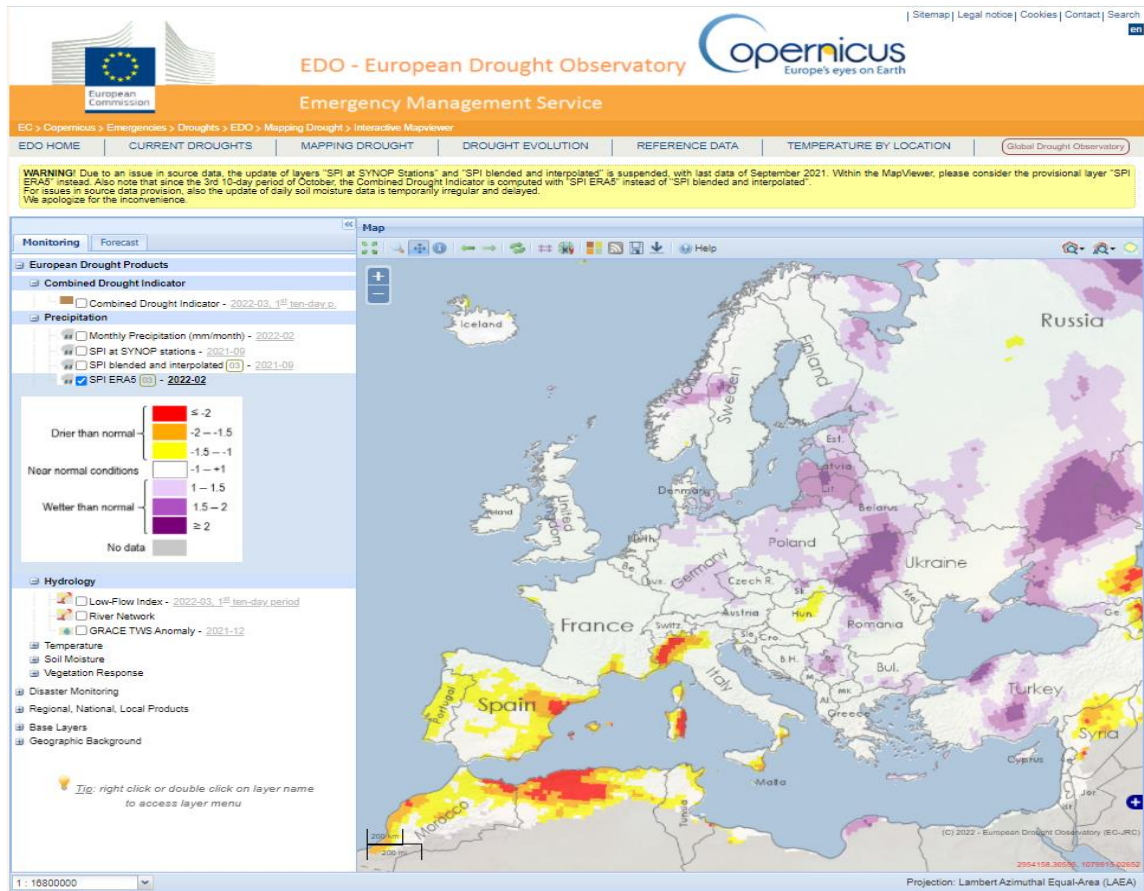
**Figura 2 Monitor de sequía meteorológica**

Fuente: (CSIC, 2015).

El sistema de monitoreo permite observar como la sequía avanza en el espacio y en el tiempo y muestra las anomalías de los indicadores respecto a las condiciones normales (periodo histórico). En aquellos lugares categorizados en condiciones de sequía por el índice, el sistema permite conocer la persistencia (duración) y la intensidad (severidad acumulada).

En Europa también existen diferentes servicios climáticos que monitorean índices de variables hidrometeorológicas en tiempo real. El Observatorio Europeo de Sequías (*European Drought Observatory, EDO*) colabora con diferentes instituciones a través de Europa, entre las que se encuentran, aquí en España, las Confederaciones Hidrográficas del Ebro y del Segura. Este servicio climático produce continuamente información, a escala de Europa para los índices de sequía más comunes, ver Figura 3.





**Figura 3 Herramientas cartográficas para la evaluación de sequía**

Fuente : (European Drought Observatory, 2017)

El EDO produce información para indicadores basados en (i) el contenido de agua en el suelo, como son el índice EDO de anomalía en la humedad del suelo y el índice de severidad de sequía; (ii) el estrés hídrico de las plantas como el índice de severidad de Palmer; (iii) índices de sequía que estiman la escasez de agua en ríos y embalses tal como el índice EDO de flujo mínimo (LFI); y (iv) indicadores combinados que incluyen anomalías de precipitación y de humedad del suelo. También se incluyen mediciones realizadas a través de imágenes de satélite de las condiciones de la vegetación (European Drought Observatory, 2017).

El EDO tiene un equivalente a escala global que es Observatorio Global de Sequías (*Global Drought Observatory, GDO*) el cual tiene como principal objetivo el monitoreo de las sequías que pueda aportar a la gestión de riesgo de desastres en otras partes del mundo como son África, centro y sur América (European Drought Observatory, 2021).



Para Estados Unidos existe el Monitor de Sequía de los Estados Unidos (The United States Drought Monitor, USDM) desarrollado en conjunto por the National Drought Mitigation Center at the University de Nebraska-Lincoln, the National Oceanic and Atmospheric Administration (NOAA) y the U.S. Department Agriculture (USDA). El monitor emplea el índice de severidad de Sequías de Palmer, el SPI, indicadores de humedad del suelo e información hidrológica, además de otros índices de vegetación (National Drought Mitigation Center et al., 2022). Este servicio climático no realiza pronósticos de las variables, de hecho, realiza una evaluación de las sequías a escala semanal empleando los registros de precipitación actualizados cada martes.

Existen otros tipos de servicios climáticos, que monitorean fenómenos de variabilidad climática; en Asia existe Beijing Climate Centre (BCC) entre la información que aporta este servicio climático se encuentran pronósticos mensuales, estacionales y anuales de cambios importantes en la atmosfera como es el fenómeno de oscilación sur (ENSO) que afecta al este de Asia y América.

### **2.3 Predicciones meteorológicas e hidrológicas**

Las predicciones de variables meteorológicas e hidrológicas se pueden obtener de dos formas: a través de modelos hidrológicos que emplean como variable de entrada predicciones de variables meteorológicas; o por algoritmos de sistemas de predicción numéricos que realizan directamente las predicciones de las variables hidrológicas (Wu et al., 2020).

Las predicciones de variables meteorológicas se obtienen a través de modelos de circulación general (GCMs). Estos modelos describen la evolución océano-atmosférica y los procesos físicos que influyen en las condiciones del tiempo, el clima y dinámicas marino-costeras. Un ejemplo de estas predicciones es el ECMWF (European Centre for Medium-Range Weather Forecasts) un centro de Investigación que produce predicciones numéricas del clima a escala global. Una de sus líneas de investigación se centra específicamente en pronósticos, por lo cual desarrolló ECMWF IFS, un sistema de predicción integrado que incluye modelos acoplados que se especializan en describir el estado de

un componente del océano y/o atmósfera. Owens & Hewson (2018) describen que entre los modelos del ECMWF IFS se encuentran:

- (i) Un modelo atmosférico ejecutado a diferentes resoluciones espaciales y temporales (HRES, ENS, extended range and seasonal), cada de ellas adaptada a un objetivo específico, y a partir del cual se pueden realizar pronósticos.
- (ii) Un modelo de circulación oceánico (ECWAM) que también se encuentra configurado para diferentes resoluciones (HRES-WAM)
- (iii) Un modelo oceánico (NEMO) que incluye un modelo en las regiones con abundante hielo (sea ice model)
- (iv) Un modelo de la superficie de la tierra (HTESSEL) que incluye almacenamiento superficial de agua (lagos)
- (v) Un sistema de análisis de datos que se encarga de la optimización condiciones iniciales de las predicciones, asegurando un ajuste óptimo de todas las observaciones.

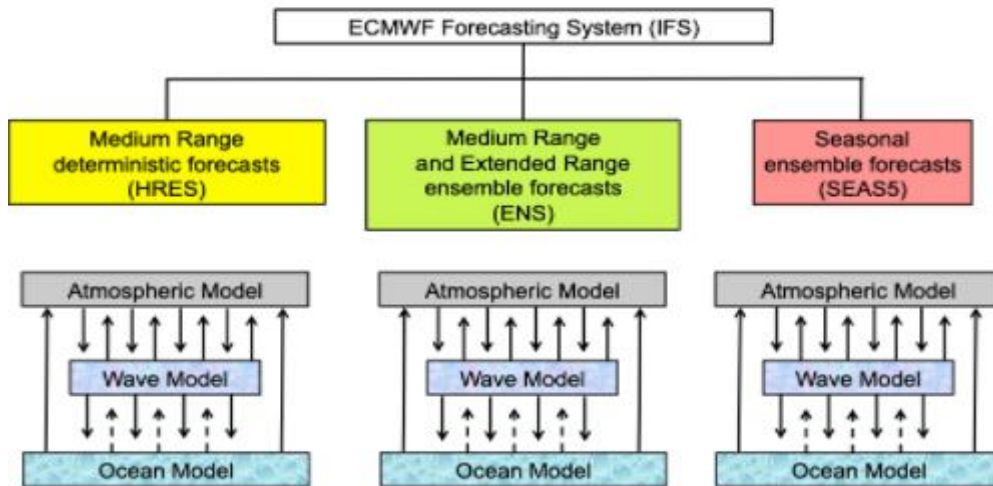
En relación con el modelo atmosférico, existen diferentes enfoques de predicción. Algunos emplean un enfoque determinista, es decir generan un único escenario de predicción del estado futuro, con cierto grado de incertidumbre. Otros modelos, en cambio, emplean el enfoque de predicción probabilística que realiza múltiples predicciones, es decir un sistema de predicción por conjuntos o, en inglés, “ensembles” (Wu et al., 2020).

El modelo atmosférico del ECMWF IFS, se puede dividir en tres sub-modelos en función de su resolución, los cuales presentan pequeñas diferencias en la configuración, aunque la estructura del modelo atmosférico se mantiene (ver Figura 4).

El modelo HRES (high resolution forecasts) emplea un enfoque determinístico, realizando un único pronóstico para 10 días con una resolución espacial aproximada de 9 km. El modelo ENS (Ensemble) emplean un enfoque de predicción probabilística, en donde se realizan 51 predicciones para 15 días que tienen una resolución espacial de 18 km, y que cuenta también con un modelo extendido (Extended-Range forecasts) ejecutado a partir del día 15 al 46 (Owens & Hewson, 2018).

Por último, el modelo System5 forecasts o Long-Range seasonal ensemble forecasts (SEAS5) proporciona una visión del estado de la atmósfera para

un periodo entre 7 y 12 meses. Al igual que el modelo ENS realiza 51 predicciones a una resolución espacial aproximada de 36 km. El modelo se ejecuta el primer día de cada mes para predicciones de 7 meses de anticipación y escala trimestral para predicciones de 12 meses de anticipación (Owens & Hewson, 2018).



**Figura 4 Interacción entre los componentes del IFS**

Fuente: (Owens & Hewson, 2018)

Dada la resolución espacial de cada uno de los modelos, se puede observar que el modelo HRES proporciona una descripción espacial y temporal más detallada de los patrones atmosféricos si se compara con los otros modelos, sin embargo Owens & Hewson (2018) mencionan que en términos de capacidad de predicción (skill), cuando se realizan muchas predicciones, el término medio de estas predicciones puede reproducir de forma más precisa los patrones meteorológicos a gran escala, debido que cuando se realiza una única predicción no se pueden establecer la incertidumbre o el nivel de confianza.

A pesar de lo anterior, Wu et al. (2020) describe que la predicción probabilística por conjuntos (ensemble forecasting) también tiene fuentes de incertidumbre, cuatro en concreto, que pueden ser aplicables a cualquiera de los modelos atmosféricos. Estas son: los datos de entrada, la estructura del modelo, los parámetros del modelo y datos de evaluación para la validación del modelo. Para predicciones con más de 2 o tres días de anticipación, la mayor incertidumbre proviene de la entrada de las predicciones meteorológicas. Es así que muchos institutos y programas de investigación emplean los datos de los modelos



atmosféricos y los ajustan para diferentes regiones de interés, empleando técnicas, entre las que se encuentran la reducción de escala dinámica o estadística.

Copernicus es un programa de la Unión Europea que desarrollo tres servicios de información enfocada con diferentes objetivos: calidad de la atmósfera, cambio climático y gestión del riesgo a desastres naturales. Estos se denominan, respectivamente, Copernicus Atmosphere Monitoring Service (CAMS), Copernicus Climate Change Service (C3S) y Copernicus Emergency Management Service (CEMS). El ECMWF contribuye mayoritariamente al CEMS y al C3S, en la predicción de variables meteorológicas que alimentan los sistemas de alerta temprana de amenazas por inundación e incendios. CEMS cuenta con una base de datos geoespacial de observaciones continuas de sequías (European drought Observatory-EDO) anteriormente descrito, en donde se realiza un monitoreo en tiempo real de las sequías. También cuenta con un servicio para la predicción de incendios (European Forest Fire information system-EFFIS) y la predicción de variables hidrológicos (European Flood Awareness system-EFAS) entre otras cosas para el monitoreo de inundaciones (Wetterhall, 2021).

En particular, el sistema EFAS combina los pronósticos meteorológicos con un modelo hidrológico, LISFLOOD, para proporcionar pronósticos hidrológicos que brinden información de las condiciones de los ríos a países de la Unión Europea situados aguas abajo de los ríos susceptibles a inundaciones (Prudhomme, 2021). El modelo hidrológico LISFLOOD, es un modelo hidrológico distribuido que usa como variables de entrada información meteorológica de precipitación, temperatura, evapotranspiración potencial e índices de evaporación, para calcular un balance de agua a escalas de tiempo de 6 horas o diarias en una malla de resolución aproximada de 5 km (Prudhomme, 2021). EFAS tiene su equivalente a escala global que es el sistema GloFAS, que se encarga del monitoreo de la inundación para otras regiones del mundo.

También existen otro tipo de modelos hidrológicos que estiman los procesos y almacenamientos de los diferentes componentes del ciclo hidrológico, ejemplo HBV-N (Arheimer & Brandt 1998), MONERIS (Behrendt et al. 2002), SWAT (Arnold & Fohrer 2005), SWIM (Krysanova et al. 2005), VIC-WUR model (Liang et al, 1994) y HYPE (SMHI, 2005) (Lindström et al., 2010).

## 2.4 Modelo hidrológico E-HYPE

Hydrological Predictions for the Environment (HYPE) es un modelo hidrológico de código abierto desarrollado por el Swedish Meteorological and Hydrological Institute (SMHI) que simula los procesos del ciclo hidrológico y sustancias que pueden ser arrastradas por la precipitación hasta llegar a depositarse (Lindström et al., 2010), empleando como unidad de análisis la cuenca. El modelo tiene las siguientes características:

- (i) Es un modelo semidistribuido, subdividido en subcuencas de ríos o arroyos conectados al río principal y a un flujo de agua subterráneo o subcuencas independientes (Lindström et al., 2010). Los parámetros del modelo pueden ser globales o divididos en unidades de respuestas rápidas (HRUs) basados en el tipo de suelos y en el tipo de cobertura (Hundechea et al., 2020).
- (ii) Es un modelo físicamente basado, tiene incorporado códigos para la mayoría de procesos hidrológicos que ocurren en la superficie y en la subsuperficie del suelo, como son acumulación y fusión de nieve, evapotranspiración, humedad del suelo, escorrentía, recarga y descarga de acuíferos, niveles de agua subterránea, y flujo a ríos y lagos (Pechlivanidis et al., 2020). Estos procesos y almacenamientos los calcula con un paso temporal diario u horario (Hundechea et al., 2020).
- (iii) El modelo introduce en la calibración las observaciones de caudales realizadas en campo, de las principales bases de datos nacionales de 115 estaciones, seleccionadas en un área de drenaje mínimo de 1000 km<sup>2</sup>. La evaluación y regionalización del modelo se realizó para un total de 538 estaciones sin influencias de alteraciones humanas (Hundechea et al., 2016).

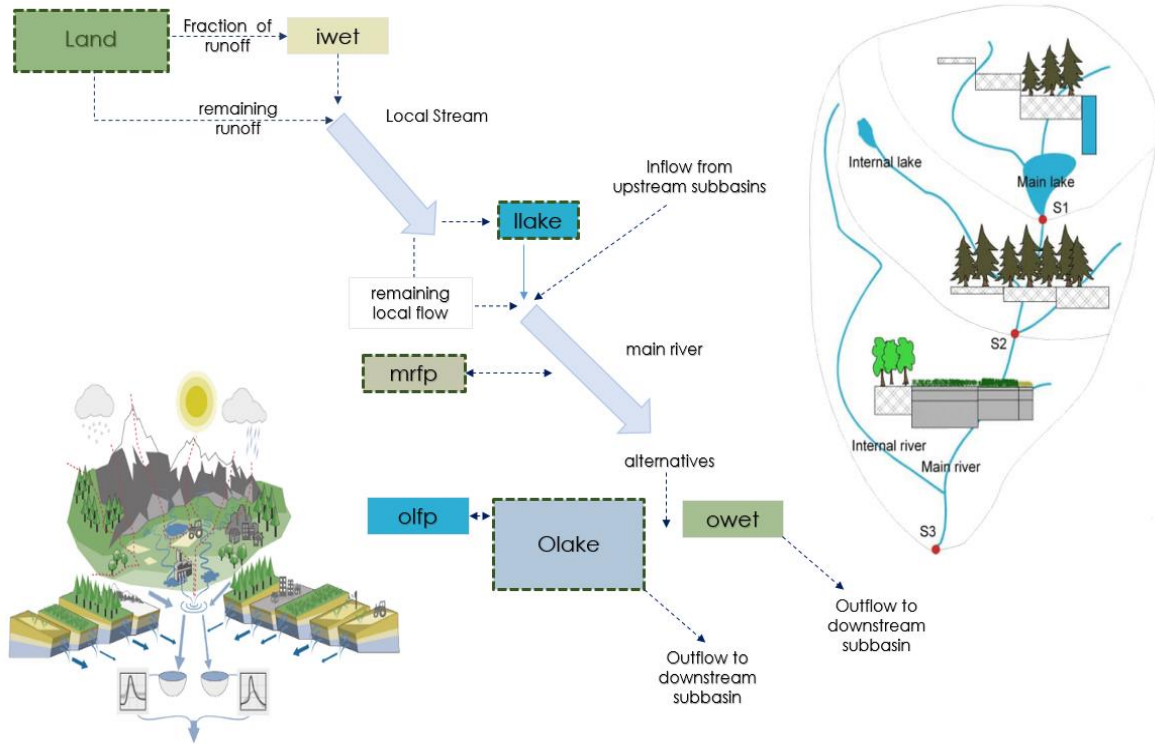
El modelo HYPE, configurado a escala pan-Europea, se denomina E-HYPE, y es empleando para el análisis de alrededor de 35.408 subcuencas, que tienen en promedio un tamaño de 248 km<sup>2</sup> y que abarcan una extensión total de 8.8 millones de km<sup>2</sup> (Donnelly et al., 2016).

Las variables meteorológicas de entrada del modelo (precipitación promedio diaria y temperatura), provienen del SEAS5 y fueron ajustadas con las series de HydroGFD, una base de datos (re



análisis meteorológicos y observaciones históricas de estaciones) a través de la cual puede realizar una corrección de los modelos atmosféricos con una resolución espacial de 0.5 grados. HydroGFD permitió ajustar los datos de referencia que fueron usados en el modelo hidrológico E-HYPE para el periodo de 1991-2015; los dos primeros años son usados para crear los estados del modelo (Pechlivanidis et al., 2020).

En la Figura 5 se muestra que cada subcuenca del modelo HYPE se encuentra dividida en 9 elementos: (1) Land, relacionado con los procesos de evapotranspiración, intersección, infiltración y recarga, que cambian en función de la cobertura de la tierra y tipo del suelo; (2) iwet, que integra los almacenamientos e intercambios de agua, precipitación-evapotranspiración de humedales locales; (3) local stream, que representa el flujo de agua proveniente de la escorrentía, percolación a ríos secundarios; (4) ilake, que se refiere al almacenamiento en lagos internos que pueden provenir de ríos locales; (5) main river floodplain (mrfp), que se refiere a los procesos hidrológicos que ocurren en la llanura de inundación; (6) main river (mriver), representa el aporte de agua que proviene de ríos secundarios, la llanura de inundación, flujo base y lagos internos a ríos principales; (7) outlake floodplain (olfp), se refiere a los procesos hidrológicos de la llanura de inundación de los lagos; (8) outlet lake (olake), recibe, almacena y transfiere el flujo que proviene de la llanura de inundación de los lados y/o de ríos principales hasta la desembocadura del río; y (9) outlet wetland (owet), recibe y transporta hacia la desembocadura de la cuenca el flujo proveniente de los ríos principales.



**Figura 5 Elementos del modelo hidrológico HYPE.**

Fuente: Modificado de (Hundecca et al., 2016; Lindström et al., 2010; SMHI, 2020).



## Capítulo 3. Caso de estudio e información

### 3.1 Área de Estudio.

Las 617 subcuencas extraídas del modelo E-HYPE fueron seleccionadas teniendo en cuenta que cada una de estas subcuencas cuentan con una estación de aforo en el punto de desembocadura, lo que significa que han sido empleadas en la calibración del modelo. Las subcuencas tienen asociado un código (SUBID) que la relaciona con el río principal y permite agruparla con otras subcuencas del modelo de similares características hidrológicas. La selección ofrece una muestra representativa de los diferentes tipos de climas, accidentes geográficos e hidrología existentes en Europa. Las subcuencas seleccionadas presentan una extensión en promedio de 4691 km<sup>2</sup>, con rangos de precipitación media que van desde 15 mm/año en climas áridos hasta 2108 mm/año en climas húmedos, ver Tabla 1

**Tabla 1 Características de las subcuencas de E-HYPE**

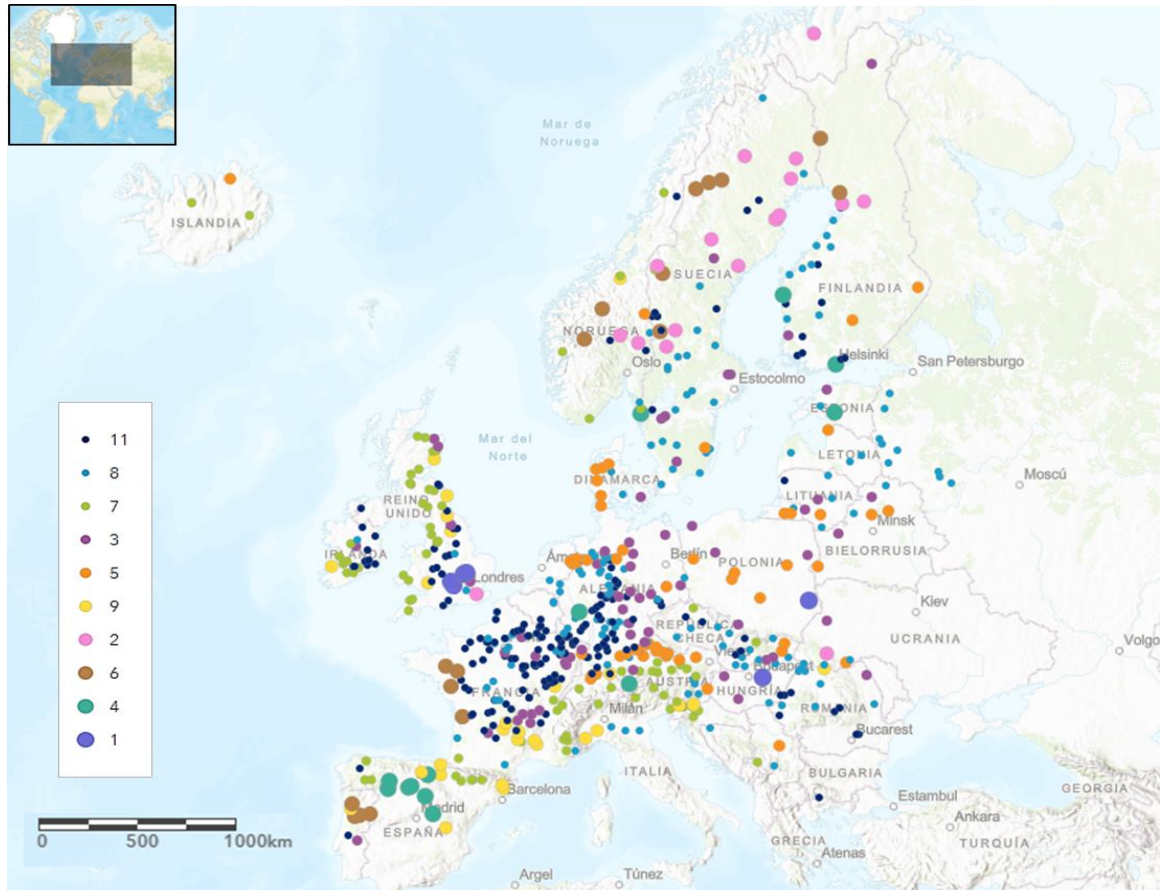
Statistic	5%	25%	Median	75%	95%	Min	Mean	Max
<b>Basin surface (km<sup>2</sup>)</b>	565	854	1500	3814	20261	503	4691	95970
<b>Mean annual runoff (mm)</b>	139	264	371	576	1035	15	461	2108
<b>Interannual variability of runoff (%)</b>	13	19	24	29	41	6	25	139
<b>Availability of records during 1981-2010* (%)</b>	20	37	83	97	100	10	69	100

Fuente: Hydrology Research Unit 2021

Para identificar cuencas hidrológicas similares, E-HYPE clasificó 15 streamflow signatures (índices que caracterizan el comportamiento hidrológico) que dieron como resultado la agrupación de las subcuencas en 11 agrupaciones o clústeres.

Se destaca que la muestra que hace parte de este estudio cuenta con subcuencas representativas de 10 de los 11 clústeres definidos para el modelo HYPE, cada uno de ellos con un número variable de subcuencas. Se identificó que aproximadamente el 54.3% de las subcuencas se

encuentran incluidos en los clústeres 8 y 11 y alrededor del 32.4%, incluyen los clústeres 3,5 y 7. Las subcuencas restantes, que representan el 13.3% se encuentran distribuidas en los clústeres 1, 2, 4, 6 y 9. La muestra no incluye subcuencas representativas del clúster 10, caracterizado por sistemas hídricos de climas mediterráneos ubicados en bajas latitudes (ver Figura 6).



**Figura 6 Clústeres del Modelo E-HYPE para las subcuencas de estudio**

Fuente: Elaboración propia

Pechlivanidis et al. (2020) describe las características de subcuencas agrupadas en cada clúster:

- Los clústeres 1 (subcuencas de Polonia y Dinamarca), 8 (subcuencas situadas en Europa central) y 9 (subcuencas de Escandinavia y Rusia) experimentan una gran memoria, derivada del flujo de base. Estas cuencas tienen largas recesiones con una pequeña variabilidad anual y, por lo tanto, con muy poca respuesta a las precipitaciones.

- Las subcuencas del clúster 2 se caracterizan por largas recesiones en su respuesta hidrológica, pero los frecuentes eventos de precipitación dan lugar a frecuentes picos de caudales máximos. Estas subcuencas se encuentran principalmente en Suecia, el sur de Finlandia y Rusia.
- El clúster 3 incluye subcuencas del centro-norte y del noroeste de Rusia. Su régimen de caudales está determinado por procesos de fusión de nieve (es decir, el deshielo durante la primavera), mientras que la presencia de lagos y humedales resulta en la amortiguación de los caudales.
- La alta estacionalidad causada por la fusión de nieve también caracteriza a las cuencas de los grupos 4 y 5, que se encuentran en regiones muy elevadas y/o de clima continental frío. La regulación para la producción de energía hidroeléctrica durante el invierno también afecta el régimen de caudales en el clúster 4.
- Las cuencas del clúster 6 están generalmente repartidas por Europa y son muy sensibles a las precipitaciones, pero con largas recesiones.
- Las cuencas del clúster 7 se encuentran en un clima mediterráneo cálido y templado, pero ubicadas en altitudes altas, mientras que su régimen de caudales se caracteriza por una gran variabilidad. La respuesta de los caudales es muy sensible a las precipitaciones mientras que la evapotranspiración es baja.
- Las subcuencas del grupo 11 están situadas en el este de Ucrania y el sureste de Rusia y se caracterizan por un bajo coeficiente de escorrentía y una variabilidad anual relativamente alta variabilidad anual determinada por el riego.

### 3.2 Datos de E-HYPE

Los modelos de predicción meteorológica e hidrológica ejecutados para periodos pasados se conocen como pronósticos del pasado o hindcasts. Por lo general emplean un amplio periodo histórico (décadas) y su objetivo es estimar la capacidad de predicción y las necesidades de ajuste o corrección considerando este periodo histórico como la simulación de referencia. En el caso del enfoque de predicción probabilística (modelos ENS y SEAS5), el número de predicciones para el pasado para la cual se ejecuta el modelo se reduce de 51 a 25 para reducir las necesidades de computación, ya que 25 es considerado un

número suficiente para estimar la calidad del servicio y determinar los ajustes a realizar.

Los datos extraídos por el SMHI del modelo E-HYPE para este proyecto, son hindcasts obtenidos a partir de predicciones meteorológicas del modelo ECMWF SEAS5, ajustadas usando el método Distribution based scaling (DBS). Se contó con información de 25 trayectorias para cada mes del periodo comprendido entre 1993-2014, y cada trayectoria dispone de datos inicializados el primer día de cada mes con pronósticos de 215 días de anticipación (aproximadamente 7 meses). La información suministrada se encuentra almacenados en formato de texto (txt), uno por cada variable, para una muestra de 617 subcuencas del modelo Estacional E-HYPE (Tabla 2).

**Tabla 2 Variables suministradas del modelo E-HYPE**

Variable ID	unidad	Descripción	Componente
COUT	m3/s	caudal promedio diario en el punto de salida de la subcuenca.	Hidrológica
CPRC	mm/día	Acumulado de precipitación diaria corregida para la elevación media de la subcuenca	Meteorológica
EPOT	mm/día	Acumulado de evapotranspiración potencial para la subcuenca	Meteorológica
EVAP	mm/día	Acumulado de evapotranspiración real para la subcuenca	Meteorológica
SRFF	%	Humedad del suelo en la zona radicular como fracción de volumen.	Edáfica

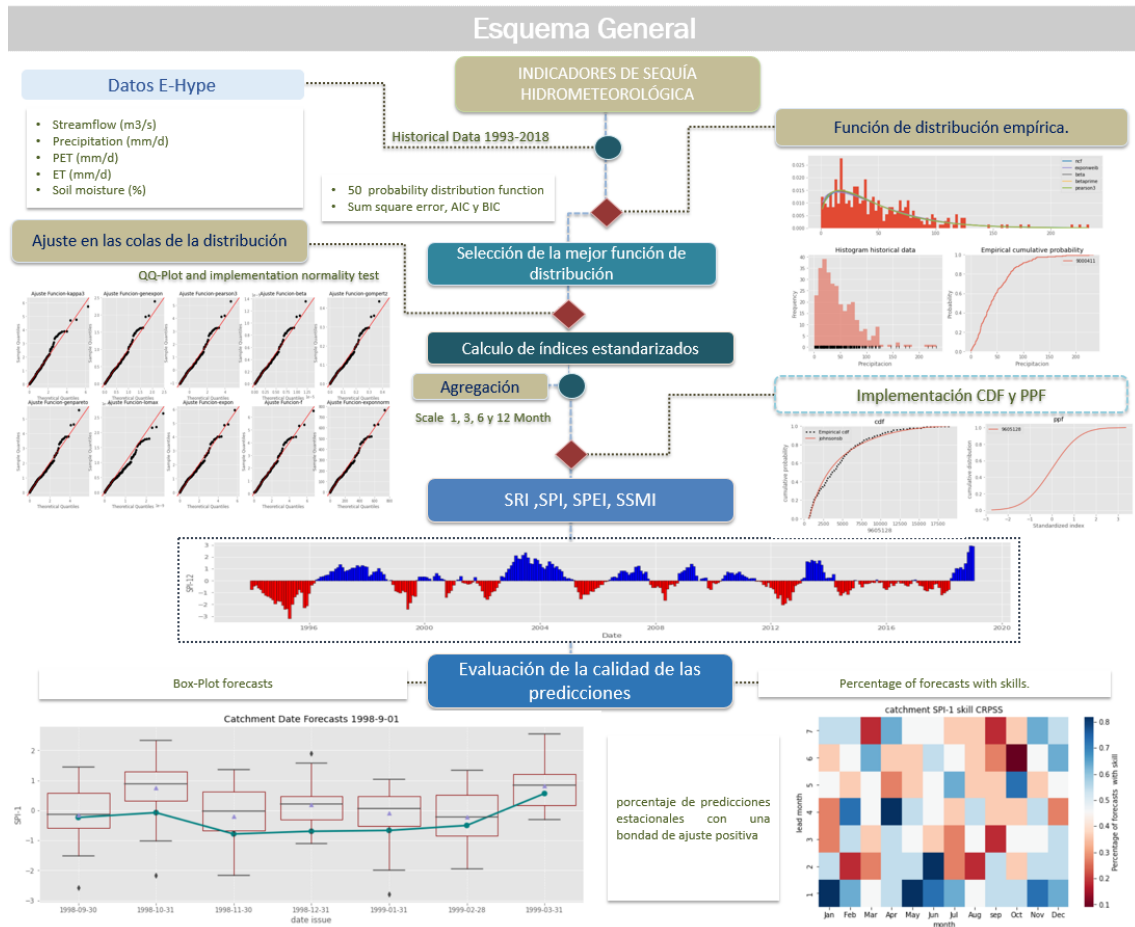
Fuente: (SMHI, 2020)

## Capítulo 4. Metodología

En la Figura 7 se presenta un esquema general con la metodología de análisis empleada en este documento para calcular índices estandarizados de sequía y estimar su capacidad de predicción con E-HYPE, que se ha desarrollado mediante el lenguaje de programación Python, con el que se ha programado un código que calcula los índices estandarizados y la capacidad de predicción de los hindcasts. La metodología toma como dato de entrada (*Datos E-HYPE*) las variables modeladas para el periodo histórico disponible para E-HYPE (1993-2018); a partir de los que se calcula el histograma de frecuencias acumuladas y la función de distribución empírica para la subcuenca y variable seleccionada (*Función de distribución empírica*). Esta información se presenta en gráficas que permiten ver la distribución y comportamiento de los datos en el tiempo.

Tras ello se realiza el ajuste de una selección de funciones de distribución teóricas a la función de distribución empírica (*select best distribution function*). Para encontrar la mejor función de distribución teórica que represente de manera adecuada los datos históricos de la variable se prueban alrededor de 50 funciones de distribución, realizando la selección de sus parámetros en función de tres métodos de estimación de los mismos: SSE (suma del error cuadrado), AIC (akaike information criterion) o BIC (Bayesian information criterion). De éstas se seleccionan las 10 que presentan el mejor ajuste (*select best distribution function*) y se les aplica el test de Kolmogorov-Smirnov, eligiendo como mejor función de distribución la que tenga el menor estadístico en este test (Ajuste en las colas de la distribución).

Tras evaluar la bondad de ajuste de las funciones de distribución teóricas y seleccionar la más adecuada, se estiman los parámetros necesarios para calcular las funciones de distribución acumulada y punto percentil (*implementación CDF y PPF*), a través de las cuales se obtiene el percentil asociado a la probabilidad de ocurrencia de un evento de la variable de interés, es decir el valor de índice estandarizado.



**Figura 7 Marco de referencia**

Fuente: Elaboración propia

Una vez calculado el índice se evalúa su normalidad a través de diferentes test de bondad de ajuste (graficas QQ-plot y los test de normalidad test D'Agostino's K-squared, Wilcoxon, Kolmogorov-Smirnov para muestras normales). Si el índice no tiene un comportamiento normal, se realiza de nuevo el proceso de ajuste de la función, separando el primer y el tercer cuartil de la serie, donde se ubican los valores extremos y seleccionando las funciones que mejor ajustan en la cola de la distribución, si nuevamente se rechaza la normalidad de la serie, se cambia el método de estimación de parámetros, AIC o BIC y se inicia de nuevo en ajuste y selección de la función de distribución teórica.

En este estudio se emplearon cuatro índices estandarizados que permitieron caracterizar eventos de sequía meteorológica (SPI, SPEI), edáfica (SSMI) e hidrológica (SRI). El ajuste de las funciones de distribución

y el cálculo de índices de sequía se realizó para el periodo de referencia previamente indicado y para las escalas de agregación de 1, 3, 6 y 12 meses. Después de obtener las funciones de distribución para cada mes de agregación, sus parámetros se almacenaron y emplearon para calcular posteriormente los índices estandarizados de los hindcasts. También se puede visualizar la variabilidad de los índices de sequía a través de graficas de *Box-Plot*.

Finalmente, se calcularon dos índices de calidad de la predicción o skills para evaluar la capacidad de predicción de los hindcasts. Para ello se emplearon el MAE y MAESS, que miden la diferencia entre el valor promedio de los hindcasts y el valor histórico; y el CRPS y CRPSS, que comparan la función de probabilidad ofrecida por los hindcasts en relación al valor histórico. Estos dos indicadores se representan a través de mapas de calor (heatmaps) que indican el porcentaje de acierto o fallo que tienen los hindcasts prediciendo la variable.

Los diferentes pasos, gráficos, test y estadísticos descritos previamente y empleadas en el código tienen su propia metodología de cálculo, por lo que a continuación se amplía de la descripción de cada una de las herramientas estadísticas utilizadas.

#### **4.1 Funciones de distribución de probabilidad**

Las funciones de distribución de probabilidad se emplean para asignar la probabilidad a cada evento perteneciente a una serie de datos. Tienen múltiples aplicaciones en la hidrología estocástica y uno de ellos es la estandarización y normalización de las series, metodología empleada en la mayoría de los índices de sequía.

En la Figura 8, Leemis & McQueston (2008) presentan alrededor de 76 distribuciones de probabilidad univariantes, y emplea tres tipos de líneas para mostrar las relaciones matemáticas entre las distintas funciones de distribución. En línea sólida se muestran los casos especiales y transformaciones que se realizan sobre una función de distribución en específico, la línea discontinua se usa para relaciones asintóticas y la línea punteada se emplea para distribuciones con relaciones Bayesianas, en donde destacan la centralidad de los datos.

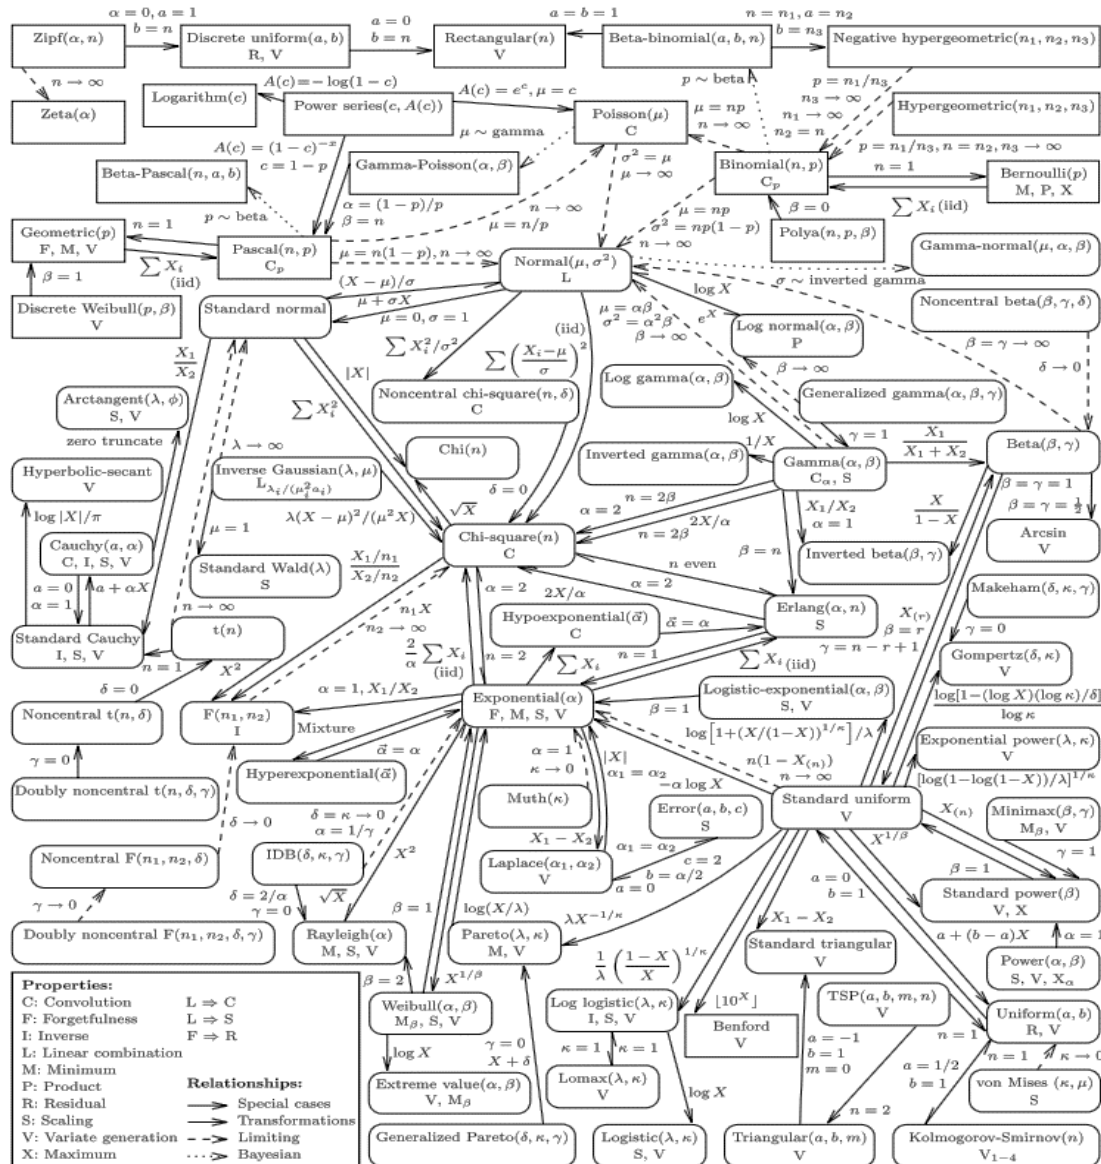


Figura 8 relaciones entre funciones de distribución univariante

Fuente: (Leemis & McQueston, 2008)

De manera general, la figura ilustra que las distintas funciones de distribución están relacionadas entre sí y que muchas son transformaciones de otras en donde se cambian algunos elementos o se adicionan parámetros que facilitan el ajuste.

En el caso de la estandarización de la precipitación, diferentes modelos se han usado para describir la lluvia de determinadas regiones; autores como Guttman (1999) concluyen que la función de distribución Pearson tipo III, es el mejor modelo universal y que permite ajustar las series de



precipitación dependiendo del tamaño de la serie. Otros autores como H. Wu et al. (2007) estudiaron la bondad de ajuste de la Gamma de dos parámetros para regiones con climas secos y recomiendan su aplicación en escalas cortas de tiempo. Lloyd-Hughes & Saunders (2002) realizaron que el proceso de estandarización de la precipitación asumiendo las distribuciones gamma, log-normal y normal, con las cuales obtuvieron buenos resultados en la normalización de la variable.

Según Vicente Serrano (2021) los primeros enfoques de la modelación para el ajuste de las colas de la distribución emplearon la distribución Gumbel, la cual selecciona muestras de la duración máxima anual de las sequías. Sin embargo, describe que esta metodología subestima el evento seco más extremo, debido a que este podría cambiar en función de la muestra seleccionada.

Para solucionar este problema, Vicente-Serrano & Beguería-Portugués (2003) desarrollaron una metodología que tomaba los picos que superaban determinado umbral (peaks over threshold) y estos picos se modelaban usando la distribución de Pareto generalizada. Según los autores esta función de distribución mostró buenos resultados en el ajuste de la precipitación en regiones de España y Europa. También existen otras distribuciones como Wakeby y Weibull que han mostrado buenos resultados en el ajuste de la precipitación (Vicente Serrano, 2021).

Para otras variables, Vicente-Serrano et al. (2010) analizó la función log-logística o fisk para realizar la estandarización de la diferencia entre precipitación – evapotranspiración de referencia. Sin embargo, Stagge et al. (2015) recomienda el uso de la distribución gamma para el ajuste del SPI y la General Extreme Value (GEV) para calcular el SPEI en Europa. A este respecto Vicente-Serrano & Beguería (2016) mencionan que las diferencias entre las funciones candidatas se encuentran en los métodos empleados para el ajuste de los parámetros de las funciones, y que las diferencias entre las funciones se encuentran principalmente en el ajuste de las colas, resultando una sobreestimación de los valores extremos del SPEI cuando se emplea la función GEV.

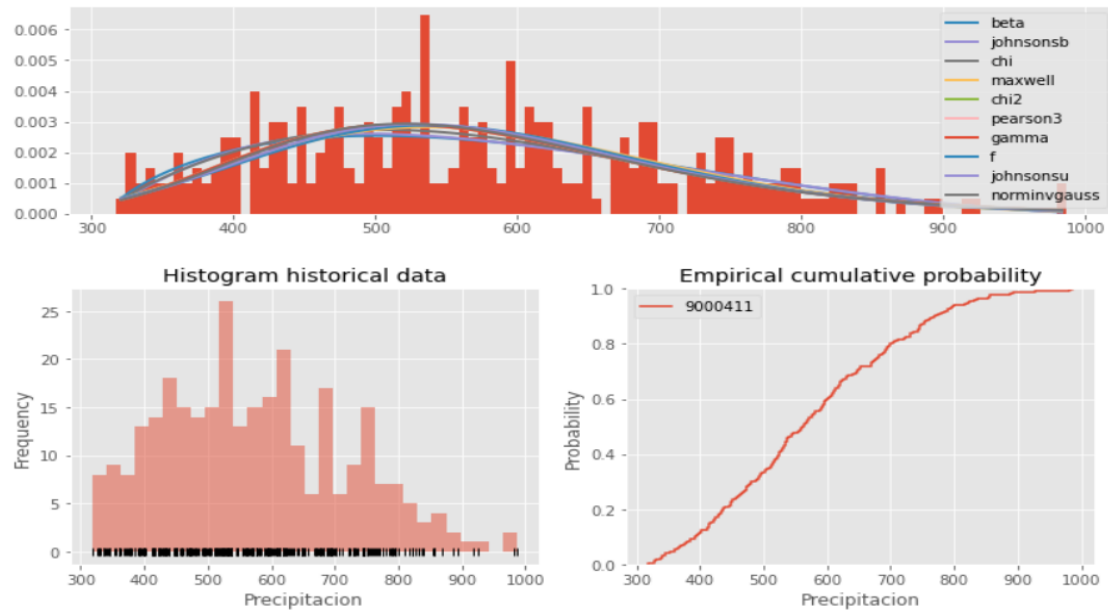
Para la estimación de indicadores de sequía hidrológica, se han empleado las funciones de distribución log-normal, Pearson tipo III, gamma de dos parámetros y GEV, generalized Pareto, Log-logistic y Weibull. En el estudio realizado por Vicente-Serrano et al. (2012) se sugiere



que las funciones de distribución con mejor ajuste para la estandarización de la escorrentía son las funciones GEV y log-logistic.

Este breve estado del arte para el ajuste de las variables hidrológicas y meteorológicas evidencia que existen diferentes recomendaciones en el uso de una u otra función de distribución para el cálculo de los índices de sequía. Lo que sí es recurrente en la mayoría de los estudios es que dependiendo del clima y la región puede que una función de distribución ajuste mejor que otras. En este punto, es importante mencionar que la selección y recomendación de una función de distribución para emplearla en la estandarización de un índice de sequía es un trabajo riguroso y de detalle, que requiere testear la función de distribución en diferentes regiones, con una base de datos amplia que permita la caracterización de los parámetros; y siendo conscientes que la selección de una u otra puede podría cambiar en función del método de ajuste de los parámetros.

Lo cierto es que con el caso de estudio de las 617 subcuencas no se puede asumir que una sola función de distribución sea la más adecuada para representar los datos de 5 variables para todas las subcuencas, especialmente cuando se tiene una variedad de climas. Lo más conveniente, dado una serie de datos de variable por subcuenca, es ajustar a diferentes funciones de distribución hasta encontrar la función de distribución teórica que mejor represente la función de distribución empírica. Para ajustar las variables a las funciones de distribución teóricas se empleó el paquete Fitter de Python, desarrollado por Thomas Cokelaer, el cual se encarga de identificar la función de distribución para una muestra de datos. El paquete llama 80 funciones de distribución de la librería scipy y permite graficar las funciones de distribución más probables y sus parámetros. El código en Python se configuró para que probara el ajuste con solo 50 funciones de distribución, para ahorrar tiempo de cálculo. Posteriormente, realiza el ajuste de las 10 funciones de distribución mejor ajustadas entre las 50 empleando los métodos suma del error cuadrado, AIC o BIC. El código permite visualizar el histograma de frecuencias acumuladas para la variable y la función de distribución empírica, ver Figura 9.



**Figura 9 Ajuste de distribuciones teóricas a distribuciones empíricas**

Fuente: Elaboración propia.

En relación con la estimación de los parámetros, su valor puede cambiar con la longitud de las series, por lo que a medida que se agreguen nuevos datos a las series se deberán ajustar nuevamente los parámetros. Para evitar que estos parámetros cambien a medida que se incorporan nuevos datos lo recomendable es emplear un periodo de referencia para estimar los parámetros de las series y aplicarlo a otros datos con características estadísticas similares (Podestá, 2020). Lo ideal es emplear un periodo de referencia largo que agrupe la mayor parte de la variabilidad de los datos, debido a que registros largos permiten describir épocas secas y húmedas, por el contrario, registros más cortos podrían estar sesgados al describir solo una parte de la variabilidad (Guttman, 1999).

La Organización Meteorológica Mundial & Asociación Mundial para el Agua (2016) mencionan que el ajuste de las funciones de distribución pueden ser realizado con registros mínimo de 20 años, siendo las condiciones ideales contar con datos de al menos 30 años. Para los datos de E-HYPE, el ajuste de las funciones de distribución se realizó para el periodo 1993-2015, un total de 22 años, que cumple con el registro mínimo de datos para el cálculo de los índices de sequía. Entre las funciones empleadas se encuentran las mostradas en la Tabla 3.

**Tabla 3 función de distribución de probabilidad**

<b>Variable</b>	<b>Funciones de distribución</b>
<b>Para todas las variables</b>	Beta, betaprime, cauchy, , cosine, dgamma, dweibull, expo, exponnorm, exponpow, exponweib, f, gamma, genexpon, genextreme, genlogistic, gennorm, genpareto, gilbrat, gompertz, gumbel_l, gumbel_r, invgauss, invweibull, johnsonsb, johnsonsu, kappa3, kappa4, laplace, levy, loggamma, logistic, loglaplace, lognorm, loguniform, lomax, maxwell, norm, norminvgauss, pareto, pearson3, powerlaw, powerlognorm', powernorm, weibull_max, weibull_min
<b>Específicas para Precipitación - evapotranspiración</b>	fisk
<b>Específicas para Precipitación, caudal y humedad del suelo.</b>	chi, chi <sup>2</sup> .

Fuente: Elaboración propia

#### 4.1.1 Estimación de parámetros

La mayoría de los métodos que se emplean para la estimación de parámetros transforman los datos disponibles en una línea recta que se ajusta a una función de distribución. Estos métodos comparan la variable aleatoria (función de distribución empírica) con la función de densidad de probabilidad (pdf) o la función de distribución acumulada (cdf) y evalúan cual es la mínima desviación entre ambas (O'Connor et al., 2016).

Existen, de manera general, tres métodos para la estimación de parámetros: el método de los momentos, la estimación por mínimos cuadrados (LSE) y el método de máxima verosimilitud. De estos métodos se han derivado otras técnicas estadísticas como la probabilidad de los momentos ponderados (PMW), y los índices AIC y BIC.

Uno de los métodos que emplea el paquete Fitter es el de mínimos cuadrados, que minimiza la suma del error cuadrado (SSE) entre los valores observados y los valores estimados (Salas, 1980); es decir, calcula la diferencia entre los valores la función de distribución empírica y la función de densidad de probabilidad, empleando la siguiente expresión:

$$SSE(f(x), y) = \sum_{i=1}^m (y_i - pdf(x_i))^2$$

Los otros dos métodos empleados por el paquete Fitter son los índices AIC y BIC, que también miden la desviación entre las funciones, pero considerando la verosimilitud (likelihood), es decir la probabilidad con la que una distribución podría haber generado la observación y el número de parámetros que emplea para hacer el ajuste.

El índice AIC sigue el principio de parsimonia: cuando el número de parámetros de la función aumenta, el AIC también aumenta. Por ello si se selecciona este método de ajuste de parámetros se debe seleccionar la función con menor AIC (Akaike, 1974). El AIC emplea la siguiente expresión matemática donde  $k$  es el número de parámetros que se emplea para hacer el ajuste:

$$AIC = -2 \log(\text{maximun likelihood}) + 2k$$

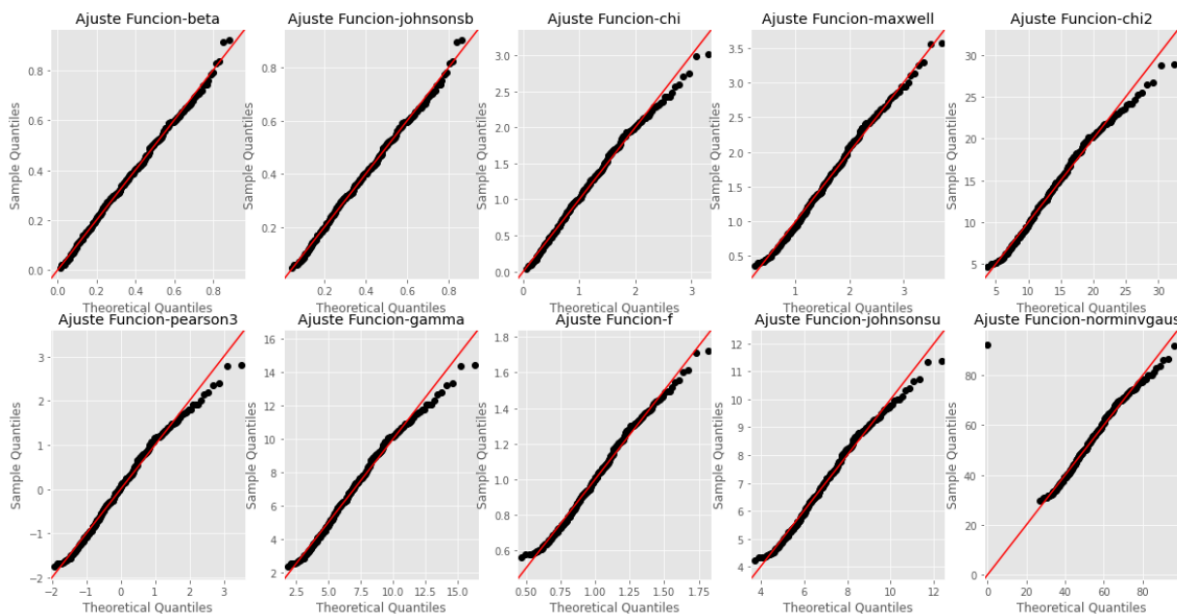
La diferencia entre AIC y el BIC se presenta en que BIC penaliza el número de los parámetros en función del tamaño de la muestra (Profillidis & Botzoris, 2019), empleando la siguiente expresión matemática:

$$BIC = -2 \log(\text{maximun likelihood}) + k \log(n)$$

## 4.2 Test de bondad de ajuste

Los test de bondad de ajuste son medidas que permiten evaluar, a través de gráficas y estadísticos, qué tan bien se reproducen los datos en el modelo ajustado. En este trabajo se han empleado gráficas QQ-plot, generadas con Python, y test estadísticos para evaluar la bondad de ajuste de la función de distribución más probable para cada subcuencia, y posteriormente analizar la normalidad de los datos.

Las gráficas QQ-plot se emplean para evaluar el ajuste en las colas de la distribución. Son gráficas de dispersión que comparan los cuantiles de la distribución empírica con los cuantiles de las distribuciones teóricas. Si los datos se distribuyen alrededor de una línea recta de 45 grados se puede interpretar que reproduce bien los datos a la función ajustada; por el contrario, cuanto más alejado se encuentre de la línea se puede considerar que peor es el ajuste, ver Figura 10.



**Figura 10 Ejemplo en el ajuste de las colas de la distribución**

Fuente: Elaboración propia

Para evaluar la bondad de ajuste existen diferentes test estadísticos que se diseñan a través de pruebas de hipótesis. Para el caso de estudio el objetivo a evaluar es que la distribución seleccionada se ajusta especialmente las colas de la distribución, debido a que es ahí donde se ubican los eventos extremos, asociados a las sequías. Para cumplir con este propósito, una vez seleccionadas las 10 mejores a través de los métodos de estimación de parámetros previamente descritos, se ha implementado el test de Kolmogorov-Smirnov (test K-S). Este estadístico mide la máxima diferencia (en valor absoluto) entre las distribuciones empírica y teórica (Mamoon & Rahman, 2019), comparando si las observaciones podrían proceder de la distribución asignada mediante la siguiente expresión matemática:

$$D = \max|F^*(x) - F_n(x)|$$

Donde  $F^*(x)$  es la función de distribución teórica y  $F_n(x)$  es la función de distribución empírica

Para cada subcuenca, entre las 10 funciones de distribución priorizadas entre el grupo de las 50 funciones, la que presente el menor p-value en el test K-S, es la que se selecciona para calcular los índices estandarizados de sequía. En este punto se observó que el test K-S por sí solo no garantizaba la normalización de los datos una vez calculado los índices estandarizados, por lo que fue necesario programar otros test de normalidad para el caso.

El Test Shapiro-Wilk mide la normalidad de los datos. Originalmente se empleaba una muestra de un tamaño menor a 50 datos, y es el primer test que mide la normalidad de los datos a partir del sesgo y la curtosis de los mismos. El sesgo es una medida de la asimetría de la distribución, y una de las características de las distribuciones normales es que son simétricas. Por otro lado, la curtosis mide el grado de concentración de los valores de una variable alrededor de las zonas central de la distribución; una distribución normal tiene un valor de curtosis de cero. El test se mide a partir del estadístico  $W$ , que toma valores entre cero y uno; valores pequeños de  $W$  se considera que los datos no siguen una distribución normal, mientras que valores de uno indican normalidad de los datos (Mohd Razali & Bee Wah, 2011)

$$W = \frac{(\sum_{i=1}^n a_i y_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}$$

El D' Agostino's K-squared test está basado en D' Agostino and Pearson's. También es una combinación del sesgo y la curtosis para establecer si la muestra proviene o no de una población de distribución normal (D'Agostino et al., 1990).

La hipótesis nula para los tests de Shapiro-Wilk y D' Agostino's K-squared es que los datos proceden de una distribución normal. Por lo tanto, el p-value de los tests indica la probabilidad de obtener los valores de la distribución empírica, si estos valores provienen de una distribución normal con media 0 y desviación estándar de 1. Para aceptar o rechazar la hipótesis se toma en cuenta el valor del estadístico del p-value: si este estadístico es menor que determinado valor, por lo general 0.05, se rechaza la normalidad de los datos (Amat Rodrigo, 2021).

El test de Wilcoxon permite comprobar si dos muestras de dos poblaciones provienen de una misma distribución. La hipótesis nula considera que no hay diferencias entre las distribuciones, cuando la probabilidad de que la observación de la población  $x$  supere a la población  $y$  es la misma que la población  $y$  supere a la de  $x$  (Neuhäuser, 2011).

El test de Anderson-Darling es un test de normalidad que compara las funciones de distribución acumulada, tanto de la empírica, como la teórica. Este test tiene la particularidad de dar más peso en el ajuste de las colas de la distribución que otros test (Mamoon & Rahman, 2019). El test se calcula empleando la siguiente expresión, Donde  $F^*(x)$  es la función de distribución acumulada teórica:

$$A^2 = -n - \sum_{i=1}^n (2i - 1) [\ln(F^*(x_i)) + \ln(1 - F^*(X_{n-i+1}))]$$

### 4.3 Índices estandarizados de sequía

La sequía es un fenómeno multiescalar. La escala de tiempo sobre la cual el déficit de los recursos inicia es muy importante a la hora de monitorear las sequías, debido a que la respuesta de diferentes sistemas hidrológicos, agronómicos y ecosistémicos a las anomalías de precipitación y temperatura varían mucho. En periodos cortos de tiempo se pueden evidenciar cambios sobre la humedad del suelo y reducción de la precipitación, y en largos periodos de tiempo cambios en los caudales, volúmenes de embalse y almacenamiento de acuíferos. Por esta razón los índices de sequía están asociados a una escala de tiempo específica para monitorear y administrar diferentes usos de los recursos hídricos (Marcos García & Pulido-Velazquez, 2019; Podestá, 2020; Vicente-Serrano et al., 2010)

A escala espacial también se pueden caracterizar diferentes tipos de sequía. En concreto se reconocen cuatro tipos:

- (i) Sequía meteorológica: representada por una prolongada reducción en la precipitación, incremento de la temperatura y evapotranspiración, y reducción de la humedad. Este tipo de sequías es la causante de los otros tipos de sequías (Podestá, 2020; van Ginkel & Biradar, 2021).



- (ii) Sequía agrícola o edáfica: se refiere a un periodo con una disminución en la humedad del suelo, que incide sobre la disponibilidad de agua para las plantas de forma natural (Mishra & Singh, 2011)
- (iii) Sequía hidrológica: escasez en la disponibilidad de agua superficial y/o subterránea, incluyendo lagos, arroyos y acuíferos. Existe una reducción de la precipitación que incide sobre la escorrentía y que también puede ocasionar que el agua subterránea no tenga recarga (van Ginkel & Biradar, 2021).
- (iv) Sequía socioeconómica: pérdidas económicas derivadas de las sequías meteorológicas, hidrológicas o agrícolas. La reducción en la disponibilidad del agua conlleva impactos socioeconómicos.

En este sentido, se considera que es necesario el uso de índices que permitan capturar adecuadamente las escalas temporales relevantes para detectar impactos negativos sobre los diferentes tipos de sequía. El European Drought Observatory (2017) menciona que los índices de sequía pueden ser calculados en periodos de acumulación entre 1 a 48 meses, mientras que la WMO (world Meteorological Organization) menciona que las escalas más apropiadas para el cálculo del índice de sequía varían entre 1 y 24 meses (Podestá, 2020).

#### **4.3.1 Escala de agregación del cálculo del índice de sequía.**

Recientemente algunos estudios consideran un mes entre actualizaciones de índices como un periodo demasiado extenso y proponen el cálculo del índice a una escala más reducida que puede ser diaria, por pentadas o semanal. Por lo que al final de cada mes se tendrían 30 valores diarios, 6 valores por pentadas o 4 valores semanales del indicador de sequía (CSIC, 2015; Podestá, 2020). Es clave resaltar que las actualizaciones de los índices estandarizados en escalas cortas se realizan con el objetivo de monitorear casi en tiempo real las variables, y que estos sistemas por lo general están conectados a redes meteorológicas locales que miden la variable en campo e inmediatamente se sube a la base de datos de los registros históricos para calcular el índice.

En este punto es importante evaluar a qué escala de agregación hay que realizar el cálculo de los índices de sequía hidrometeorológica. Se considera que un índice estandarizado a escala diaria proporcionaría un

valor que representa el déficit o exceso hídrico de cada día del mes, cuyos valores contienen mayor variabilidad que a escala semanal o mensual.


Dada la variabilidad del índice a escala diaria, se pueden presentar valores que cambien rápidamente de tendencia: un cambio de un par de valores con exceso hídrico en periodos secos o la situación contraria. Ello podría llegar a generar ruido en la interpretación de los datos, lo que conllevaría a que de igual forma fuese necesario agrupar los valores de la variable o promediar los valores del índice en escalas de tiempo más grandes para observar una tendencia más clara del comportamiento de las sequías. Otra razón importante es la frecuencia de actualización de los datos de entrada. El modelo hidrológico E-HYPE realiza actualizaciones de las predicciones de variables hidrometeorológicas a inicio de mes (al igual que el ECMEF-SEAS5) para un periodo de 215 días, por lo que se obtendrían datos diarios que se actualizarían cada mes. Calcular los indicadores a escala diaria o semanal implicaría más esfuerzo computacional y requeriría de más tiempo de ejecución. Por ello lo más práctico es calcular los índices de sequía hidrometeorológica a escala mensual, acorde a la planificación y gestión de los recursos hídricos, que emplean escalas mensuales para caracterizar los recursos medios de las variables hidrológicas.

En España, AEMET monitorea la sequía meteorológica, para los periodos de 1, 3, 6, 9, 12 y 24 meses; y los Planes Especiales de Sequía (PES) analizan la sequía meteorológica para 3 y 12 meses. La WMO describe que la sequía agrícola puede ser bien representada por escalas de 2 y 3 meses, mientras que el caudal de un río se describe mejor en escalas de 2 a 6 meses, también se han encontrado asociaciones entre la variación del nivel de la capa freática entre escalas de 6 a 24 meses (Podestá, 2020).

Teniendo en cuenta este contexto, la frecuencia de actualización de los datos y la asociación de las diferentes escalas con los diferentes tipos de sequía, se consideró que los periodos que mejor podrían reflejar los impactos derivados de las sequías son de 1, 3, 6 y 12 meses de agregación.

La Figura 11 muestra el método de cálculo de los índices estandarizados de sequía. En azul se presentan los datos de lluvia, que son necesarios para calcular el índice, y en naranja se representa cuando el valor del índice está disponible. En el caso del índice estandarizado de 1 mes solo

se necesita la agrupación de los valores al final del mismo mes para estimar el índice; para los demás periodos se necesita la agrupación de la variable al final de 3, 6 o 12 meses.



**Figura 11 tiempos de agrupación de índices de sequía**

Fuente: Modificado de (Podestá, 2020)

De acuerdo con el procedimiento metodológico empleado para el cálculo de los índices de sequía, estos acumulan los valores de la variable para el final de cada mes natural, de manera que el periodo de acumulación constituye la escala de agregación del índice (Podestá, 2020).

#### 4.3.2 Índice estandarizado de Precipitación SPI

A través de la Declaración Lincoln sobre índices de sequía, la WMO recomendó el índice estandarizado de precipitación (SPI) para su uso generalizado en los países que deseen hacer un seguimiento de la sequía meteorológica. Durante la declaración se mencionó que el SPI no debería sustituir a los índices locales de sequía meteorológica que se utilizan en diferentes regiones, sino que por el contrario debería ser complementario y estar disponible en todo el mundo dada sus ventajas (Hayes et al., 2011)

El SPI es una transformación de las series de precipitación a una función de distribución normal estandarizada (z-distribution). Con esta transformación se busca el percentil asociado a la probabilidad de ocurrencia de un evento de precipitación (Lloyd-Hughes & Saunders, 2002; Vicente-Serrano et al., 2010); es decir, para cualquier valor de acumulación de precipitación la probabilidad de que se haya registrado al menos la cantidad de precipitación observada durante el periodo de tiempo.

Vega-Viviescas & Rodríguez (2018) describen la metodología de cálculo del SPI e indican que, para una serie de precipitación, la variable se debe acumular para las diferentes escalas de tiempo y seleccionar la función de distribución de probabilidad que mejor ajuste a las series acumuladas,

$$P \sim f(p, \theta)$$

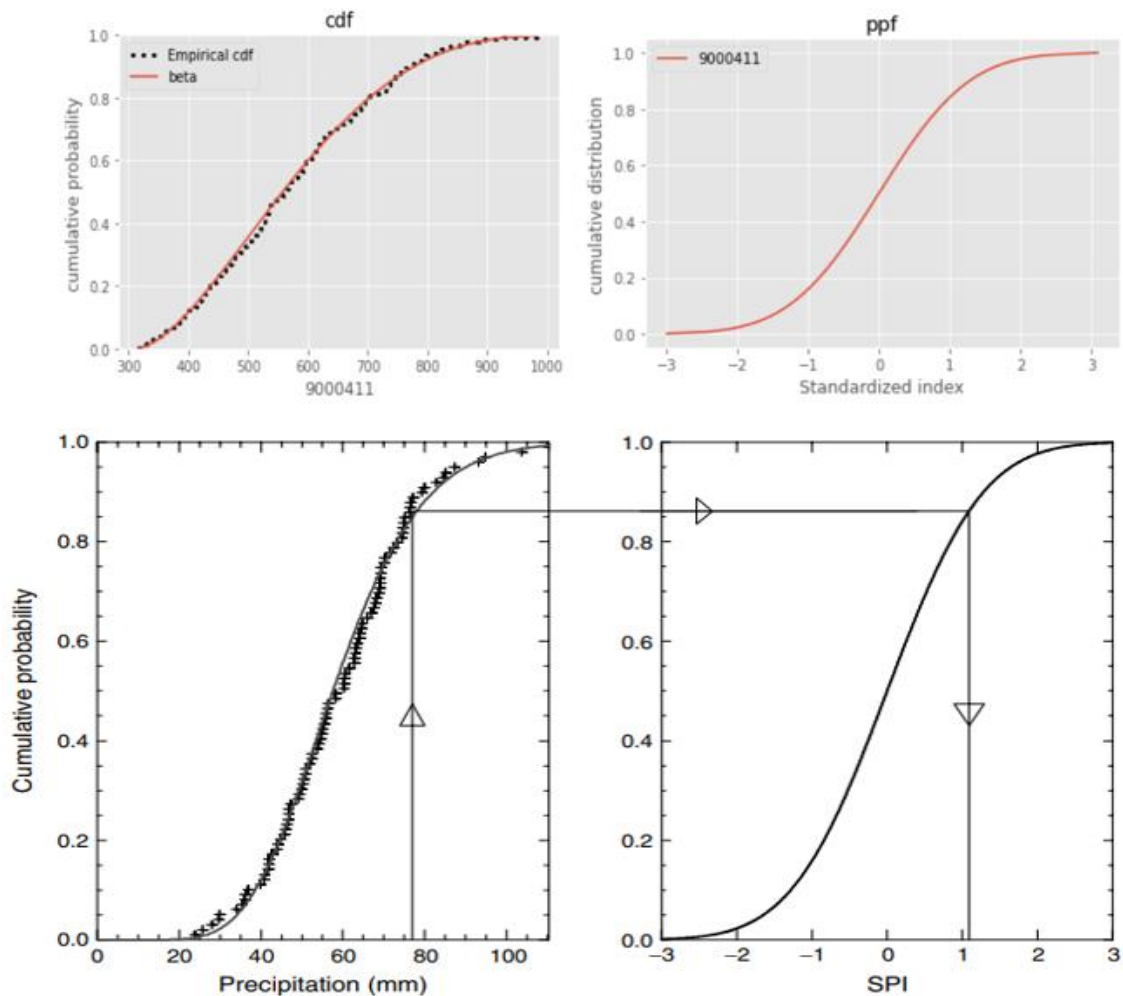
Donde  $P$  representa la serie de precipitación,  $f(p, \theta)$  la función de distribución de probabilidad y  $\theta$  los parámetros de la función.

Una vez ajustada la función de distribución, se calculan los valores acumulados de la función de distribución de probabilidad (función de distribución acumulada-  $F(p)$ ) y ésta se ajusta a una función de distribución normal estándar, cuyo valor para cada registro concreto es el que representa el valor del SPI.

$$F(p) = \int_0^p f(p, \theta) dp$$

$$SPI = \Phi^{-1}(F(p))$$

En la Figura 12 se observa en la parte superior el resultado de una de las gráficas obtenidas en el análisis para una de las subcuencas, comparada con un gráfico de ejemplo de la literatura (parte inferior). En la gráfica de función de distribución acumulada (cdf) se muestra en línea punteada los datos de la variable y en línea continua el ajuste a una función de distribución. En la gráfica función punto percentil (ppf, columna derecha) se muestra la transformación de la probabilidad acumulada en el valor del SPI, a través del ajuste a una función de distribución normal estándar.



**Figura 12 Ejemplo de transformación de una distribución teórica a la distribución normal estándar.**

Fuente: Modificado de (Lloyd-Hughes & Saunders, 2002)

En la metodología hay que considerar, según lo describen Lloyd-Hughes & Saunders (2002) y Vega-Viviescas & Rodríguez (2018), que algunas funciones de distribución no están definidas para valores nulos  $P(x = 0)$ , por tanto se debe realizar un ajuste estadístico con base en que la probabilidad de la precipitación sea nula:

$$SPI = H(p) = q + (1 - q)F(p)$$

$$q = \frac{P(x = 0)}{P(x)}$$

donde  $q$  representa la probabilidad de que el valor de la variable sea cero y  $F(p)$  la función de distribución teórica ajustada.

Para interpretar los valores del SPI, la World Meteorological Organization (2012) menciona que valores positivos representan condiciones húmedas; cuanto más alto es el SPI, más inusualmente húmedo. Valores negativos del SPI representan condiciones secas; cuanto más bajo es el SPI, más inusualmente seco. Los episodios de sequía tienen lugar siempre que el SPI tenga valores negativos continuos y alcancen una intensidad de -1 o inferior (ver Tabla 4). El evento finaliza cuando el SPI alcanza valores positivos.

**Tabla 4 Valores del SPI y su correspondiente probabilidad**

SPI value	Category	Probability of event %
>2	Extremely wet	2.3
1.5 to 1.99	Severely wet	4.4
1.0 to 1.49	Moderately wet	9.2
0 to 0.99	Mildly wet	34.1
0 to -0.99	Mild drought	34.1
-1.0 to -1.49	Moderate drought	9.2
-1.5 to -1.99	Severe drought	4.4
<2	Extreme drought	2.3

Fuente: (Lloyd-Hughes & Saunders, 2002)

Entre las ventajas del uso del SPI se encuentra su simplicidad, y en climas húmedos la precipitación es la variable principal que determina el inicio, la duración, intensidad y fin de la sequía. Además, sus datos pueden compararse entre diferentes regiones climáticas (Vicente-Serrano et al., 2010). Sin embargo, para las regiones con precipitaciones muy estacionales (en particular, cuando las precipitaciones son muy escasas o nulas durante varios meses), el SPI puede que no represente adecuadamente las sequías.

#### **4.3.3 Índice estandarizado de Precipitación-Evapotranspiración (SPEI) -**

El índice estandarizado de Precipitación-evapotranspiración (SPEI) usa la diferencia de precipitación y evapotranspiración de referencia como medida del excedente o déficit de agua de la relación suelo-atmosfera. En términos de sequías representa un déficit en la atmosfera o en el suelo (Vicente-Serrano et al., 2010).

El SPEI se desarrolló como alternativa al SPI en regiones donde la temperatura tiene un efecto mayor sobre la demanda de agua. Este índice tiene la sensibilidad para incluir la evapotranspiración causada por fluctuaciones de variables climáticas diferentes a la precipitación, por lo tanto, proporciona una medida más real de la severidad de la sequía (Beguería et al., 2014).

Una de las dificultades de la metodología de cálculo que supone este índice es la estimación de la evapotranspiración de referencia, la cual puede ser determinada a través de diferentes metodologías (Thorntwaite, Penman-Monteith, Hargreaves). A efectos de este trabajo, la evapotranspiración de referencia es una de las variables extraídas del modelo hidrológico E-HYPE, la cual emplea una metodología propia basada en la temperatura. Vicente-Serrano et al. (2010) indica que una vez obtenida la evapotranspiración de referencia (PET), se calcula la diferencia entre la precipitación  $P$  y la PET, para cada mes de la serie, de la siguiente manera:

$$D_i = P_i - PET_i$$

$D_i$  proporciona una medida sencilla del excedente o déficit de agua para el mes analizado en milímetros. Esta nueva serie se puede agregar a diferentes escalas de tiempo, siguiendo el mismo procedimiento que para el SPI.

La diferencia  $D_{i,j}^k$  en un mes  $j$  y un año  $i$  determinados depende de la escala temporal  $k$  elegida (Vicente-Serrano et al., 2010). La diferencia acumulada para un mes en un año  $i$  con una escala temporal de 12 meses se calcula mediante:

$$X_{i,j}^k = \sum_{l=13-k+j}^{12} D_{i-1} + \sum_{l=1}^i D_i \text{ if } j < k$$

$$X_{i,j}^k = \sum_{l=j-k+1}^j D_i \text{ if } j \geq k$$

Este índice, dada su naturaleza donde la serie puede tomar valores positivos y negativos, no necesita realizar el ajuste cuando la serie toma valores de cero. El sistema de clasificación del índice es el mismo que emplea el SPI.

#### 4.3.4 Índice estandarizado de humedad del suelo (SSMI)

El índice estandarizado de humedad del suelo SSMI se basa en el concepto de porcentaje de precipitación normal y en el índice de Palmer empleando para agricultura, pero su construcción estadística está basada en el SPI (Xu et al., 2018).

El SSMI se basa únicamente en el contenido de humedad del suelo, y se calcula ajustando una función de distribución no paramétrica a las observaciones de humedad del suelo y luego transformándola en una distribución normal con una media de cero y una desviación estándar de uno. Los valores normalizados que dan negativos indican condiciones de suelo seco, mientras que los valores positivos indican condiciones de suelo húmedo (Carrão et al., 2016). El SSMI utiliza la estandarización de la variable para explicar cuanto se desvía el valor de su media y, por lo tanto, identifica las sequías como valores atípicos estadísticos en la serie temporal (Xu et al., 2018).

Este índice de sequía también emplea el mismo sistema de clasificación del SPI, pero su interpretación está dirigida a evaluar de manera cuantitativa y objetiva el rendimiento de los cultivos en un marco operativo. Carrão et al. (2016) mencionan que el indicador se creó para monitorear las condiciones de humedad del suelo para servicios como el Sistema Mundial de Información y Alerta (SMIA) de la FAO y el Sistema de Vigilancia de los Recursos Agrícolas (MARS) y del Sistema de Predicción de Rendimiento de Cultivos (MCYFS) de la Comisión Europea (CE). Estos sistemas de predicción se centran en los niveles continental y regionales respectivamente, y requieren indicadores fiables y casi en tiempo real para la evaluación de la productividad de los cultivos.

#### 4.3.5 Índice estandarizado de caudal (SRI)

El índice de escorrentía estandarizado (SRI) emplea la misma metodología de cálculo que el SPI, pero la estandarización y normalización de la variable la realiza sobre el caudal. Para largos periodos de acumulación, Shukla & Wood (2008) mencionan que los resultados entre los dos índices son similares. Sin embargo, el SRI incorpora procesos hidrológicos que permiten diferenciar el comportamiento de las variables meteorológicas y el desfase en el comportamiento de la escorrentía en cortos periodos de tiempo. Por tanto, en escalas de tiempo



mensuales el SRI es un complemento importante del SPI para representar aspectos hidrológicos de la sequía.

Shukla & Wood (2008) aplicaron el concepto empleado por McKee et al. (1993) para el SPI, al definir al SRI como la desviación normal estándar unitaria asociada al percentil de la escorrentía hidrológica acumulada durante un periodo de agregación. El índice puede ser calculado para diferentes periodos, siendo los más habituales 1, 3, 6 y 12 meses; y diferentes agregaciones espaciales en función de la resolución de los datos. Para nuestro caso de estudio, la variable hidrológica representa el caudal de salida de cada subcuenca.

De manera general, Shukla & Wood (2008) han observado que la diferencia entre los dos indicadores se incrementa a medida que decrece el periodo de acumulación. En cortos periodos de acumulación el SRI es menos variable de mes a mes que el SPI, porque existen otros procesos hidrológicos y almacenamientos que aportan a la escorrentía (almacenamientos en el suelo, nieve, conexión río-acuífero). Es así que las anomalías de las variables climatológicas no son tan evidentes en periodos cortos de las variables hidrológicas.

Una de las ventajas del SRI, en términos de predicciones, es que la escorrentía es más fácil de predecir debido a que su predictibilidad no sólo depende de las condiciones climáticas (donde la capacidad de predicción es reducida) sino que también depende de las condiciones hidrológicas iniciales, que en algunas estaciones determinan en gran medida la escorrentía para los modelos calibrados (Shukla & Wood, 2008).

#### **4.4 Evaluación de la capacidad de predicción**

La capacidad de predicción de las variables (hindcasts) de E-HYPE, y de los índices de sequía derivados de estas variables, se evaluaron a través de dos indicadores: el MAE (mean absolute error) y CRPS (Continuous Ranked Probability Score).

El MAE mide la diferencia entre el promedio de las observaciones de los hindcasts, o promedio de los índices de sequía según corresponda (F), y el valor para la misma fecha del modelo E-HYPE (O), a través de la siguiente expresión:

$$MAE_{t,l} = \left| \left( \frac{1}{N} \sum_{i=1}^N F_{t,l,i} \right) - O_{t+l} \right|$$

En donde  $t$  corresponde a la fecha en la que se ejecutó la predicción,  $l$  la fecha de anticipación,  $i$  el número del conjunto de la predicción (ensemble member) y  $N$  número total de conjuntos (ensemble). En cuanto a su interpretación, el MAE es siempre un número positivo cuyo valor aumenta a medida que disminuye la capacidad de predicción.

Para que sea más fácil interpretar la capacidad de predicción de las variables, los resultados del MAE se emplean para calcular el MAESS (mean absolute error skill score). Este indicador cuantifica el error de predicción relativo con respecto a una predicción de referencia, usando la siguiente expresión:

$$MAESS = 1 - \frac{MAE_{F,t,l}}{MAE_{B,t,l}}$$

Donde  $MAE_{F,t,l}$  es el valor de MAE para el hindcasts o índice de sequía, y  $MAE_{B,t,l}$  es el MAE de la predicción usada como referencia, el cual representa una situación sin predicción en la que se usa el promedio histórico para el periodo considerado. El MAESS tiene un rango de variación de  $(-\infty, 1]$ . Los valores negativos indican que el valor del sistema de referencia supera a los hindcasts, lo que indica una mala capacidad de predicción del modelo. Los valores nulos indican un rendimiento idéntico mientras que los valores positivos de MAESS indican que los hindcasts superan el sistema de referencia, es decir que existe una buena capacidad de predicción (hasta un valor de 1 que corresponde a una predicción perfecta).

Por otro lado, el CRPS mide para cada paso de tiempo, la diferencia entre la función de distribución acumulada (cdf) del conjunto de predicciones (ensembles) y las asociadas a una predicción perfecta (Pechlivanidis et al., 2020) empleando la siguiente expresión:

$$CRPS_{t,l} = \int_{-\infty}^{+\infty} [P_{F,t,l}(x) - P_{O,t+l}(x)]^2 dx$$

Donde  $x$  corresponde a la variable predicha,  $P_{F,t,l}(x)$  la función de distribución acumulada del conjunto de predicciones (ensembles) y  $P_{O,t+l}(x)$  la función de distribución acumulada de la predicción perfecta (igual a 0 si  $x < O_i$  e igual 1 en caso contrario).



Al igual que el MAESS, se puede calcular el CRPSS (Continuous Ranked Probability skill score), este indicador también se estandariza dividiendo el  $CRPS_{F,t,l}$  de las variables predichas con por la media mensual del periodo histórico  $CRPS_{B,t,l}$ , a través de la siguiente expresión.

$$CRPSS = 1 - \frac{CRPS_{F,t,l}}{CRPS_{B,t,l}}$$

Mientras que los valores de CRPS oscilan entre cero (0) e infinito ( $\infty$ ) con 0 indicando una predicción perfecta; los valores de CRPSS oscilan entre  $(-\infty, 1]$ , siendo 1 el óptimo. CRPSS permite una clara categorización de sus valores en (muy) buenos/malos rendimientos (Pechlivanidis et al., 2020).

## Capítulo 5. Resultados y discusión

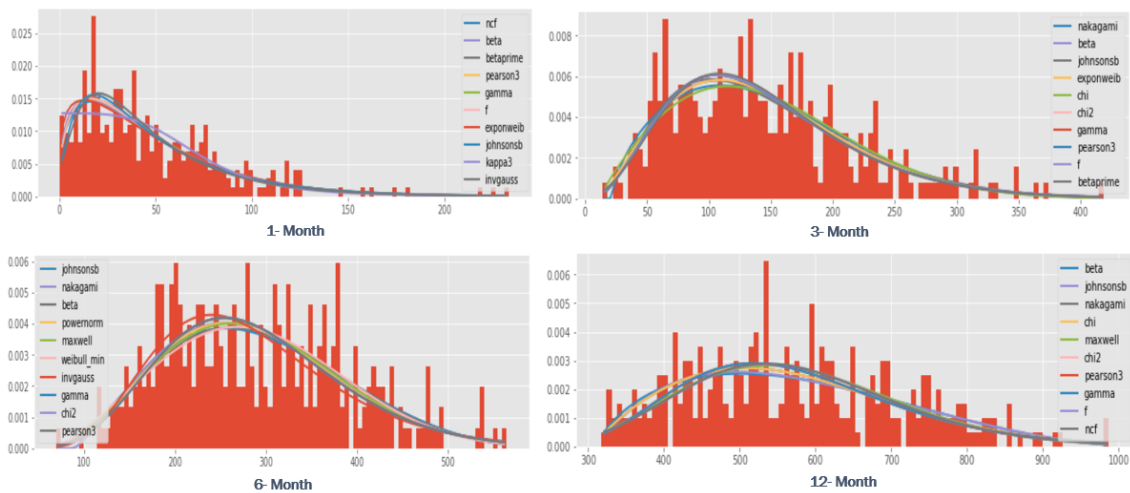
### 5.1 Ajuste de funciones de distribución teóricas a distribuciones empíricas

El análisis del ajuste de las funciones de distribución teóricas se ha dividido en tres partes. Primero se realizó la selección de las funciones de distribución y estimación de parámetros por subcuenca, variable y periodo de agregación. Después se espacializaron las funciones de distribución ajustadas para cada subcuenca, se analizó la correlación espacial y se intentó establecer si existía algún patrón físico o proceso hidrológico que influyera en la selección de las funciones. Finalmente se realizó un análisis del test de normalidad usando el p-value del test D' Agostino's K-squared. A través de este análisis se identificaron las subcuencas que no presentan un comportamiento normal a pesar del ajuste que el código realiza en las colas de la distribución (ver Anexo 1. *Funciones de distribución*).

#### 5.1.1 Precipitación

En la Figura 13 se presentan las series de precipitación para 1, 3, 6 y 12 meses de agregación. Las gráficas permiten observar que, a medida que se avanza con la agregación de la variable, esta tiende a una distribución normal y se pierde el efecto de la estacionalidad sobre la variable. Este comportamiento se da porque en cortos periodos de agregación el efecto de la estacionalidad es mucho mayor y la precipitación presenta un sesgo hacia valores cercanos al cero, que está asociado al tipo de clima característico de la subcuenca; y en algunos casos una disminución de la precipitación en los meses de verano, además de fenómenos de variabilidad climática y los de mayor interés para el estudio la reducción de la precipitación por debajo de lo normal. A medida que se acumula la variable el efecto de los valores extremos (valores de cero) desaparece y los valores empiezan a localizarse hacia la parte central de la distribución.

Esta tendencia de la variable es importante, principalmente en cortos periodos de agregación (1 y 3 meses), porque existen algunas funciones de distribución que no están definidas cuando la variable toma un valor de cero. Por tanto, una vez seleccionada la función que mejor ajusta los datos, se debe validar y ajustar la probabilidad de obtener un valor de cero antes de realizar la estandarización de la serie.



**Figura 13 Ejemplo de distribución de la precipitación para diferentes niveles de agregación temporal**

Fuente: Elaboración propia

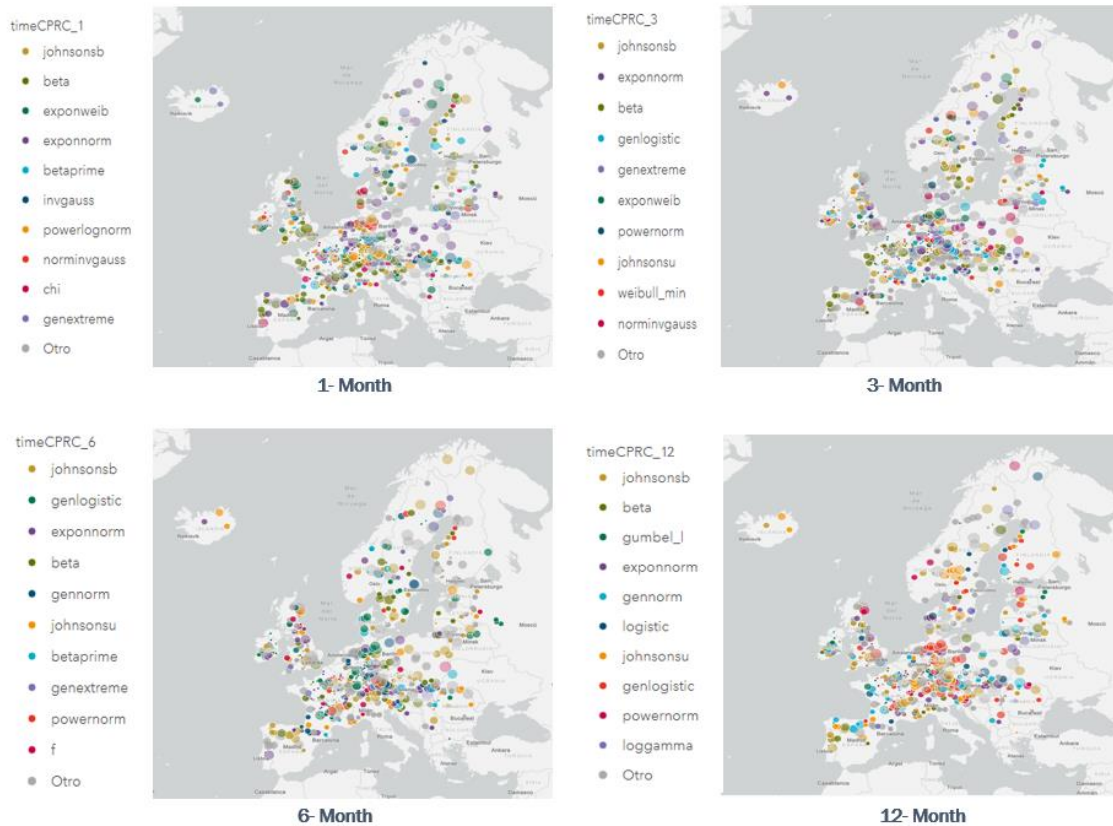
Las funciones seleccionadas para cortos periodos de tiempo deben tener la capacidad de modelar distribuciones fuertemente sesgadas, con una alta densidad de valores asintóticos cerca del límite de cero, (Stagge et al., 2015). En cambio, las funciones seleccionadas para largos periodos de tiempo han de tener la capacidad de modelar distribuciones ligeramente sesgadas y con un comportamiento aproximadamente normal.

A nivel de subcuencas, en la Figura 14 se presenta la espacialización de las funciones ajustadas para los diferentes meses de agregación de la precipitación. En las gráficas no es posible identificar una tendencia espacial clara, ya que no se observa una correlación entre la distancia entre subcuencas y la selección de las funciones de distribución, o características geográficas similares que permitan diferenciar clústeres que empleen las mismas funciones para realizar el ajuste de los parámetros.

Se resalta el hecho que la función de distribución seleccionada por una subcuenca para el primer mes de agregación puede ser la misma o puede cambiar para los siguientes meses de agregación 3, 6 y 12. Independientemente que la función sea la misma, los parámetros de ajuste cambian en función del mes de agregación.

Se observó que para la precipitación, dada su alta variabilidad temporal y espacial, se han empleado entre 20 y 35 funciones de distribución de

las 50 inicialmente probadas. Las funciones más empleadas, teniendo como criterio el número de cuencas que realizan el ajuste con la misma función son: Johnsonsb, exponnorm, beta y genlogistic.



**Figura 14 selección de las mejores funciones de distribución del SPI**

Fuente: Elaboración propia

A nivel de clúster esta selección puede tener modificaciones respecto a los resultados a nivel de subcuenca. Considerando el mismo criterio (número de subcuencas que emplean la misma función de distribución) se presentan los siguientes resultados a nivel de clúster:

- (i) Para la escala de agregación 1 mes: Los clústeres 1, 2, 3, 6 y 7 tienen un mayor número de subcuencas que realizan el ajuste empleando función beta; en cambio para los clústeres 4, 5, 8, 9 y 11 la función que predomina es la Johnsonsb.
- (ii) Para la escala de agregación 3 meses: los clústeres 2 y 6 mantienen la función beta con la mayor frecuencia en la selección. Los clústeres 3, 5 y 9 cambian a la función exponnorm y los clústeres 1, 4, 7, 8 y 11 a la función Johnsonsb.

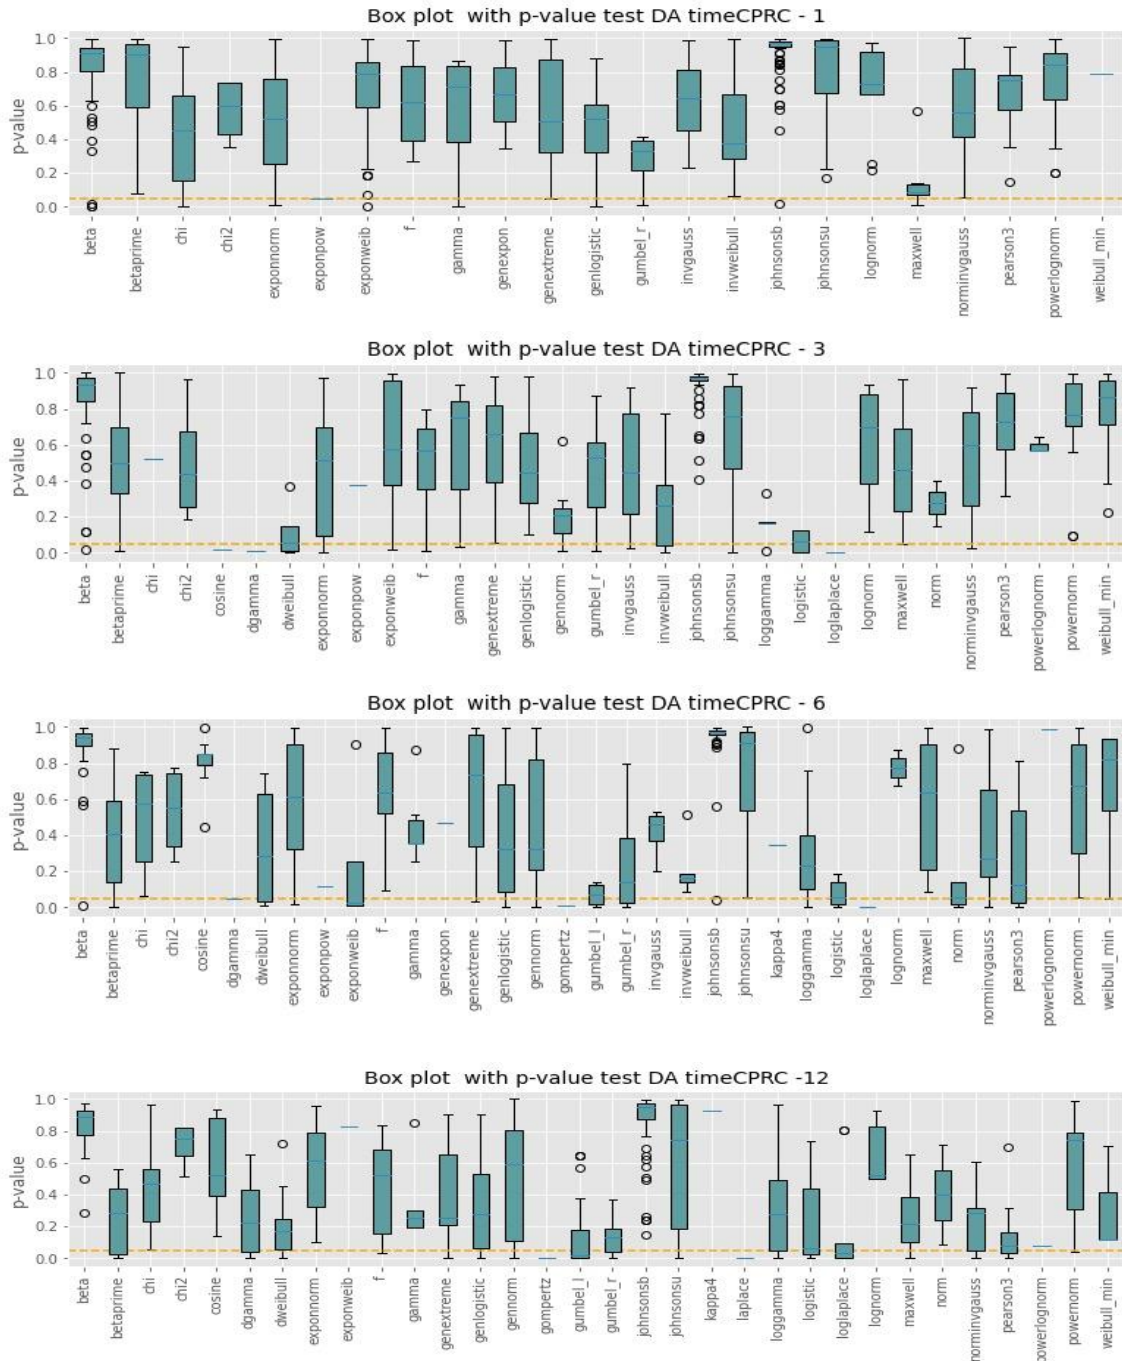
- (iii) A los 6 meses de agregación las funciones de distribución candidatas se amplían: las subcuencas del clúster 1 emplean mayormente las funciones johnsonsb y loggamma; el clúster 2 johnsonsb y dweibull; Los clústeres 3 y 4 seleccionan la función johnsonsb; mientras que los clústeres 5,8 y 11 cambian a la función genlogistic. El clúster 6 emplea la función norminvgauss; clúster 7 cambia a exponnorm; y por último el clúster 9 cambia a la función betaprime.
- (iv) A los 12 meses de agregación, donde se ha reducido el efecto de la estacionalidad, la función johnsonsu y johnsonsb son seleccionadas como las mejores en los clústeres 1, 2, 3, 6, 7 mientras que en los clústeres 4, 5, 8, 9 y 11 predominan las funciones genlogistic y beta.

La Figura 15 presenta la distribución de los p-values del test D' Agostino's K-square (test DA). Para valores del p-value que superan el nivel de significancia (0.05), se puede decir con un nivel de confianza del 95%, que la serie es normal. Cada caja-bigote incluye el p-value obtenido en el test para cada una de las subcuencas que seleccionaron determinada función como la mejor para el periodo de agregación dado. La línea punteada representa el nivel de significancia. Las distribuciones que están por encima de este umbral son aquellas donde el ajuste da como resultado una serie normalizada. Por el contrario, las funciones que están por debajo de este umbral, representan subcuencas en donde la variable no se normalizo.

Se observa en las gráficas que suelen predominar los valores altos del p-value (ejemplo función beta y Johnsonsb), lo que representa, que para la mayoría de subcuencas en donde se seleccionaron estas funciones, la serie es normal, por lo que el ajuste es adecuado. Sin embargo, para estas mismas funciones se observan algunos valores atípicos por debajo del umbral que representan subcuencas en donde se rechazó la normalidad de los datos. No obstante, la mayoría de las subcuencas presenta ajustes satisfactorios.

Por otro lado, también se presentan algunas cajas-bigote con una alta variabilidad en el p-value, en donde una parte de la caja o la parte inferior del rango intercuartílico se encuentra por debajo del umbral, lo que representa que para una parte de las subcuencas se rechaza la

normalidad de los datos. Los resultados indican que, en promedio, alrededor del 4.7% de las subcuencas no presentan una adecuada normalización de las series.



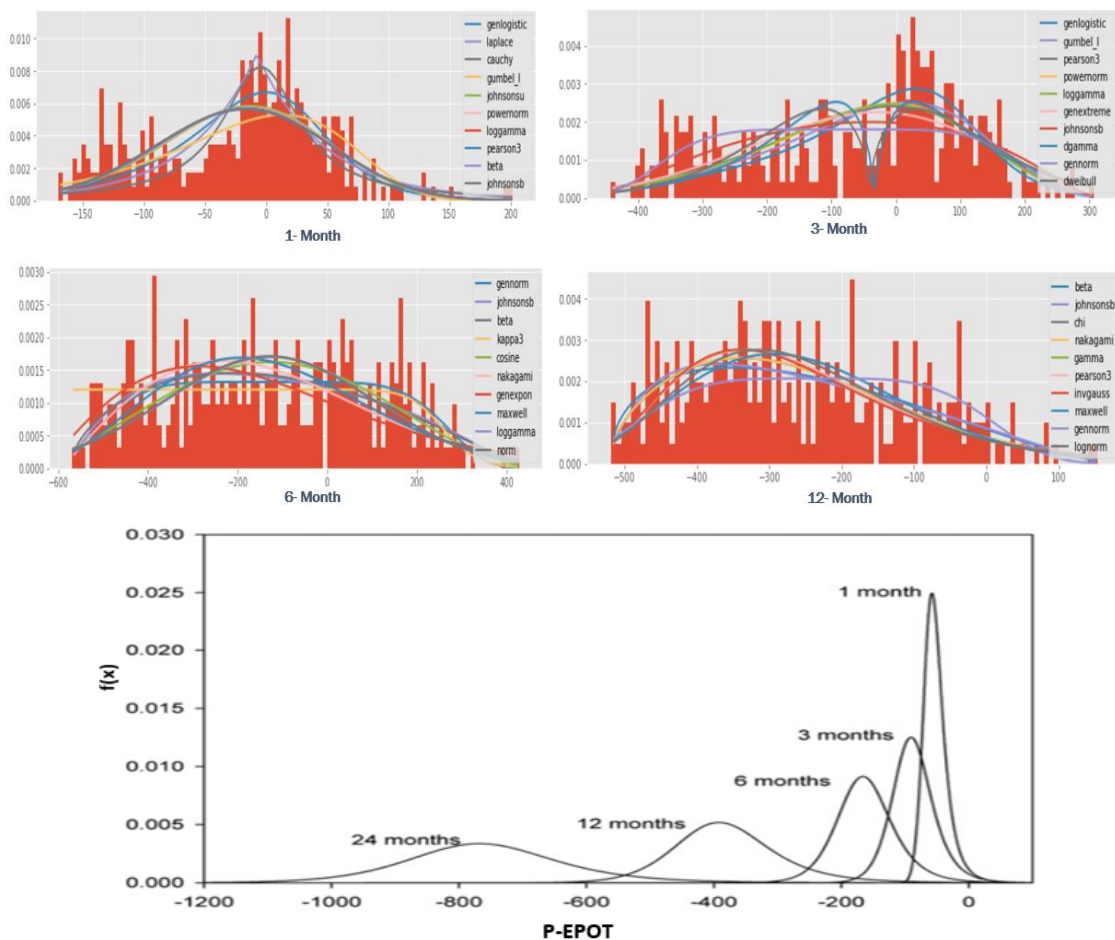
**Figura 15 p-value del test DA obtenidos para SPI**

Fuente: Elaboración propia



### 5.1.2 Precipitación – Evapotranspiración Potencial.

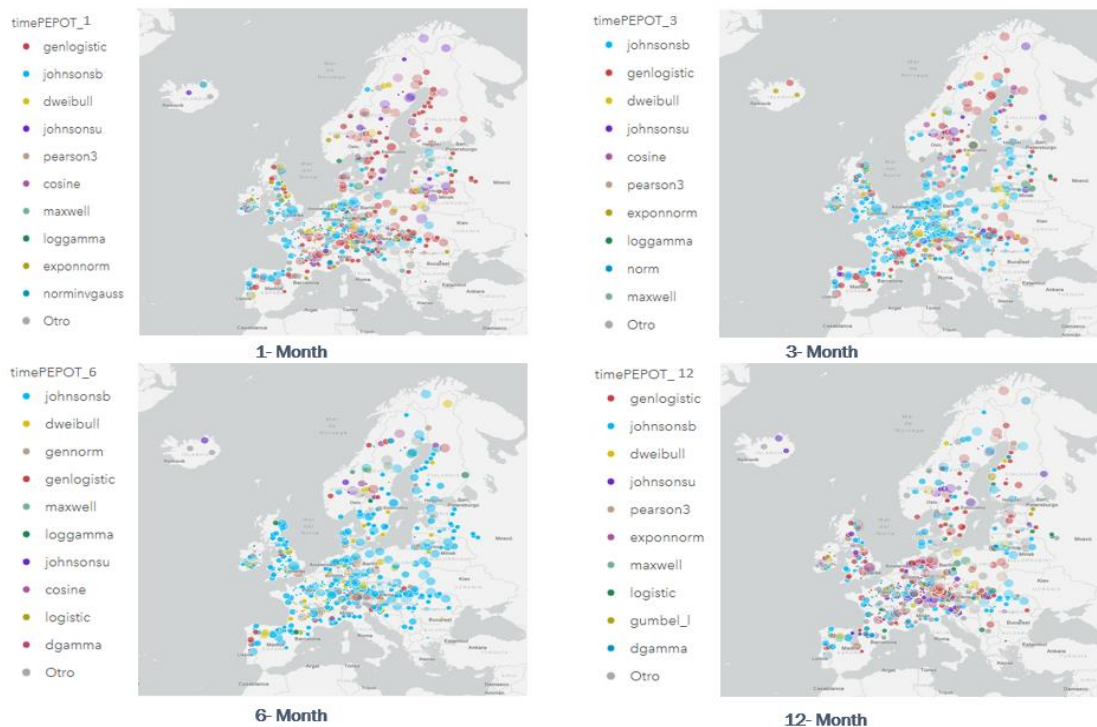
En la Figura 16, se observa que para periodos de agregación cortos, la variable tiene comportamiento bimodal, sesgado hacia la izquierda con un pico en los valores negativos y otro en valores próximos a ceros. Para periodos largos el comportamiento de la serie cambia a un régimen unimodal, con mayor peso hacia las colas de la distribución, que hace que la serie se extienda y el sesgo se desplaza ligeramente a la derecha. El comportamiento de la variable se puede observar de forma más clara a través de la figura presentada por Vicente-Serrano et al. (2010). En el primer mes de agregación, se presenta una alta frecuencia de la variable P-EPOT cercanas a valores de cero, a medida que se avanza con los niveles de agregación, aumenta la variabilidad en la diferencia P-EPOT hacia los valores negativos pero disminuye su frecuencia.



**Figura 16 Ejemplo de distribución de la P-PEPOT para diferentes niveles de agregación temporal**

Fuente: Modificado de (Vicente-Serrano et al., 2010).

Esta característica de la serie conlleva a que la estimación de los parámetros se tenga que realizar de manera mensual. Además, algunas distribuciones de dos parámetros, realizan el ajuste para series definidas entre cero y el infinito positivo ( $0 < x < \infty$ ), lo que reduce en gran medida la selección de la función; mientras que en funciones de distribución con tres parámetros o más la serie se puede ajustar con mayor facilidad a valores negativos (Vicente-Serrano et al., 2010). En comparación con las series anteriores, en estas series si se observa un patrón espacial en la selección de las funciones de distribución. Para las diferentes escalas de agregación las funciones de distribución más seleccionadas son genlogistic y la Johnson SB, ver Figura 17.



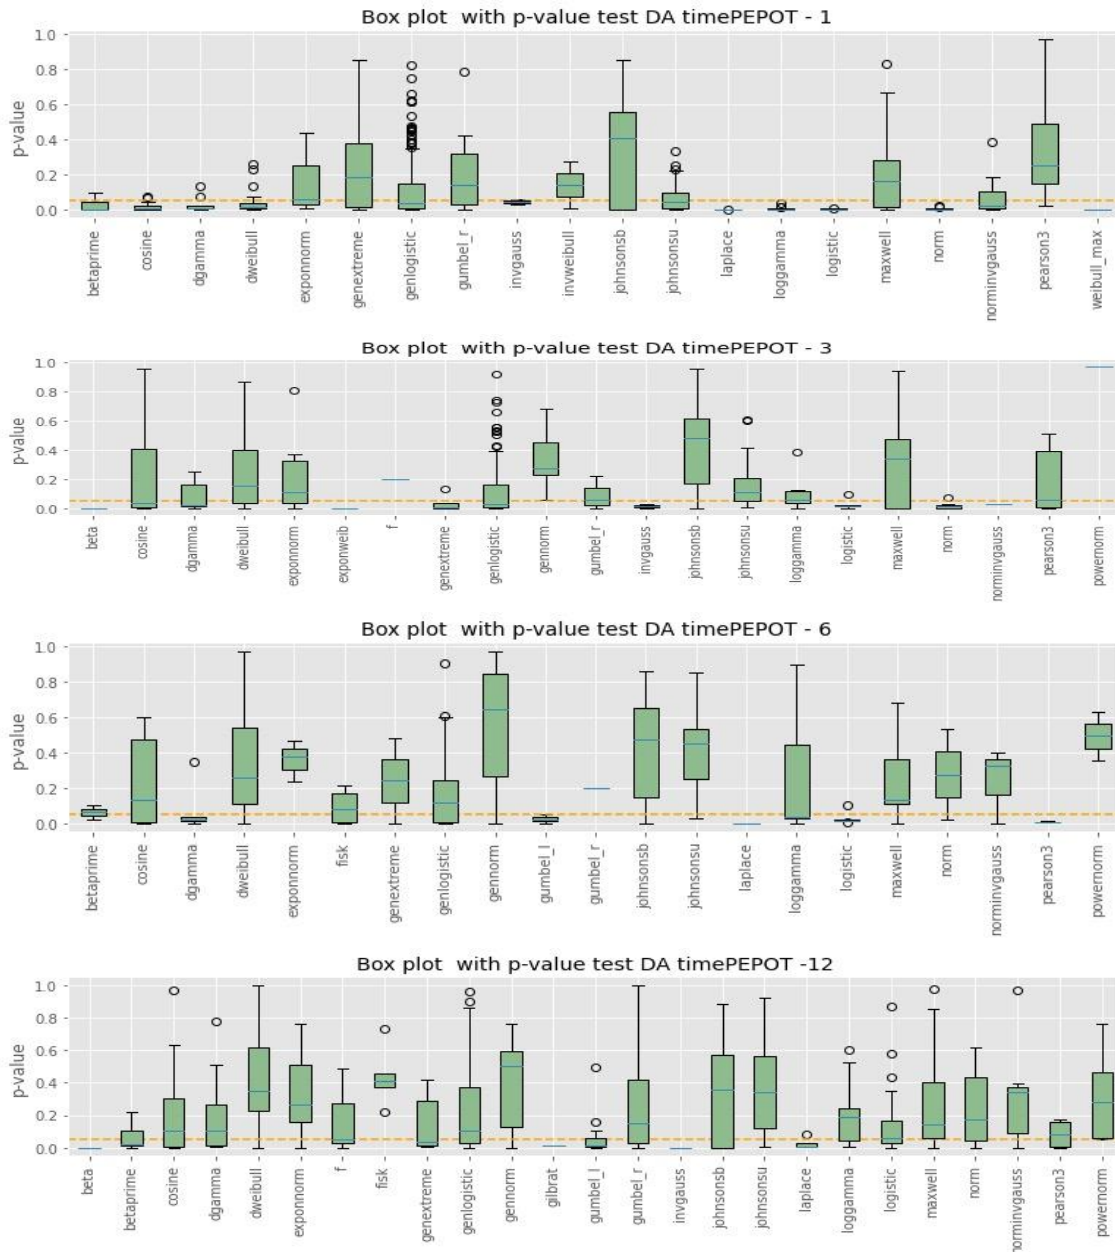
**Figura 17 selección de las mejores funciones de distribución para el SPEI**

Fuente: Elaboración propia

La distribución Johnson SB es una transformación de la distribución normal clásica que emplea 4 parámetros para realizar el ajuste, lo que le permite ser bastante flexible y ajustarse a la forma de diferentes distribuciones, de ahí que sea la más seleccionada.

En relación con los p-values de las series SPEI, en la Figura 18 se observa que todas las funciones empleadas tienen cierto número de subcuencas

en donde se rechaza la normalidad de la serie. En el caso particular de la función genlogistic, a medida que se avanza con los meses de agregación se mejora en la normalización de los datos, desplazando la media de las cajas por encima del umbral del nivel de significancia, debido a que medida que se avanza con el nivel de agregación se reduce el efecto de la estacionalidad sobre la variable.



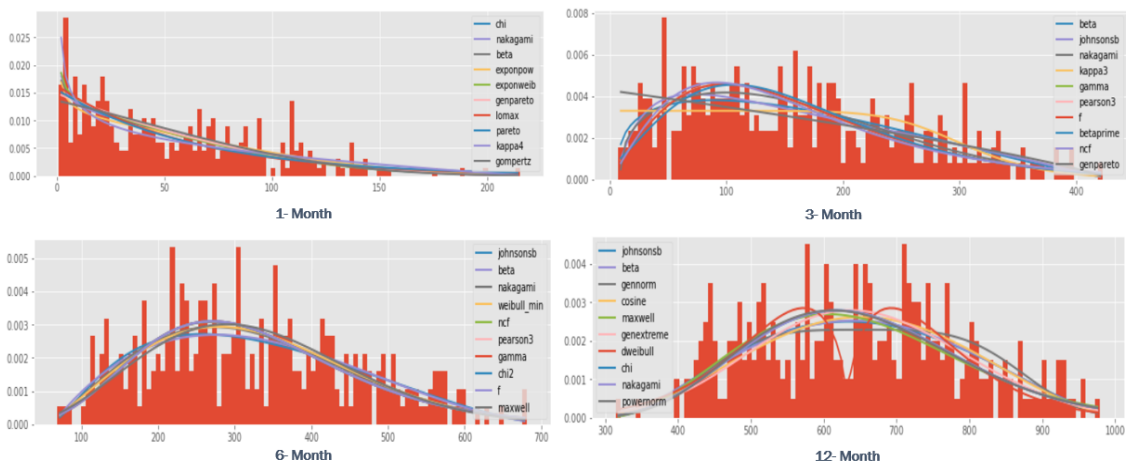
**Figura 18 p-value del test DA obtenidos para SPEI**

Fuente: Elaboración propia

Para el caso de la distribución Johnsonsb, se presenta una alta variabilidad en la caja. La mayoría de subcuencas que seleccionaron esta función tienen como resultado una serie normal. Sin embargo, también existe una proporción de subcuencas con series no normales. Los resultados indican que, en promedio, alrededor del 15% de las subcuencas no presentan una adecuada normalización de las series.

### 5.1.3 Humedad del suelo

Las series de humedad del suelo, tiene como características una distribución unimodal con un fuerte sesgo hacia la derecha, que se mantiene hasta los 3 meses de agregación de la variable y que luego va desplazando el pico de la distribución hacia la parte central (Figura 19).

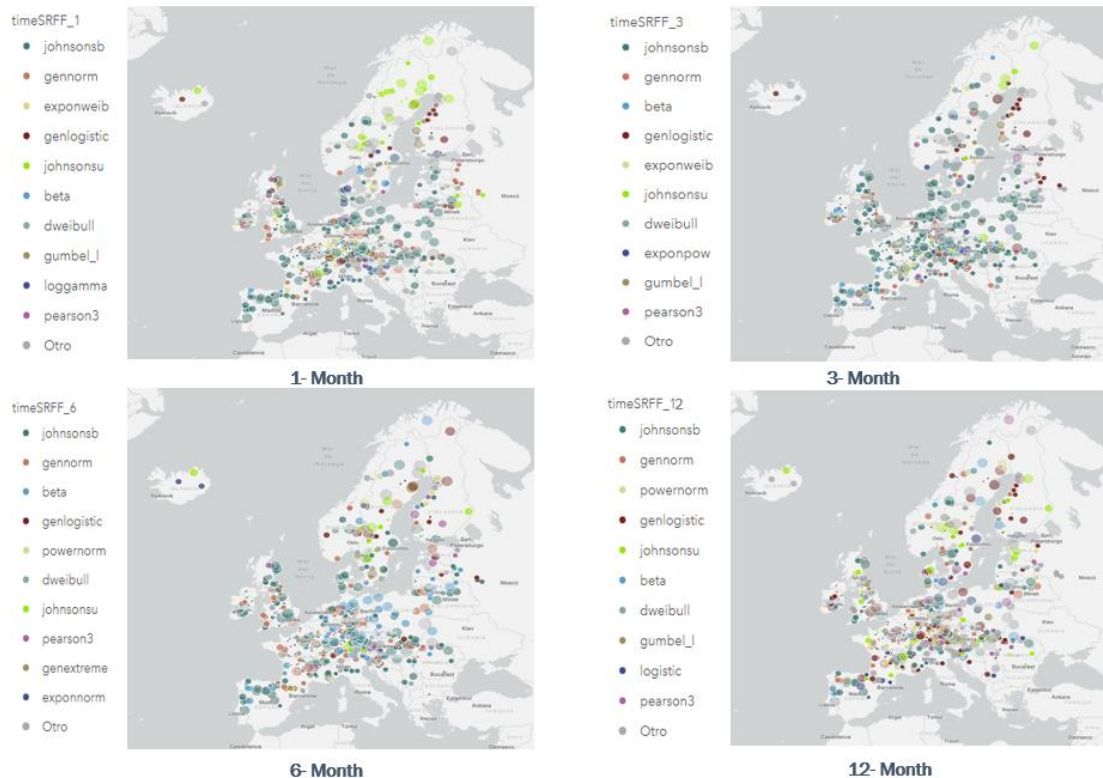


**Figura 19 Ejemplo de distribución de la humedad del suelo para diferentes niveles de agregación temporal**

Fuente: Elaboración propia

En el primer mes de agregación se observa un comportamiento asintótico hacia los valores de cero, que se van perdiendo en las siguientes escalas de agregación. También es posible identificar que para algunas de las funciones de distribución teóricas no es tan fácil reproducir la tendencia de los datos.

En cuanto a la distribución espacial de las series de humedad del suelo, a lo largo de Europa central, las funciones más empleadas son Johnsonsb, gennorm y Beta; mientras que en el norte de Europa (Noruega y Finlandia) predomina la función Johnsonsu y genlogistic (Figura 20).



**Figura 20 selección de las mejores funciones de distribución para el SSMI**

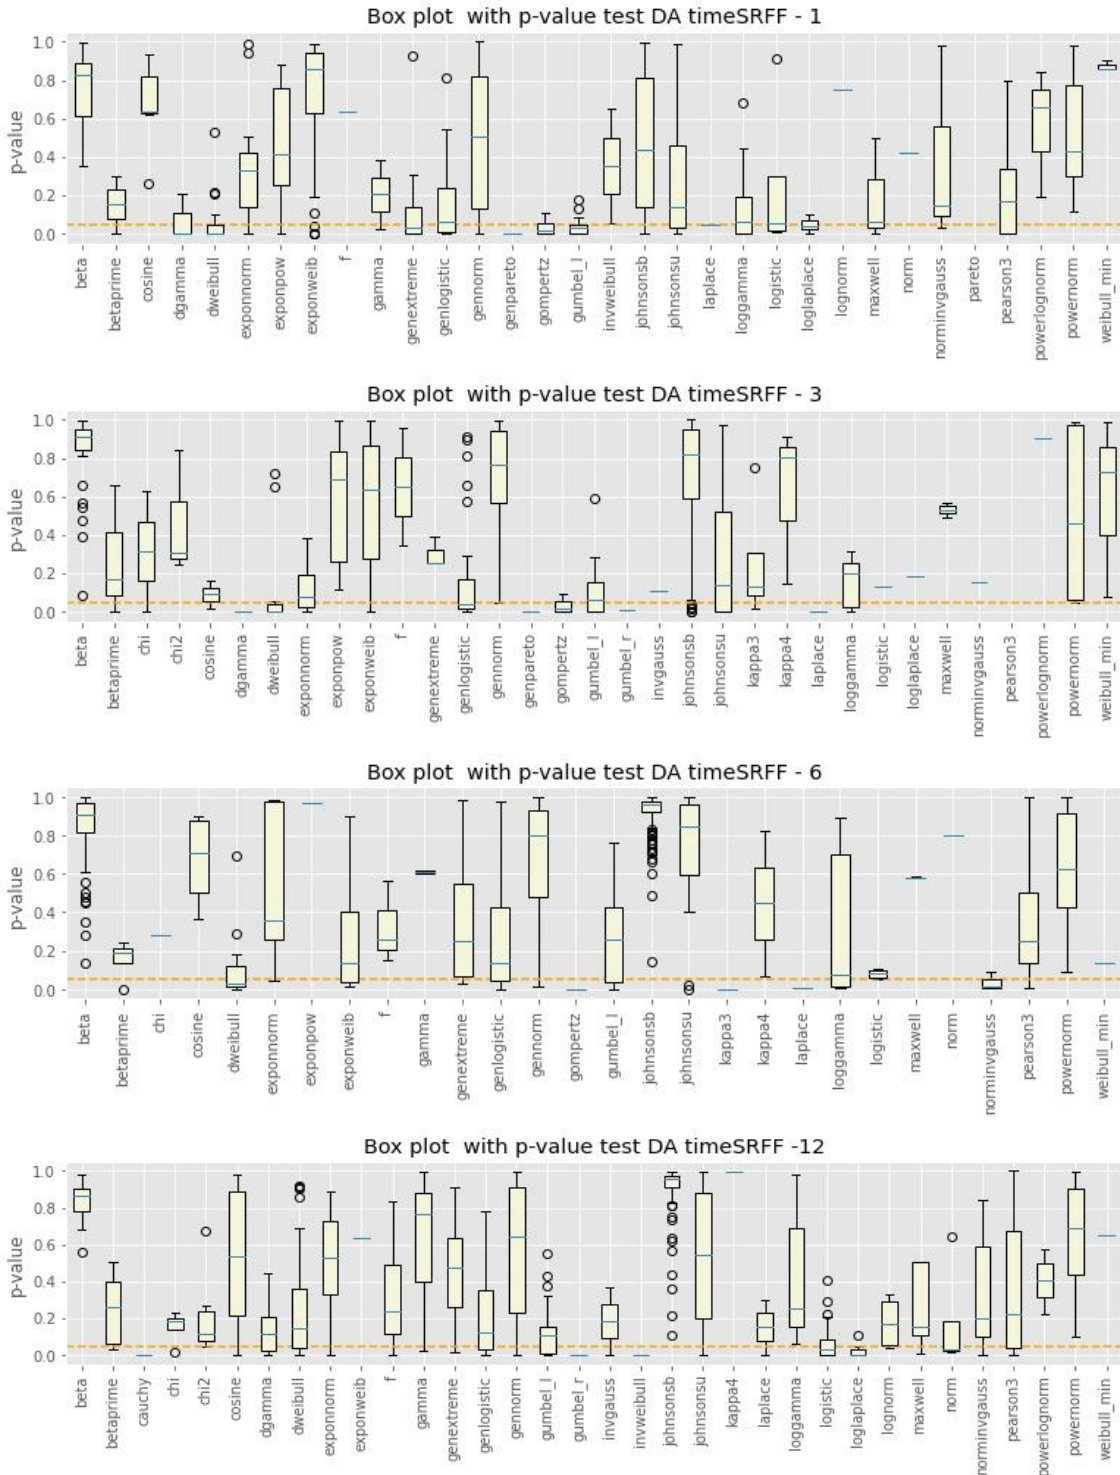
Fuente: Elaboración propia

A nivel de clúster, para la escala de agregación 1 mes, la función más seleccionada para el ajuste de las series es la Johnsonsb, con excepción del clúster 2, en donde se seleccionó una función de la misma familia, la Johnsonsu. Para el nivel de agregación 3 predomina la función Johnsonsb en todos los clústeres.

En la escala de agregación de 6 meses solo se observa respecto a 3 meses un cambio en la selección del clúster 2, donde la función con mayor recurrencia es la genlogistic. Finalmente, para los 12 meses de agregación, la función dweibull es la que más subcuencas agrupa en el clúster 1, mientras que la función genlogistic es la más frecuente en los clústeres 2, 5 y 8; para el resto de los clústeres domina la función Johnsonsb.

En la Figura 21 es posible identificar que las funciones con mayor frecuencia en la selección son las que presentan mayor variabilidad en las cajas, y que para algunos meses de agregación algunas subcuencas se encuentran por debajo del umbral de normalidad. Los resultados

indicando que, en promedio, alrededor del 7.79% de las subcuencas no presentan una adecuada normalización de las series.



**Figura 21 p-value del test DA obtenidos para SSMI**

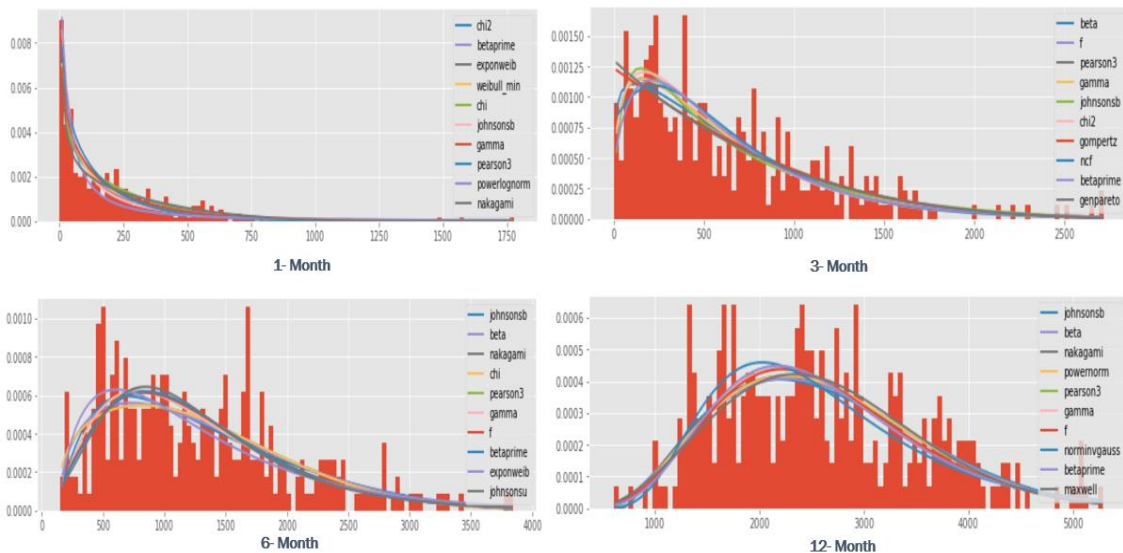
Fuente: Elaboración propia

#### 5.1.4 Caudal

La variabilidad en el caudal a nivel de subcuenca puede estar dominado por diferentes procesos hidrológicos. Hay cuencas con caudales muy dependientes de la precipitación, que es la entrada más importante de agua en el sistema, de ahí que para algunas subcuencas exista una gran cantidad de valores de cero, principalmente en verano (Figura 22).

Por otro lado, en otros tipos de sistemas el caudal puede estar dominado por grandes masas de agua, como humedales, lagos o acuíferos, que regulan el caudal a lo largo del año. También existen sistemas en donde la fusión de nieve juega un papel importante en la regulación del caudal en los meses de primavera; y sistemas hídricos que han sido alterados para la agricultura y la producción hidroeléctrica, por lo que su comportamiento en algunos casos puede llegar a invertirse (mayor caudal en los meses de verano, donde se hay un mayor consumo de agua).

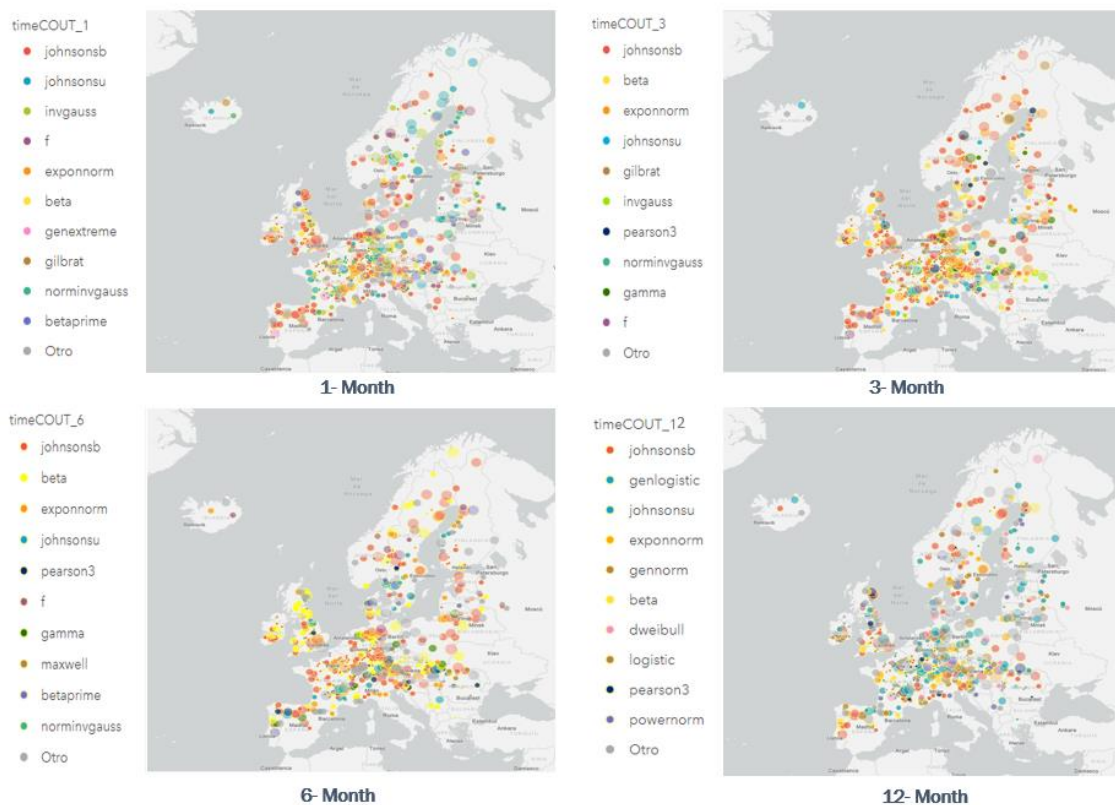
Como se muestra en la Figura 22, el caudal es posiblemente la variable con mayor sesgo entre todas las analizadas. Este sesgo hacia la derecha se mantiene, aunque con menor concentración de valores, hasta los 12 meses de agregación.



**Figura 22 Ejemplo de distribución de la caudal para diferentes niveles de agregación temporal**

Fuente: Elaboración propia

La estandarización y normalización de las series de caudales para las 617 subcuencas empleó entre 28 y 34 funciones de distribución de las 50 iniciales. Al igual que en la precipitación, no se alcanza a diferenciar ninguna tendencia espacial en la selección de las funciones, pero si es claro también para el caudal la función Johnsonsb es la más empleada en el ajuste de las series; seguida de las funciones Inverse Gaussian (invgauss) y beta (Figura 23).




**Figura 23 selección de las mejores funciones de distribución para el SRI**

Fuente: Elaboración propia

Para las series de caudales también se observa un porcentaje de subcuencas en donde se rechaza la normalidad de los datos, correspondiente en promedio a un 11,3% del total. En el caso de las funciones Johnsonsb y beta, a pesar de tener algunos valores atípicos, los valores de p-value son altos, lo que indica series normales de índice estandarizado de escorrentía (SRI). Para la función invgauss, no se presentan valores atípicos pero su rango de variabilidad es mucho mayor, cercano al umbral del nivel de significancia, y para algunos meses de agregación el tercer cuartil de los datos supera el umbral (Figura 24).





**Figura 24 p-value del test DA obtenidos para SRI**

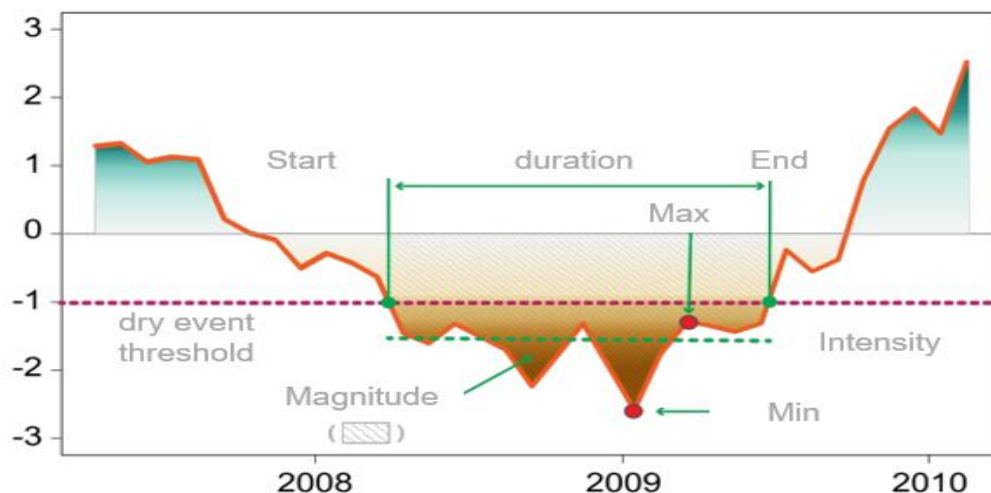
Fuente: Elaboración propia

## 5.2 Análisis histórico de índices estandarizados de sequías

Dos de las características más importantes de los eventos de sequía, son la frecuencia y la duración. Dichas características cambian con los periodos de agregación, en cortos periodos de tiempo las sequías se presentan con mayor frecuencia y menor duración, pero a medida que se avanza en la escala de agregación, el resultado se invierte.

Lo anterior se explica debido a que en periodos de tiempo de 3 meses o menos, cada mes tiene un gran impacto sobre el acumulado de la variable, por lo que es muy fácil que el índice se mueva de periodos secos a periodos húmedos. Sin embargo, en la medida que se van agregando meses en el acumulado, el impacto individual de cada mes es menor en el índice y este responde más lentamente, dando como resultado menos sequías, pero con mayor duración.

La frecuencia está definida como el número de veces que el índice estandarizado está por debajo de determinado umbral, mientras que la duración marca el periodo de inicio y fin de cada evento. Otros de los criterios que se emplean para caracterizar una sequía son la intensidad y la magnitud. La intensidad se define como la cantidad de valores promedio del índice para la duración del evento. También se puede caracterizar la intensidad máxima refiriéndose al máximo valor negativo del índice en el periodo analizado. La magnitud se define como el acumulado del déficit por debajo del umbral durante el periodo de sequía (Figura 25).



**Figura 25 Características de los índices de sequía**

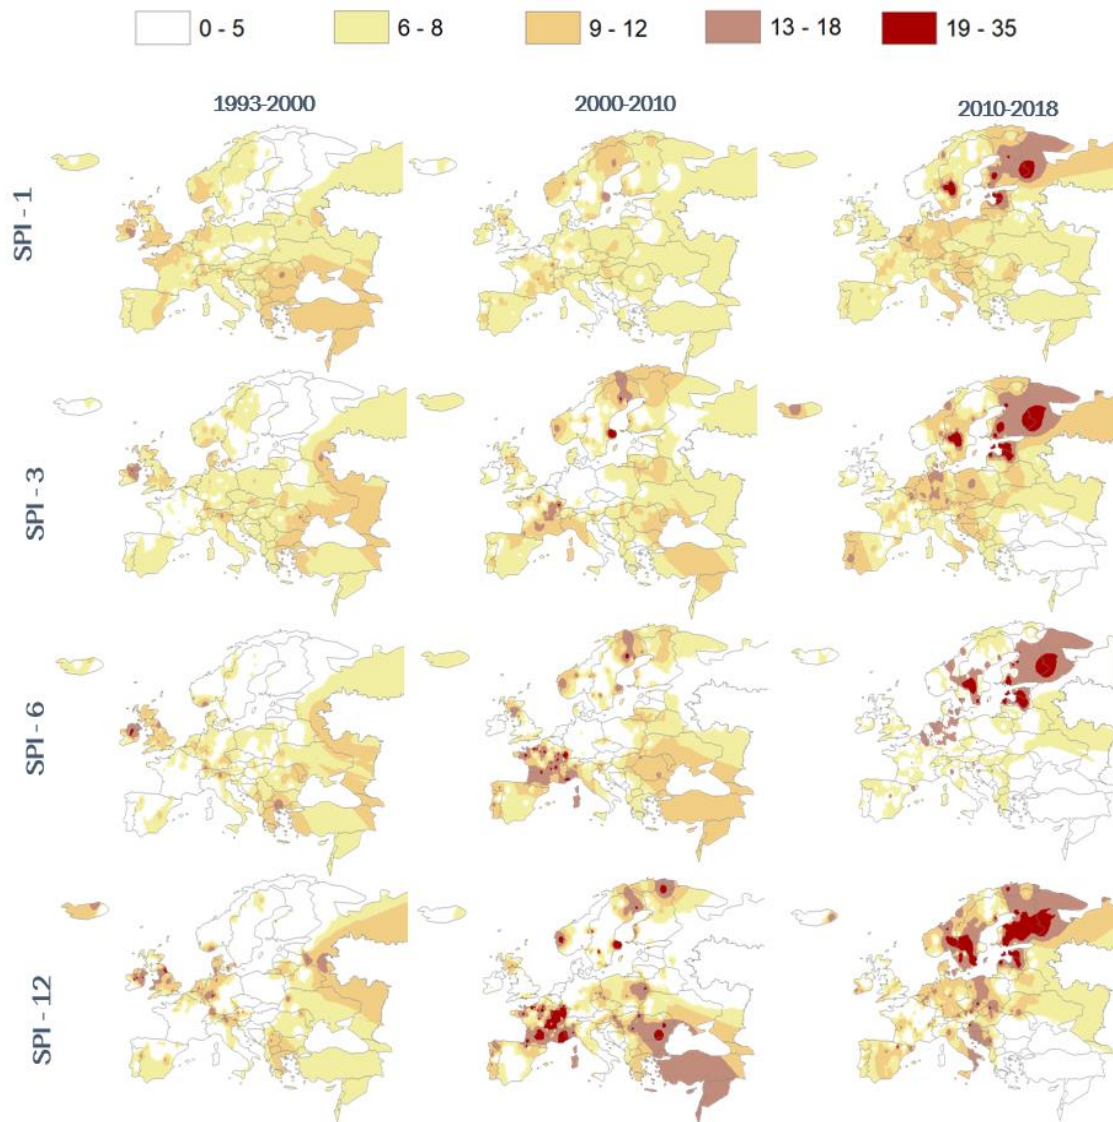
Fuente: Modificado de (Podestá, 2020)

Los resultados de los eventos de sequías caracterizados a través de los 4 índices estandarizados (SPI, SPEI, SSMI y SRI), cada uno de los cuales con 4 niveles de agregación (1, 3, 6 y 12 meses) se presentan a través de dos conjuntos de mapas. Los mapas se dividen en 3 periodos de análisis: 1993-2000, 2000-2010 y 2010-2018. Los primeros mapas muestran la frecuencia de la sequías, medida como el número de meses con valores por debajo de -1.5. El segundo conjunto de mapas representa la intensidad media, es decir los valores promedio por debajo del umbral de -1.5.

### 5.2.1 Índice estandarizado de Precipitación SPI

En la Figura 26 se presentan los resultados de la frecuencia decadal para las 4 escalas de agregación del SPI. La primera tendencia que se observa, y que se mantienen para los demás índices de sequía, es que para la última década el número de sequías es mayor que en décadas anteriores. Esta tendencia coincide con diferentes estudios que afirman que en Europa, en la última década, ha aumentado el número de veranos extremos asociados a eventos de sequía, principalmente en los años 2015, 2018 y 2019 (Ionita & Nagavciuc, 2021).

Para el SPI-1 y SPI-3 la frecuencia en las sequías es mayor hacia el norte de Europa, en donde para la década de 2010-2018 se han presentado entre 19 a 35 eventos en categorías severas o extremas. Los sistemas hídricos ubicados en este sector son subcuencas que responden rápidamente a los cambios en la precipitación (principalmente clúster 2), de ahí que cualquier anomalía se refleje rápidamente en una sequía meteorológica. Para el SPI-6 y el SPI-12, las sequías también se presentan hacia el norte de Europa, pero se empiezan a extender hacia la parte central, llegando hasta España en la última década, con una frecuencia entre 13 y 18 meses. Estos resultados indican que, independiente de la cantidad de lluvia, el SPI muestra que las anomalías sobre la precipitación han sido mayores en climas templados y fríos comparados con regiones donde la precipitación anual acumulada es escasa (clima mediterráneo).



**Figura 26 Frecuencia decadal de las sequías meteorológicas según el índice SPI**

Fuente: Elaboración propia

En la Figura 27 se presenta la intensidad media de los meses en sequía severa o extrema (valores del SPI por debajo de  $-1.5$ ). Se observa en el primer mes de agregación es notorio el efecto individual de las sequías severas y extremas. Por contra, para los 3-meses y 6-meses, se observa que, hacia la parte central y occidental de Europa, las condiciones cambian con duraciones cortas, pero de mayor intensidad, que podrían estar acentuadas precisamente por el tipo de clima y las características geográficas de las cuencas.

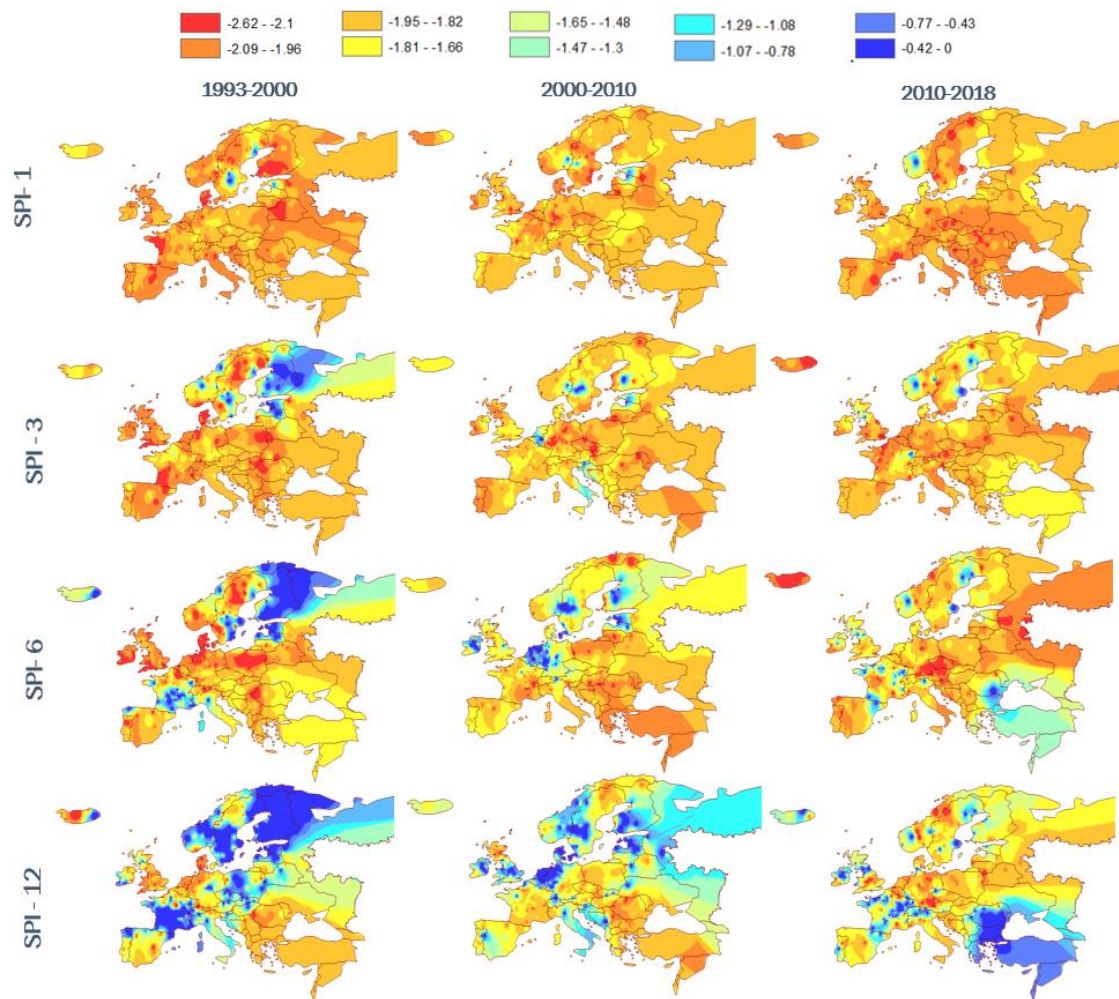


Se observa una ligera tendencia en donde las zonas con mayor relieve en Europa son las que presentan mayor déficit (cordillera cantábrica, los Alpes, Apeninos, Montes Escandinavos). Esto concuerda con estudios (Van Loon & Laaha, 2015; Weingartner et al., 2013) que muestran que la elevación de un sistema hídrico puede llegar a determinar el déficit medio de una sequía: cuanto más alta se localice la subcuenca, mayor será el volumen del déficit. En hidrología ya está demostrada la relación que existe entre la altitud, precipitación y temperatura, y también se conoce que cuanto mayor es la variabilidad de la precipitación, mayor es probabilidad de que existan desviaciones de la normal, por tanto, mayores serán los volúmenes de déficit.

Sin embargo, si se tiene en cuenta que la precipitación tampoco se distribuye de manera homogénea sobre la cuenca, tendremos que las zonas más altas, tienen mayor variabilidad en la precipitación y las zonas bajas de descarga o desembocadura una menor precipitación; por lo que, al tomar el valor promedio de precipitación para la cuenca, este valor está influenciado por los extremos, en donde existe un amplio rango altitudinal, lo que se traduce en mayor déficit.

De acuerdo con Van Loon & Van Lanen (2012) el déficit medio de las sequías en la descarga muestra alta correlación con las variables relacionadas con el clima y las características de la cuenca. Estas variables no son independientes: las precipitaciones suelen aumentar con la altitud, y una alta precipitación media se traduce en una descarga media alta y, por tanto, en un umbral alto. Las fluctuaciones en torno al umbral resultan en altos volúmenes de déficit.

Hacia los 12 meses de agregación la intensidad de las sequías disminuye, ya que se atenúa el efecto de los valores extremos de las sequías cortas. Se observa sequías a largo plazos principalmente en España, Italia y en Europa central hacia la última década.



**Figura 27 Intensidad decadal de las sequías meteorológicas según el índice SPI**

Fuente: Elaboración propia

A escala de clúster, las sequías meteorológicas se presentan con mayor frecuencia en los clústeres 2, 3, 4, 5, 8 y 11, con frecuencias máximas de al menos 30 meses. Estos clústeres, con excepción del clúster 8, tienen la característica que las precipitaciones tienen una fuerte respuesta sobre el caudal, por lo que es uno de los procesos hidrológicos dominantes. En estas subcuencas las anomalías de precipitación en 1 y 3 meses de agregación representan cambios en diferentes procesos, como son la cantidad precipitación que se convierte en escorrentía y la fusión de nieve. Esto concuerda con Van Loon & Laaha (2015), que describen que la propagación de la sequía es diferente en un clima semiárido y en un clima con acumulación de nieve en invierno (clúster 2, 3, 4 y 5), y difiere

entre las cuencas montañosas (clúster 2), las cuencas con muchos lagos y humedales (clúster 3), y las cuencas con pendientes suaves (clúster 11) y cuencas con grandes acuíferos (clúster 8).

Las sequías, según Van Loon & Van Lanen (2012) también se pueden agrupar dependiendo de cómo se propaga en el ciclo hidrológico. La sequía clásica o sequía meteorológica, está causada exclusivamente por una falta prolongada de precipitaciones y puede producirse en cualquier estación, en cualquier cuenca (de respuesta rápida o lenta) y en cualquier región climática siempre que la precipitación caiga en forma de lluvia, es decir que se puede presentar en cualquiera clúster del modelo E-HYPE. Pero existen otro tipo de sequías en particular, que son las sequías de la estación de otoño a invierno, que son generadas por un déficit de lluvias (sequía meteorológica) normalmente en la estación de lluvias que se propaga hasta la estación de invierno. Este tipo de sequías termina cuando la precipitación se considera dentro de lo normal. Sin embargo, no cae en forma de lluvia sino en forma de nieve porque la temperatura ha descendido por debajo de cero. En consecuencia, la humedad del suelo y las aguas subterráneas no alcanzan a recargarse en la estación de lluvias, y en el invierno pueden llegar a manifestar déficit en el volumen de agua hasta el pico de fusión de la nieve de la primavera (Van Loon & Van Lanen, 2012).

Este tipo de sequías son características de los clústeres 2, 3, 4 y 5, ubicados en grandes altitudes, y la duración de las sequías entre la transición lluvia-nieve-deshielo puede llegar a abarcar el año hidrológico. Lo anterior es muy importante desde el punto de vista de la gestión integral del recurso hídrico, ya que son cuencas en donde se regula el caudal y en donde la estacionalidad de la lluvia es muy marcada, como es el caso del clúster 4, por lo que los índices en cortos periodos de tiempo podrían llegar a alertar si la reducción sobre la precipitación podría llegar afectar el nivel de agua necesario para la generación de energía, debido a que en este sector lo más relevante es el volumen de agua que falta en comparación con las condiciones normales (volumen deficitario en invierno).

En 6 y 12 meses se pueden evidenciar cambios en sistemas con mayor inercia, como variaciones importantes en la recarga natural por precipitación y deshielo que reciben las masas de agua subterráneas,

que pueden generar un descenso en el nivel del acuífero y en los ríos que se encuentren conectados (característicos del clúster 8).

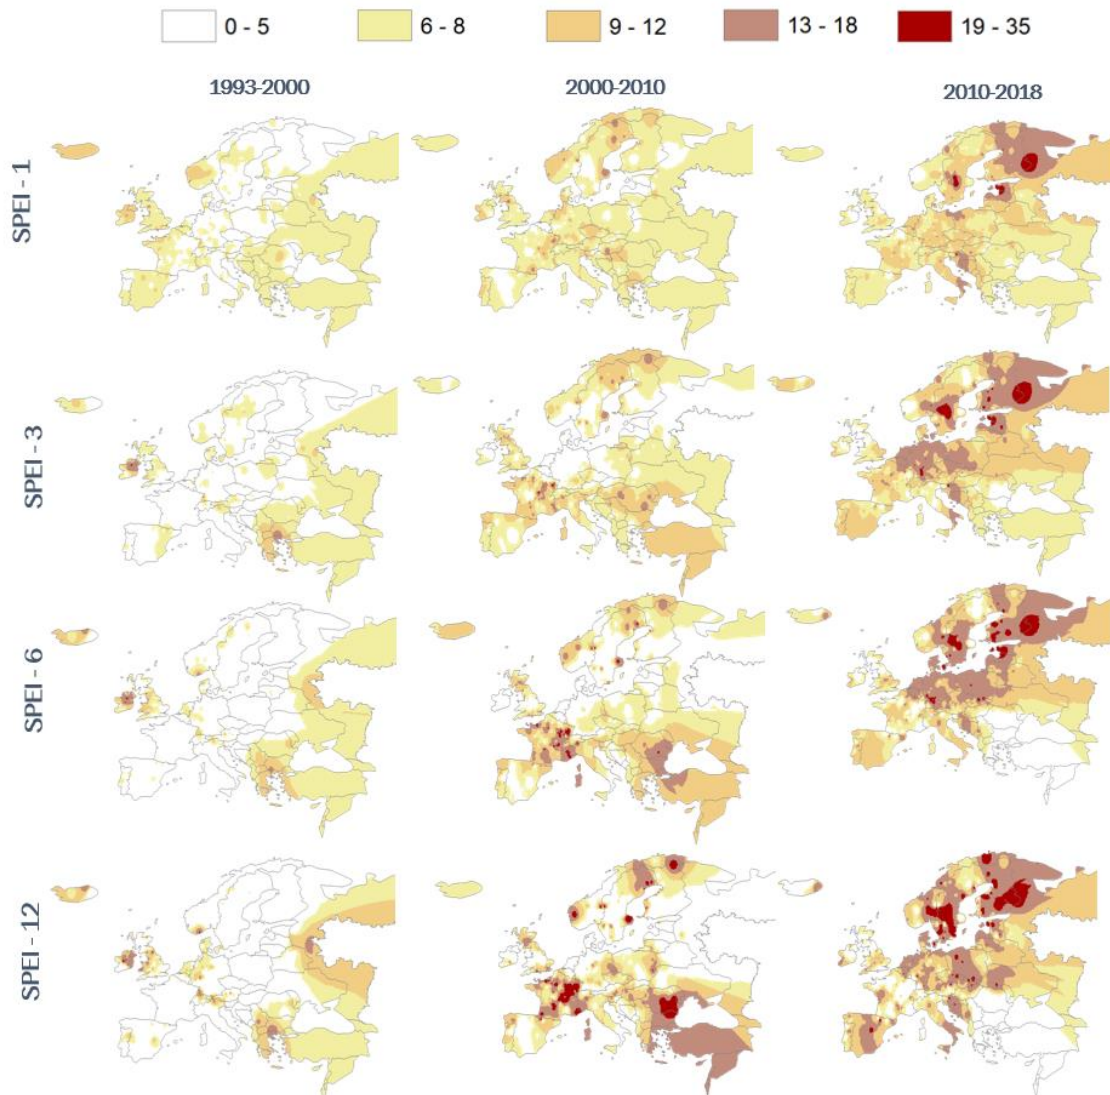
De igual manera en el clúster 11, en donde la agricultura es uno de los factores que más influye en la variabilidad anual de los sistemas hídricos, índices en cortos plazos aportan información de cómo gestionar sequías meteorológicas. En estas mismas cuencas, donde hay una fuerte respuesta a la precipitación, índices de largo plazo aportan información sobre si la sequía meteorológica podría llegar a desarrollarse en una sequía hidrológica, que se podría conocer como un tercer tipo de sequía a la que Van Loon & Van Lanen (2012) han llamado sequía compuesta, en donde existen varios mecanismos generados de un déficit en el volumen de agua que son difíciles de distinguir.

### **5.2.2 Índice estandarizado de Precipitación-Evapotranspiración (SPEI)**

Uno de los resultados esperados en cuanto al SPI y el SPEI era que España fuera una de las regiones con mayor frecuencia en las sequías, dado a que hay constancia de ciclos secos multianuales. Sin embargo, los resultados no muestran esta tendencia de manera tan clara, ello se puede explicar porque los resultados en esta región en particular corresponden a subcuencas localizadas en grandes altitudes, en donde la evapotranspiración no es tan significativa, como si lo puede llegar a ser hacia la costa mediterránea de España; subcuencas que no forma parte de la muestra analizada (Figura 28) debido a no cumplir las condiciones previamente indicadas, sobre todo en términos de calibración.

En las demás regiones del área de estudio, la evapotranspiración potencial es importante en cuencas agrícolas (clúster 7 y 11), en donde se observan algunas diferencias con los resultados del SPI, principalmente hacia la parte central de Europa a finales de década. Pero de manera general, los resultados en comparación con el SPI son muy similares. Ello es debido a que, tal y como explican Vicente-Serrano et al. (2010), bajo condiciones climáticas en las cuales domina una baja variabilidad de la temperatura y por tanto una baja variabilidad de la evapotranspiración, los dos indicadores responden principalmente a la variabilidad en la precipitación. Esta característica se mantiene para una gran parte de las subcuencas analizadas, donde el caudal está conducido por la precipitación (ver 5.2.1 Índice estandarizado de Precipitación SPI).





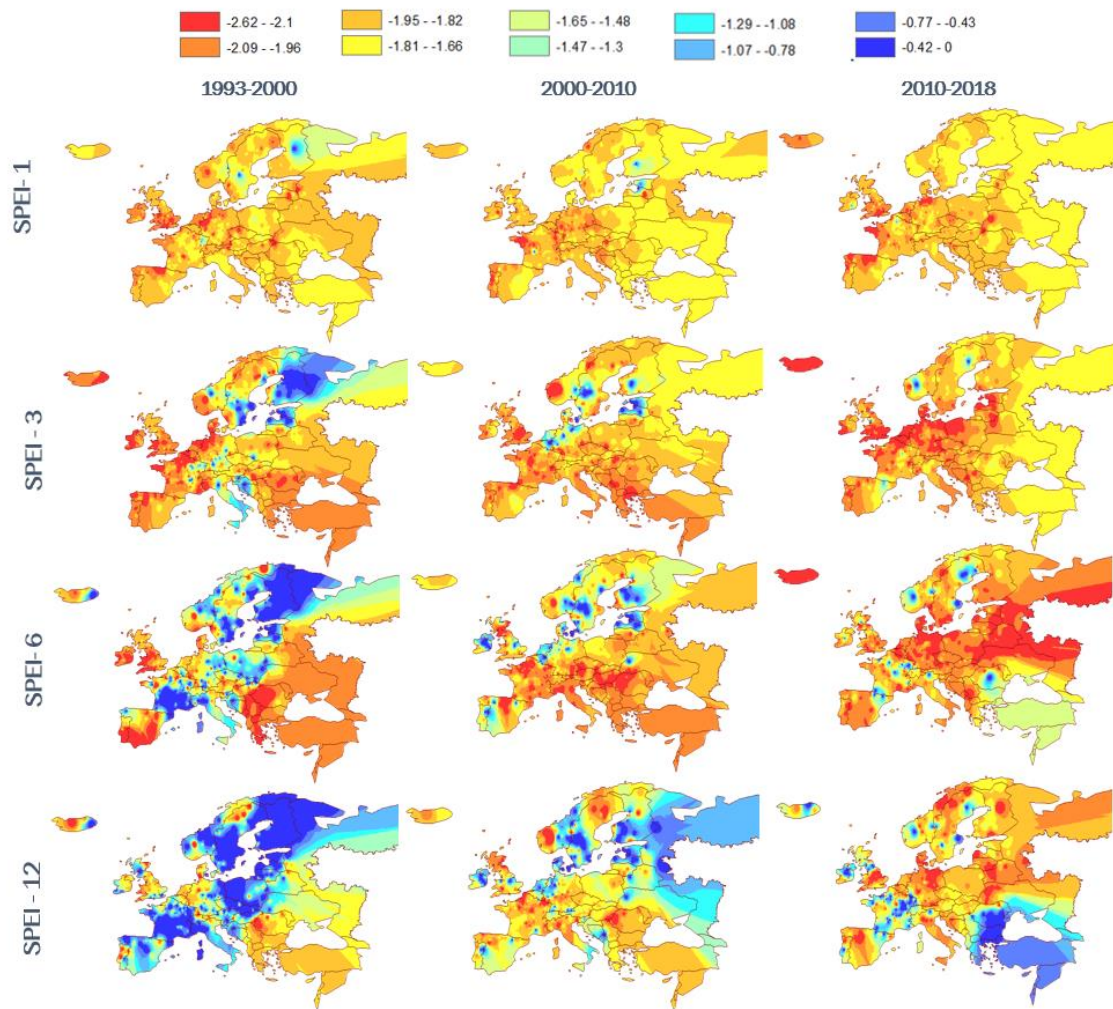
**Figura 28 Frecuencia decadal de las sequías meteorológicas según el índice SPEI**

Fuente: Elaboración propia

En relación con la intensidad, en el primer mes de agregación se sigue presentando las mayores intensidades promedio. Se observan intensidades con sequías extremas hacia la costa del océano atlántico entre el Mar cantábrico, el Canal de la Mancha y Mar del Norte; e intensidades con sequías moderadas en las demás regiones (Figura 29).

En escalas de agregación mayores (SPEI-3, SPEI-6 y SPEI-12) se empiezan a observar regiones de Europa donde no se presentaron sequías, principalmente en la década de 1993-2000. Sin embargo, existen otras regiones donde la intensidad media se incrementa. La más alta obtenida

para el periodo de análisis se da para el SPEI-3 y SPEI-6 meses en la década 2010-2018.



**Figura 29 Intensidad decadal de las sequías meteorológicas según el índice SPEI**

Fuente: Elaboración propia

En los clúster 7 y 11 se puede distinguir otro tipo de sequías, denominadas por Van Loon & Van Lanen (2012) como sequías de otoño a verano, las cuales generan un incremento en la evapotranspiración potencial en los meses de verano (mayor demanda de agua de los cultivos). Esta sequía se caracteriza por un déficit de precipitaciones (sequía meteorológica) en la estación otoño que se prolonga hasta el verano. La sequía meteorológica termina cuando el patrón de lluvias se normaliza. Sin embargo, se desarrolla una sequía hidrológica porque las cantidades de agua evaporadas superan a la precipitación, lo que conlleva que no

exista una suficiente recarga por precipitación y afecte la cantidad de agua en el suelo y/o el nivel de agua en el acuífero.

Este tipo de sequías pueden llegar a ser más complejas de analizar por las relaciones río-acuífero. En los sistemas hídricos donde el río sea perdedor, en épocas de insuficiente recarga natural en el acuífero, el agua que circula por el río compensaría el déficit en la recarga por precipitación. En el caso que el río sea ganador, un descenso en el nivel del acuífero se vería reflejado directamente en un menor caudal; en los dos casos es evidente un déficit originado por la sequía meteorológica.

La sequía de estación otoño a estación verano se produce en cuencas con una clara estación húmeda y seca (subtipos climáticos Köppen-Geiger, clima estepario y clima mediterráneo). Las duraciones son largas (de medio año a un año), y los volúmenes de déficit pueden ser altos en los climas húmedos y a menudo, se mantienen bajos en climas semiáridos (Van Loon & Van Lanen, 2012).

### 5.2.3 Índice estandarizado de humedad del suelo (SSMI)

Uno de los mecanismos que tienen las sequías para avanzar en el ciclo hidrológico es que al pasar de sequías meteorológica a sequía edáfica se produce un desfase (Van Loon & Van Lanen, 2012), debido a que toma más tiempo en rellenar las cavidades del suelo. Esto crea un déficit en el volumen de agua en el suelo, que es aún mayor cuando existe vegetación que necesita el agua en sus procesos fisiológicos. Este desfase también conlleva un alargamiento de la sequía en el tiempo.

Es ahí donde se empiezan a observar las primeras diferencias entre el SSMI y los índices anteriores. Las sequías edáficas mostradas por el SSMI empiezan a tener una mayor frecuencia que las sequías meteorológicas, entre 36 y 45 meses (ver Figura 30). Ello es debido a que en las sequías edáficas además del tipo de clima y la altitud, empiezan a intervenir otros factores fisiográficos como son el tipo de suelo, la porosidad, la capacidad de almacenamiento, el nivel del manto freático y la vegetación.

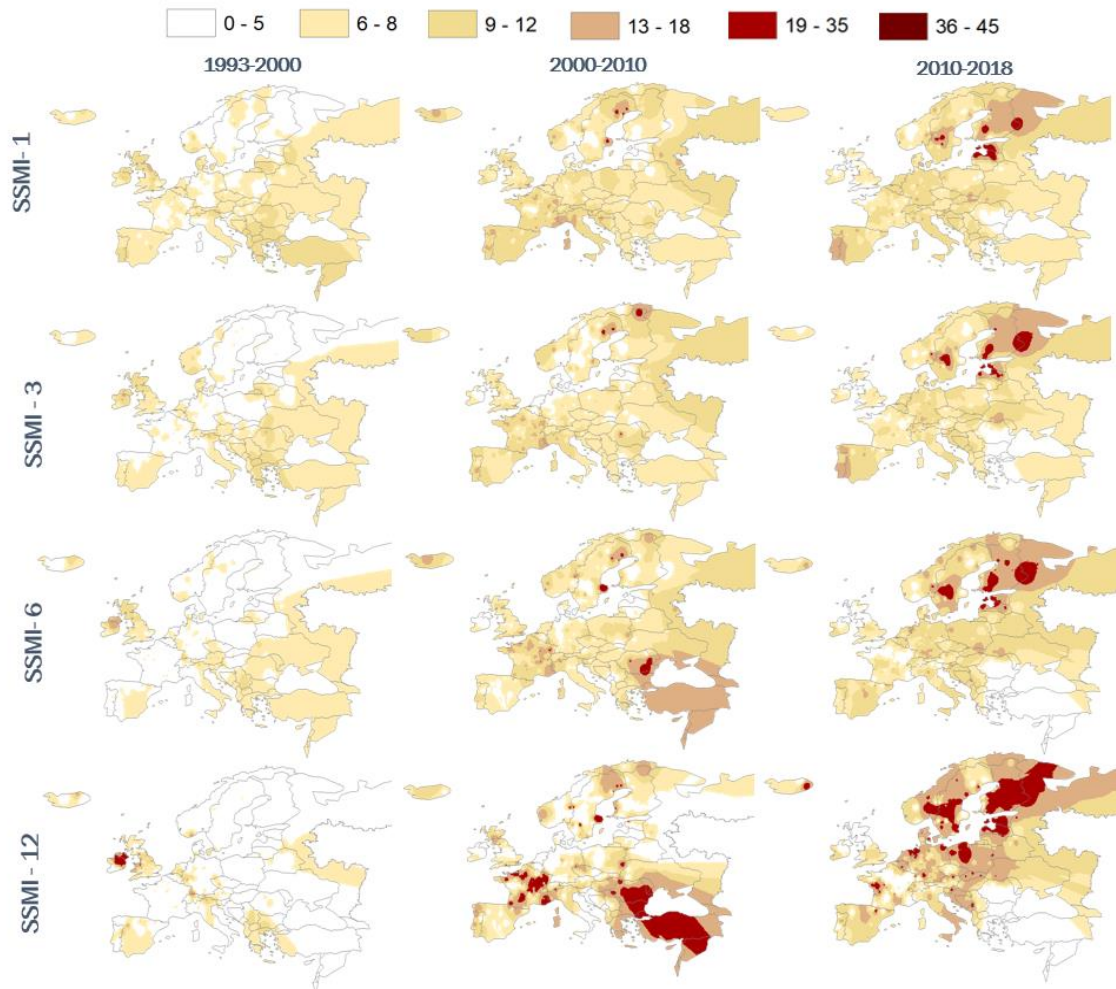
La distribución espacial de la frecuencia de las sequías es muy similar a la mostrada por SPI y SPEI, pero su frecuencia es mucho mayor. Se observa



que la frecuencia en las sequías edáficas es mayor en largos niveles de agregación (SSMI-12) y que las zonas más afectadas son las zonas con clima húmedo. Se destaca el hecho que una de las zonas que presentan mayor frecuencia en las sequías son las masas de aguas superficiales ubicadas en Finlandia, hacia el oeste de los Montes Urales, donde las anomalías en la humedad reflejan un déficit en el volumen del suelo.

En esta región el clima está influenciado por masas de aire frías que vienen del norte y también por los vientos cálidos del atlántico, que contienen grandes cantidades de humedad que se transportan de oeste a este y quedan bloqueadas por la cordillera escandinava. También tiene la particularidad que la humedad del suelo en la capa más superficial es más sensible a pequeños cambios en las variables climáticas, mientras que, en capas más profundas, que están en contacto con las raíces de los suelos forestales, la humedad es más estable. Es por esta razón que el SSMI describe sequías más frecuentes en el extremo sur de Finlandia donde los suelos son poco profundos (Gao et al., 2016)

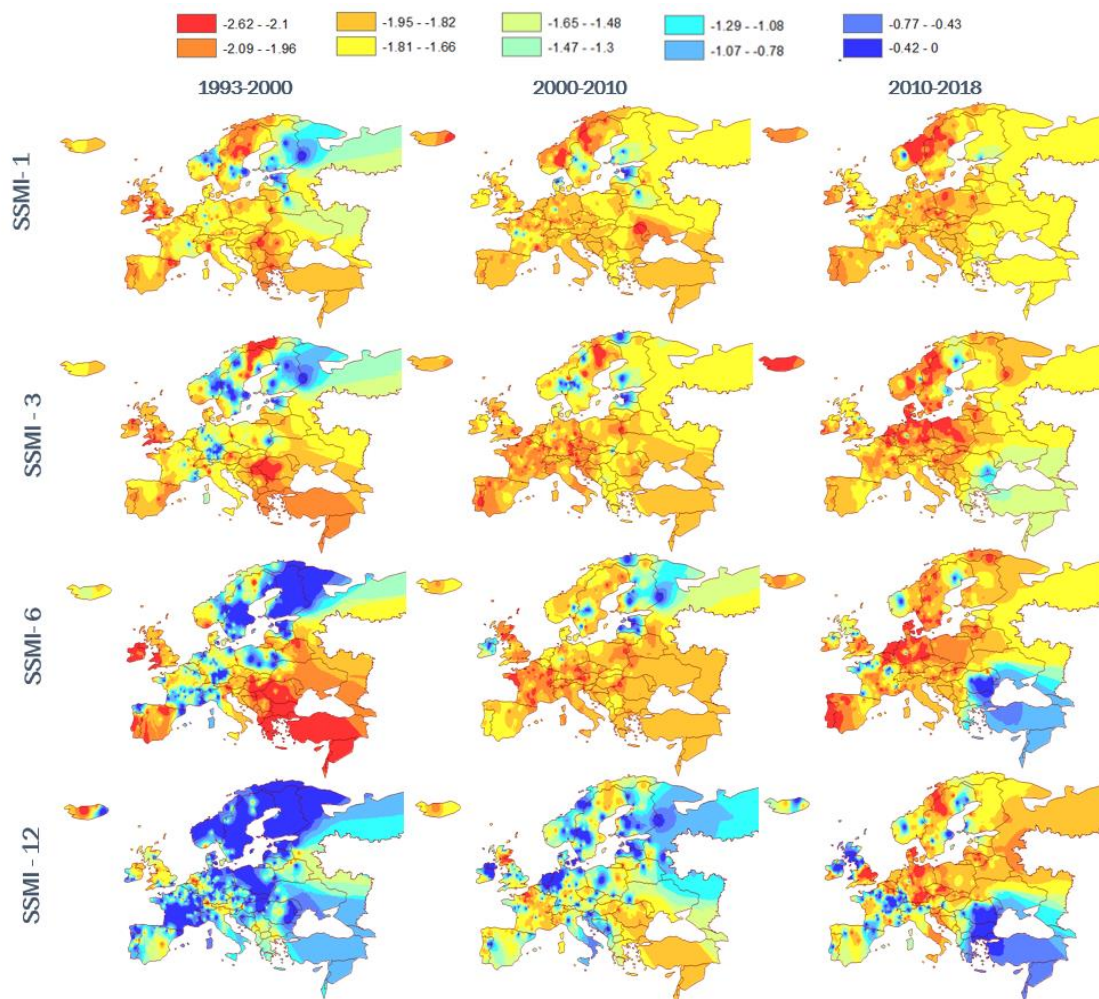
En Rumania también se observan sequías con una frecuencia entre 19 y 35 meses en la década del 2000 al 2010. Las anomalías sobre la humedad en el suelo en esta región están asociadas al régimen de riego de los cultivos agrícolas (Figura 30).



**Figura 30 Frecuencia decadal de las sequías edáficas según el índice SSMI**

Fuente: Elaboración propia

Las sequía severa y extrema del SSMI se presentan con mayor intensidad para la última década 2010-2018, y las áreas con mayor afectación son el norte de Europa, Europa central y la península ibérica (ver Figura 31). A pesar de que la última década sea la de mayor intensidad, se mantiene la tendencia en comparación con el SPI y el SPEI, en donde la intensidad disminuye con el nivel de agregación, suavizando así el efecto de la estacionalidad. Según las características fisiográficas de Europa, una anomalía en la humedad del suelo se puede presentar para cualquier mes, en cualquier estación, aunque se esperaría que la estación con mayor déficit en la humedad fuese verano, por el incremento en la evapotranspiración. Sin embargo, en invierno también se han obtenido déficits importantes en el volumen de agua en el suelo.



**Figura 31 Intensidad decadal de las sequías edáficas según índice SSMI**

Fuente: Elaboración propia

A escala estacional, uno de los procesos que inciden en el volumen de agua almacenado es la fusión de nieve. Asociada a la estación de invierno se pueden dar dos tipos de sequía descritas por Van Loon & Van Lanen (2012): (i) la sequía fría, en invierno, que aparece en subcuencas con un invierno muy frío, que producen un comienzo temprano de la temporada de nieve y un retraso en su derretimiento (clúster 3,4 y 5); y (ii) la sequía cálida, también en invierno, provocada por un derretimiento temprano de la nieve o una fusión por completo del manto de nieve seguido de un déficit en las precipitaciones, lo que es más probable que ocurra en los climas semi-áridos (clúster 7) y en cuencas de respuesta lenta (clúster 1, 8 y 9).

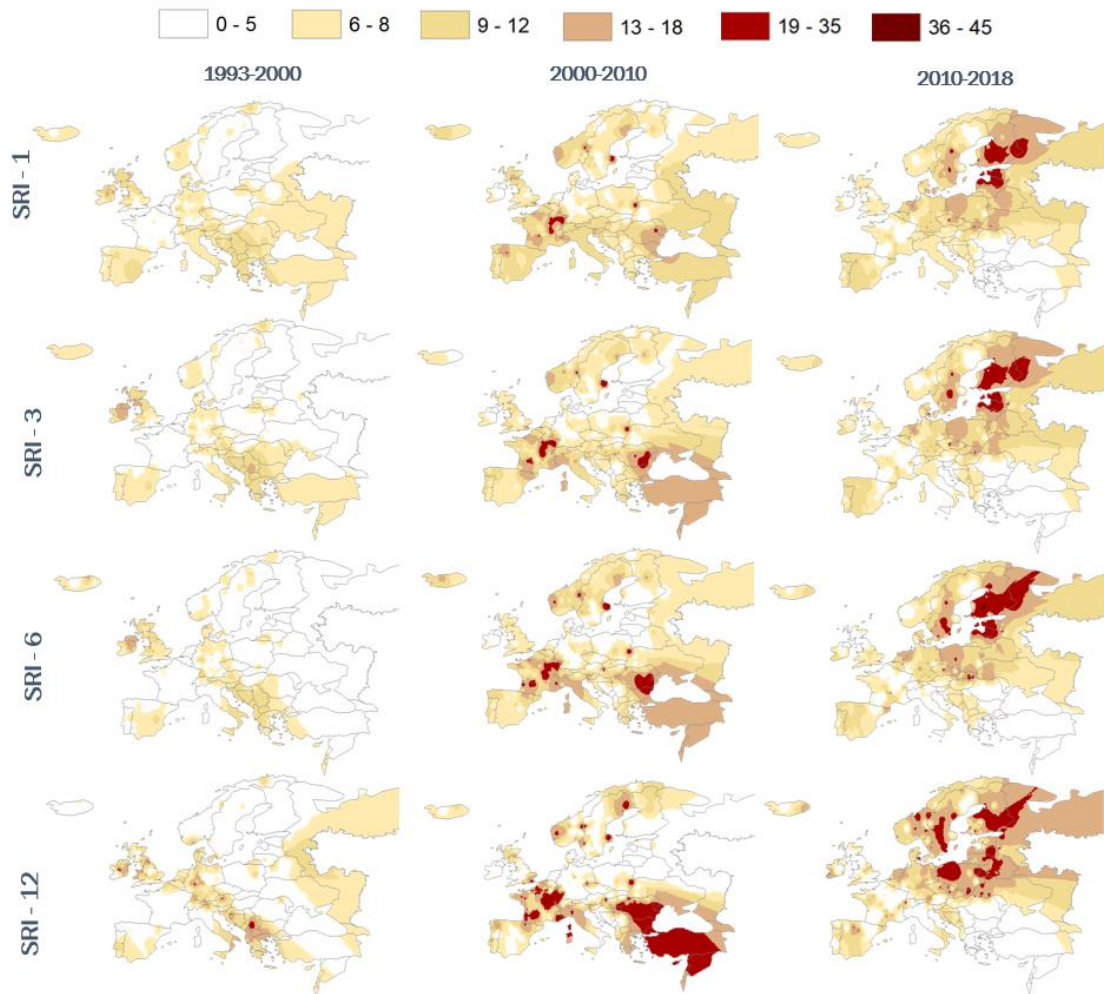
A nivel de clúster, para el SSMI las frecuencias de sequías más altas se observan en los clústeres 3,4,5, 8 y 11, mientras que la intensidad media de la sequía se aprecia en los clústeres 2,6 y 8 que tienen en común al dominio del caudal base y/o a largas recesiones.

#### 5.2.4 Índice estandarizado de caudal (SRI)

Las sequías hidrológicas son un tipo de sequía compuesta que combina un número de eventos de sequía meteorológica y/o edáfica en distintas estaciones y que puede llegar a ser difícil de distinguir. Van Loon & Laaha (2015) describen que en una sequía hidrológica la humedad de la cuenca y la estacionalidad del régimen de caudales tienen la misma importancia y que eventos de sequía hidrológica se vuelven menos frecuentes, pero más largos cuando se pasa de un déficit en la precipitación a un déficit en la humedad del suelo y, posteriormente, a un déficit en el almacenamiento de agua subterránea.

Lo anterior toma mucha relevancia, porque el emplear la frecuencia de meses secos en cada década como variable de análisis no permite distinguir si se están presentando menos sequías hidrológicas más largas en comparación con las sequías meteorológicas y edáficas. Si bien los resultados muestran que en algunas subcuencas ubicadas en Letonia, Estonia y Finlandia (Ríos Salaca, Pärnu jõgi, Kokemäenjoki, Pihlajaveden Reiti) existe una mayor frecuencia en los meses secos, de 36 a 45 meses, en comparación con el SPI y el SPEI. Éstos pueden distribuirse de dos formas: muchos eventos secos de corta duración o pocos eventos secos de larga duración. Para establecer la distribución hay que realizar un análisis bivariado que tenga en cuenta la duración y frecuencia.

El análisis de frecuencia de meses secos del SRI permite observar un déficit del caudal en la región de Francia y Alemania, principalmente en la década 2000-2010, que se produce mayormente en subcuencas del clúster 8 y 9 que están conducidas por el flujo base. También se observan los mismos lugares con mayores frecuencias de meses secos que han sido característicos en el SPI, SPEI y el SSMI, ver Figura 32.



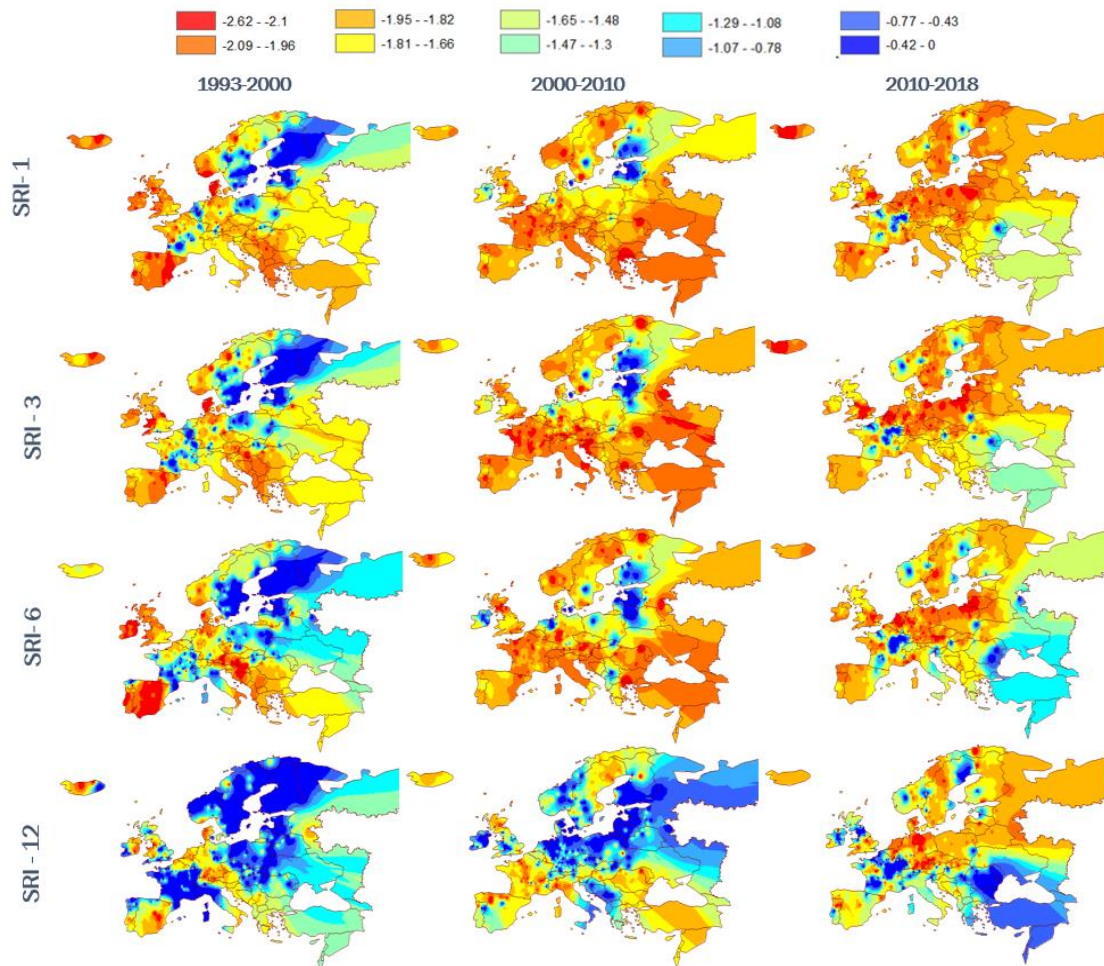
**Figura 32 Frecuencia decadal de las sequías hidrológicas según el índice SRI**

Fuente: Elaboración propia

En la Figura 33 se observa que la intensidad media del SRI tiene una gran correspondencia con el SSMI, pero se presentan intensidades medias mayores (mayor desviación de la media), en los mismos lugares donde se presenta déficit en la humedad del suelo. Se destaca que, tanto para el SSMI como para el SRI, en el primer mes de agregación hay regiones en donde la intensidad baja es muy pequeña para las primeras décadas, contrario a los resultados del SPI y el SPEI, en donde el primer mes de agregación es el que muestra las mayores intensidades en gran parte de Europa. Lo anterior se explica en que los volúmenes de déficit son mayores en las sequías de precipitación, en comparación con las sequías



edáficas e hidrológicas, porque la precipitación es mayor y más variable, lo que da lugar una mayor desviación de la normal climatológica.



**Figura 33 Intensidad decadal de las sequías hidrológicas según el índice SRI**

Fuente: Elaboración propia

A escala de clúster, las frecuencias en los meses secos fueron más altas en los clústeres 3, 5, 8 y 11, mientras que las intensidades medias se obtuvieron en los clústeres 9 y 11. En las subcuencas de gran altitud (clústeres 3 y 5) pueden existir sequías hidrológicas severas en cualquier época del año, y los volúmenes de déficit son elevados debido a la alta variabilidad de la precipitación. Por el contrario, en los sistemas con pendientes relativamente moderadas y planas, las sequías graves sólo se producen en el semestre de verano porque los caudales son nulos y los volúmenes de aguas deficitarios (clúster 8, 9 y 11).

En sistemas agrícolas (como los del clúster 11), también se pueden presentar condiciones normales o de exceso hídrico, porque se encuentran conectados a otros sistemas (agua subterránea, embalses), en donde el efecto de las sequías se puede tardarse mucho más tiempo en presentarse (Podestá, 2020).

### **5.3 Evaluación de la capacidad de predicción estacionales de variables e índices de sequía por el modelo E-HYPE.**

Al hablar de la capacidad de predicción de las variables hidrometeorológicas hay dos factores a tener en cuenta, la escala temporal y escala espacial, debido a que éstos son los que definen la variabilidad de los parámetros y variables de las subcuencas y, a su vez determinan la duración y déficit de las sequías.

A gran escala, la duración de la sequía esta más relacionada con los factores climáticos que con los factores fisiográficos, como la altitud. Por contra, a escala regional, a la que se realiza la gestión de los recursos hídricos, el clima es más uniforme pero la geología, el suelo, la cobertura del terreno y otras características físicas tienden a presentar mayor variabilidad.

El modelo E-HYPE, a través de los clústeres demostró que la calidad de las predicciones de los caudales estacionales puede regionalizarse, basándose en el conocimiento a priori de las condiciones hidroclimáticas locales (Pechlivanidis et al., 2020); Y es que a través de los clústeres modelo E-HYPE, se pueden agrupar los procesos hidrológicos dominantes de los sistemas hídricos.

El estudio realizado por Pechlivanidis et al. (2020) se complementa en este documento con el análisis de la capacidad de predicción los índices de sequía, ya que a través de este análisis se identificó que tanto el clima, como las características físicas de la cuenca desempeñan un papel en la frecuencia e intensidad de los eventos de sequía. Autores como Van Loon & Van Lanen (2012) describen que la frecuencia y duración de la sequía está determinada por el clima, mientras que el volumen del déficit esté más relacionado con las características de la cuenca y su capacidad para amortiguar las sequías.



Estos procesos hidrológicos dominantes controlan tanto los mecanismos de producción de caudal (respuesta rápida, respuesta lenta, influenciados por nieve, evapotranspiración y/o riego), como los medios de propagación de los diferentes tipos sequías (alargamiento, desfase y agrupación). En consecuencia, tienen mucha relevancia al momento de evaluar la capacidad de predicción de las variables hidrometeorológicas basándose en el conocimiento de las condiciones hidroclimáticas del clúster y fluctuaciones estacionales del caudal.

En los siguientes apartados se presenta un análisis de la calidad de las predicciones estacionales. Dicho análisis se presenta a escala de clúster y para cada nivel de agregación de los índices de sequía, estableciendo los factores espacio-temporales que afectan la bondad de las predicciones. El análisis emplea el valor medio del clúster del porcentaje de predicciones estacionales con una bondad de ajuste positiva en el CRPSS. Los colores cálidos de los mapas de calor indican una baja capacidad de predicción y los colores fríos una buena capacidad de predicción. En vertical se pueden ver la calidad de la predicción de los 4 índices de sequía, mientras que en horizontal los resultados por clúster. Los resultados muestran que en todos los clústeres la predicción para el primer mes de anticipación es generalmente aceptable, pero disminuye rápidamente para los siguientes meses de anticipación.

### 5.3.1 Capacidad de predicción de índices de sequía de 1 mes de agregación

La Figura 34 y la Figura 35 presentan los resultados para 1 mes de agregación de la calidad de las predicciones para los 4 índices (SPI, SPEI, SSMI y SRI). Se puede observar que, de manera general, el SPI y el SPEI tienen la capacidad de predicción más baja, manteniendo la tendencia descrita que para el primer mes de anticipación (lead month) la predicción es mejor que para los siguientes meses de anticipación, al igual que ocurre para el SSMI y SRI. A escala de clúster se han identificado las siguientes relaciones entre los mecanismos de producción de caudal y la facilidad de predecir las variables hidrometeorológicas.

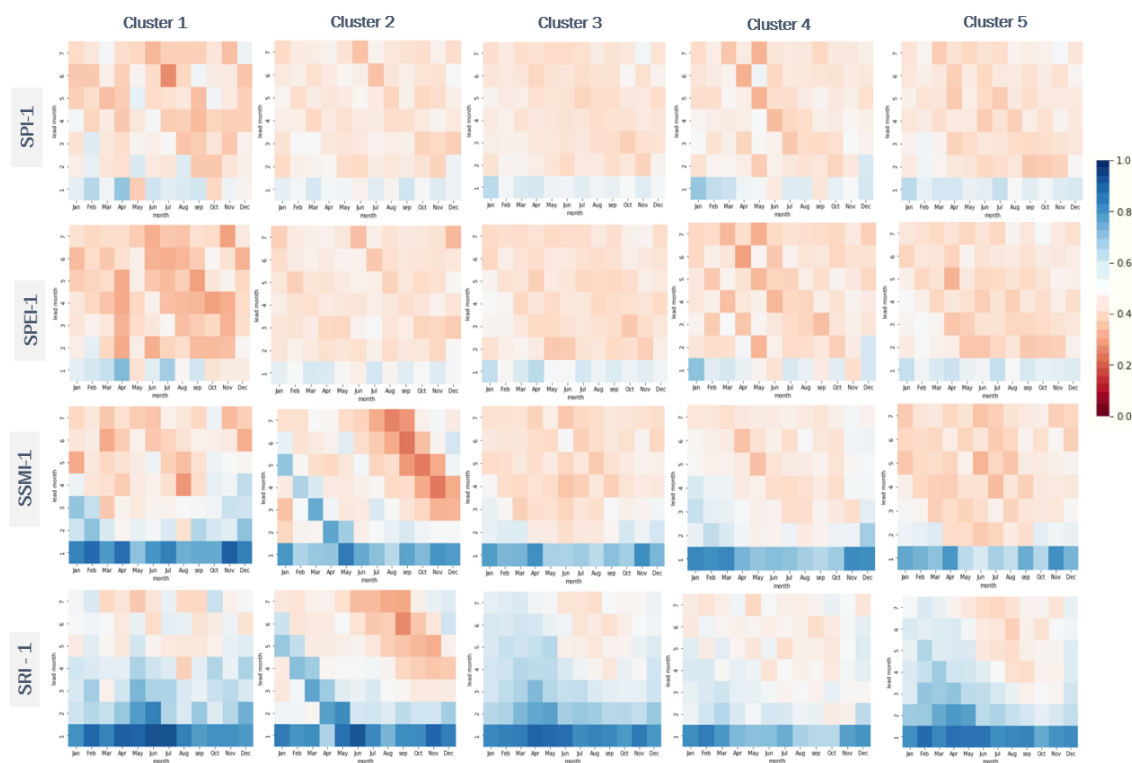
En el clúster 1 el proceso hidrológico dominante es el flujo base, el cual amortigua el caudal por las grandes masas de agua. Esto hace que procesos en el subsuelo como la humedad del suelo (SSMI-1) y el caudal (SRI-1) sean cuasi constantes, y más fáciles de predecir, que en sistemas que presentan una alta variabilidad en los mecanismos de producción de caudal. Estas cuencas tienen una baja respuesta a las precipitaciones que se evidencia en los resultados del SPI-1 y en SRI-1, que muestran una baja correlación. Los sistemas hídricos de este clúster suelen estar Reino Unido, Polonia y Hungría, y tienen alguna influencia de flujos de nieve que se ven rápidamente reflejados a través del SSMI durante el invierno y la primavera.

En el clúster 2, las subcuencas presentan fuertes recesiones, pero el proceso hidrológico dominante es la precipitación, que dan como respuesta fuertes picos en el caudal. Estas cuencas se caracterizan por climas templado continental y templado oceánico, en donde la precipitación está distribuida a lo largo del año. Sin embargo, la lluvia incrementa durante los meses de otoño e invierno (diciembre a marzo), lo que puede estar relacionado a que tengan la más baja calidad en la predicción de la humedad del suelo y el caudal (ver diagonal en rojo). Los meses de mayo y junio, son los meses con mejor capacidad de predicción (ver diagonal en azul) y se relacionan con derretimiento del manto de nieve durante la primavera. Estos sistemas hídricos se encuentran repartidas por sur de Finlandia, Suecia y Noruega.

Las subcuencas del clúster 3 están dominadas por la nieve, de ahí que exista una importante entrada de flujo durante la primavera, que se ve reflejado en el SRI-1 de abril, mayo y junio, y ligeramente en el SSMI1 de

marzo y abril. Son cuencas con una alta variabilidad anual, sin embargo, el caudal es regulado por la presencia de lagos y humedales (que aportan capacidad de predicción como se puede observar en el SRI1). Estos caudales amortiguan los picos estacionales que ocurren durante los meses de enero, febrero y marzo, que son los que tienen la más baja capacidad de predicción hacia los últimos meses de anticipación.

El clúster 4 está conformado por sistemas hídricos de regiones elevadas (cordillera cantábrica, los Alpes) y el clúster 5 por subcuencas de clima continental frío marcadas por la estacionalidad. En los dos clústeres precipitación y la fusión de nieve son procesos hidrológicos importantes. La influencia de la precipitación hace que la capacidad de predicción disminuya principalmente para verano y otoño (que se reflejan de forma, más evidente en el clúster 4 que en el 5).



**Figura 34 Calidad de predicciones 1 mes de agregación para los clústeres del 1 al 5.**

Fuente: Elaboración propia.

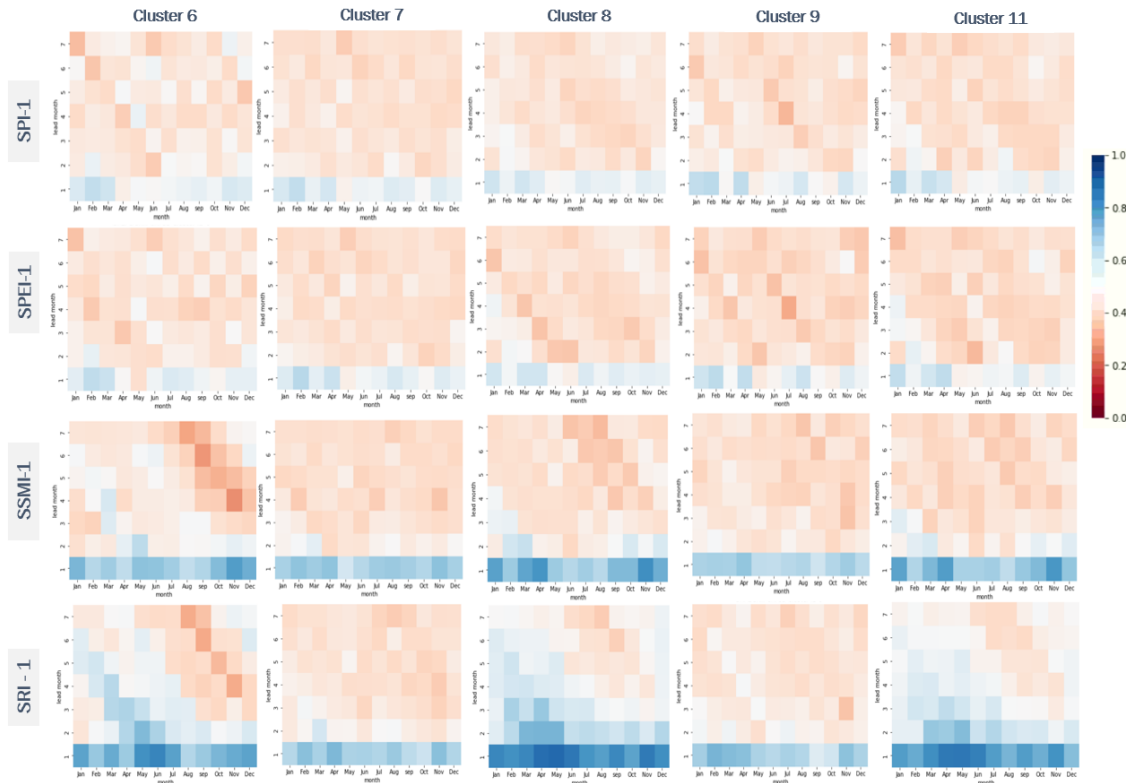
El clúster 6, al igual que el clúster 2, se compone de subcuencas en donde también hay una rápida respuesta a las precipitaciones, con largas recesiones en el caudal. Se puede evidenciar que los meses más difíciles de predecir son parte del otoño (noviembre y diciembre) e invierno

(enero, febrero y marzo) especialmente a partir del tercer mes de anticipación. A diferencia del clúster 2, en la humedad del suelo (SSM11) no son tan evidentes los procesos de fusión de nieve, como si lo pueden llegar a ser sobre el caudal (SRI1). Lo anterior se puede explicar en que una parte de las subcuencas del clúster 6 se encuentran localizadas en los Montes Escandinavos, al igual que la mayoría de los sistemas del clúster 2, mientras que otra parte se ubica en Portugal y Francia; de ahí las diferencias sobre la humedad del suelo, que hacen que el valor medio del clúster se vea afectado por los dos tipos de climas.

Las subcuencas del clúster 7 presenta una alta variabilidad en el régimen de caudales, con una fuerte respuesta a la precipitación, que hace que la capacidad de predicción sea reducida. Son sistemas ubicados en regiones con altas elevaciones (Cordillera de los Pirineos, Alpes, los montes Grampianos y los montes Cambrianos). Los resultados para este clúster indican que solo es posible predecir el primer mes de anticipación, para los siguientes meses la calidad de la predicción disminuye considerablemente.

Los clústeres 8 y 9 se caracterizan por sistemas hídricos en donde el proceso hidrológico dominante es el flujo base. Sin embargo, el clúster 8 incluye subcuencas con climas muy parecidos entre sí y que presentan una baja variabilidad en el caudal, lo que hace que sea más fácil de predecir la humedad del suelo (SSM11) y el caudal (SRI1). En comparación el clúster 9 presenta subcuencas que están distribuidas por todo Europa, con una heterogeneidad en los climas que hace que a nivel de clúster la calidad de predicción sea más baja.

En el clúster 11 se observa que la calidad de las predicciones de las sequías meteorológicas y edáficas son bastante bajas y la predicción sólo mejora en la sequía hidrológica durante la primavera y el verano. La alta variabilidad anual y la respuesta rápida a la precipitación que experimentan las cuencas en este clúster pueden explicar las bajas predicciones y el incremento de la predicción sobre el caudal puede estar asociado a los bajos coeficientes de escorrentía o a la influencia del riego.



**Figura 35 Calidad de predicciones 1 mes de agregación para los clústeres del 6 al 11.**

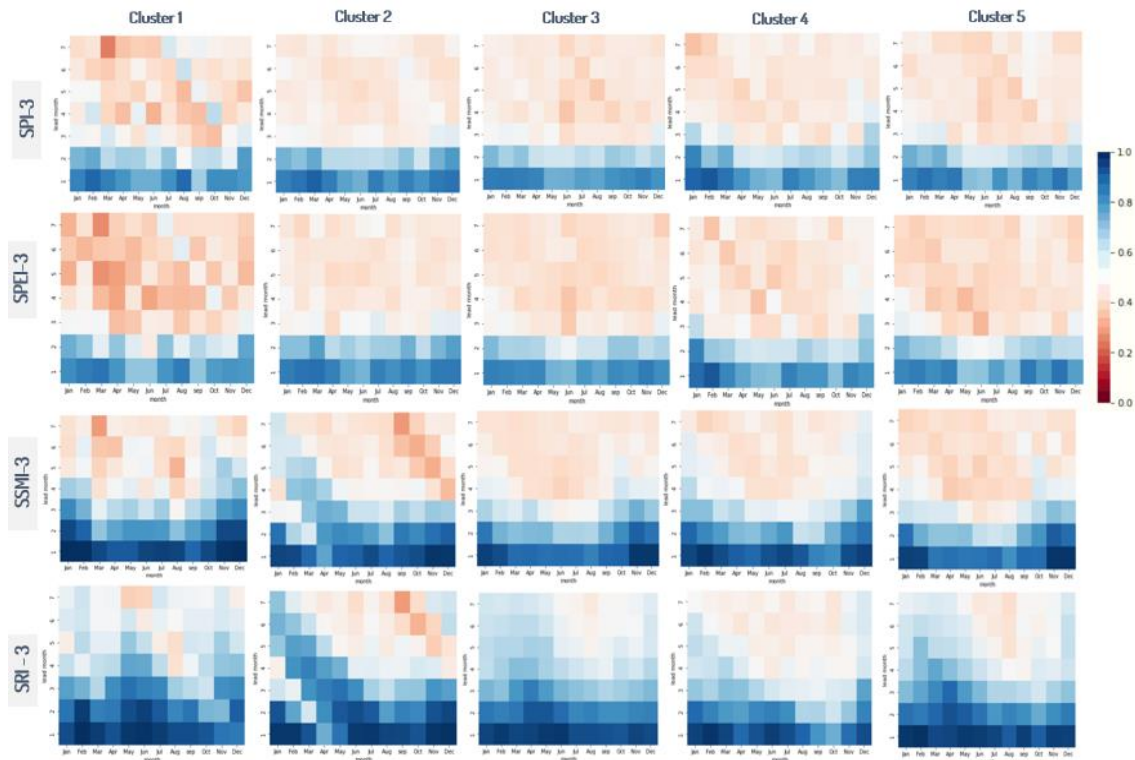
Fuente: Elaboración propia

### 5.3.2 Capacidad de predicción de índices de sequía de 3 meses de agregación

Para el tercer mes de agregación la calidad de las predicciones empieza a aumentar en todos los clústeres. En el caso de las sequías meteorológicas (SPI y SPEI), los resultados son muy similares a los obtenidos para 1 mes de agregación, aunque se observa que ahora también el segundo mes de anticipación presenta buenos resultados prediciendo las variables. Esto es esperable ya que las predicciones inferiores al periodo de agregación (3 meses) involucran datos pasados ya conocidos, lo que dota al índice de cierta inercia que aumenta su capacidad predictiva. En el caso de las sequías edáfica (SSMI3) e hidrológica (SRI3) la calidad de las predicciones es adecuada por lo menos hasta el tercer mes de anticipación.

Los clústeres con sistemas hídricos situados en Escandinavia (clúster 2 y clúster 6), al ser sistemas en donde la nieve se acumula durante el invierno

y se derrite durante la primavera, puede predecirse adecuadamente el SRI3 en la mayoría de los meses. También se conoce que en abril la calidad de la predicción desciende en Escandinavia, donde la temperatura se acerca a los 0°C y, por tanto, pequeñas desviaciones pueden traducirse erróneamente en nevadas o precipitaciones (Pechlivanidis et al., 2020), ver Figura 36.



**Figura 36** Calidad de predicciones 3 meses de agregación para los clústeres del 1 al 5.

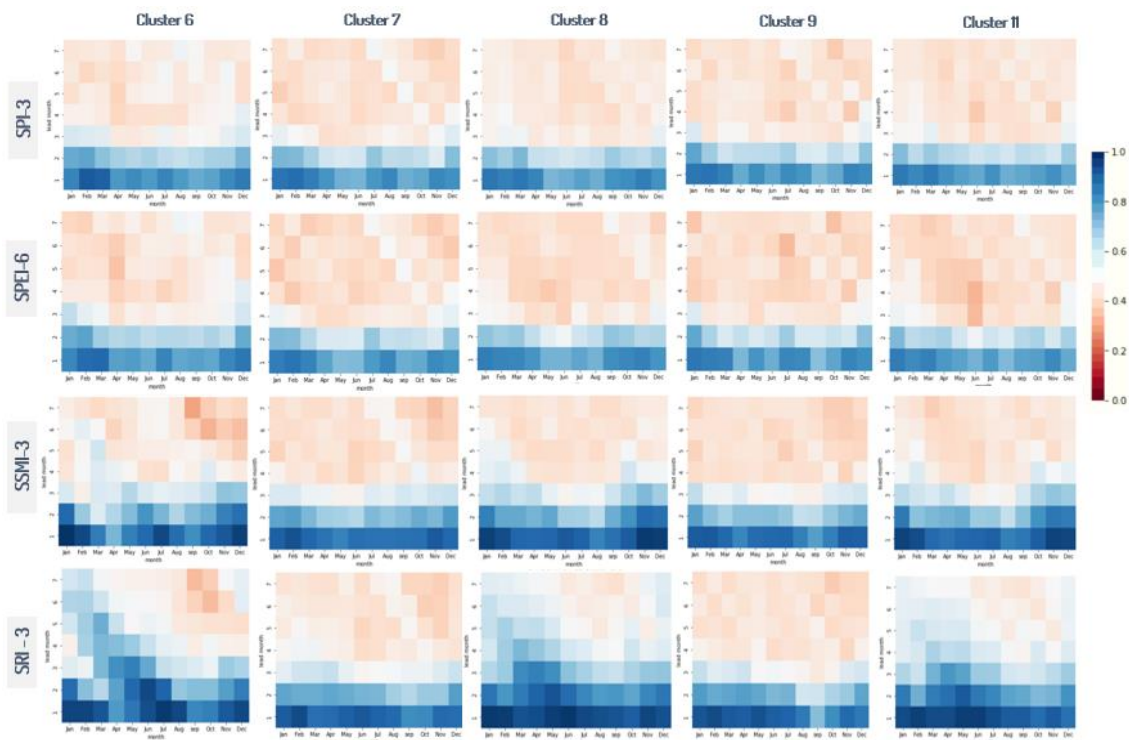
Fuente: Elaboración propia

En las subcuencas en donde se genera energía hidroeléctrica (clúster 4), Pechlivanidis et al. (2020) describe que la respuesta del caudal natural del sistema hídrico puede quedar enmascarada por el esquema de regulación, que puede tener dos tipos de respuesta (constante o estacional cuando los niveles de agua están por encima de un umbral) según las reglas de operación de los embalses,. Esta situación, que ya es conocida, se aplica tanto a la simulación del periodo de referencia como a la simulación de las predicciones. Ello da lugar a buenas predicciones en el SSMI-3 y SRI-3; pero en el caso del SRI-3 la calidad de las predicciones se encuentra un poco por debajo de la calidad en el clúster 5, que son con subcuencas muy parecidos pero que no están reguladas. En el tercer



mes de agregación la capacidad de predicción aumenta en primavera, pero en verano y otoño la calidad de predicción en meses de anticipación avanzados sigue siendo relativamente baja.

En sistemas con clima mediterráneo (clúster 7 y clúster 9) el régimen del caudal puede estar afectado por alteraciones hidromorfológicas sobre los ríos (construcción de embalses para la laminación de avenidas o para el control de regadíos) que son difíciles de predecir si se presenta una alta variabilidad anual o si no se conoce el régimen de caudales impuesto, que para estas cuencas puede estar invertido (mayor caudal en verano). En el caso por ejemplo de los ríos Cabriel, Tajo y Uvero, el régimen se caracteriza generalmente por un bajo caudal, debido a las altas tasas de evapotranspiración, que harían pensar en que el uso del SPEI presenta ventajas respecto al SPI, aunque los resultados no arrojan grandes diferencias entre los índices, debido a que el número de subcuencas con climas mediterráneos de bajas latitudes no es representativo en dichos clústeres.



**Figura 37** Calidad de predicciones 3 meses de agregación para los clústeres del 6 al 11.

Fuente: Elaboración propia

Lo que sí es evidente es que la regulación de los embalses si afecta a la respuesta de la cuenca e influye en la calidad de su predicción de los caudales. En el caso del clúster 7 está impulsada por las precipitaciones, y experimenta una gran variabilidad en el régimen hidrológico. En el caso del clúster 9 la variabilidad en el caudal esta amortiguada por el flujo base, pero el impacto de los embalses hace que tenga la calidad de las predicciones más baja en el caudal (SRI-3) comparado con los clústeres 1 y 8, que también están regulados por masas de agua.

Las subcuencas pertenecen al clúster 11 también experimentan una disminución en la calidad de las predicciones asociada a la fuerte influencia de la precipitación, particularmente en los meses de otoño e invierno y que son más evidentes en el SRI-3.

### **5.3.3 Capacidad de predicción de índices de sequía 6 de meses de agregación**

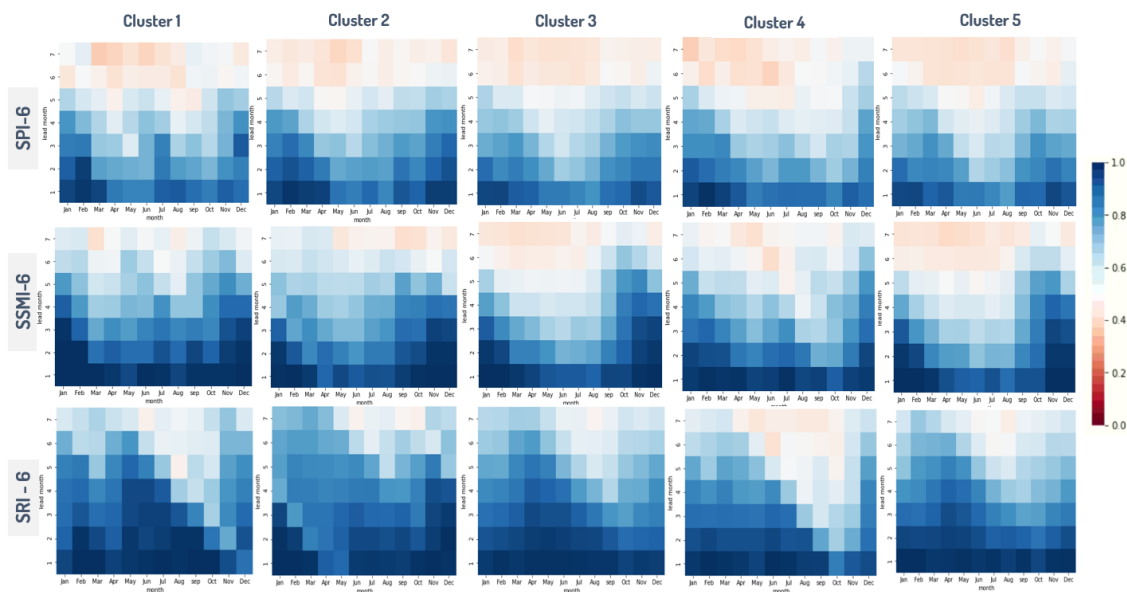
Para la escala de agregación de 6 meses, la calidad de las predicciones aumenta hasta el 5 mes de anticipación para el SPI, para el 6 mes de anticipación en el SSMI y 7 mes de anticipación en el SRI, provocado por el uso de datos pasados ya conocidos en el cálculo, al igual que se ha constatado en para una agregación de 3 meses. Para esta agregación y para 12 meses no se presentan resultados del SPEI, debido a que estos son muy similares y, para algunos clústeres, llegan a ser iguales a los resultados del SPI (por la baja influencia de la evapotranspiración en los sistemas caracterizados).

A medida que se avanza con el nivel de agregación se puede observar de manera más clara la tendencia descrita por Pechlivanidis et al. (2020): independiente del tipo de respuesta predominante en el clúster, queda en evidencia qué meses son más fáciles de predecir y sobre cuales se tiene mayor dificultad. La mayor predictibilidad sobre Europa se muestra de abril a agosto (con excepción del clúster 2 y 6), y su calidad disminuye en otoño e invierno.

En función del tipo de respuesta hidrológica predominante existe una clara identificación de los clústeres con valores altos en el CRPSS. Las subcuencas de los clústeres 1, 3 y 8 tienen la mayor calidad de predicción de caudales (SRI), debido a que tienen una alta memoria hidrológica, amortiguación del caudal por flujo base (clúster 1 y 8) y presencia de lagos y humedales, que retrasan y controlan la señal de los caudales

(clúster 3). En este grupo también se debería encontrar el clúster 9, que también está regulado por el flujo base. Sin embargo, la heterogeneidad en los climas de los sistemas que conforman este clúster hace que su calidad disminuya, principalmente en otoño (Figura 38 y Figura 39). Las cuencas de esos clústeres se caracterizan por procesos que se rigen por las características de las cuencas y condiciones de almacenamiento previas, más que en respuesta a las variaciones rápidas del clima.

Los clústeres con influencia en los procesos de nieve en regiones con alta humedad, como Escandinavia y Reino Unido (clúster 1, 2, 4 y 6), son los que presentan mejores resultados en el SSMI, debido a la saturación del suelo en las capas superficiales. En cuanto al caudal, las predicciones estacionales disminuyen en las cuencas de los clústeres 4 y 5 (más evidente en el clúster 4 que en el clúster 5), debido a que la contribución de flujo base es muy pequeña y la respuesta la precipitación sigue siendo importante en estas cuencas.

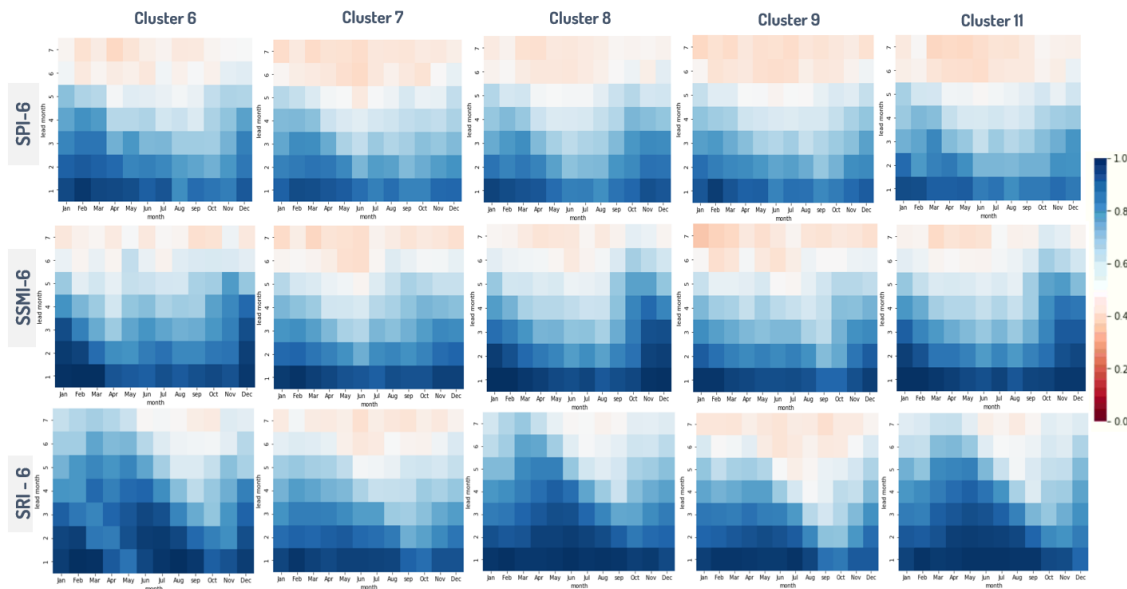


**Figura 38 Calidad de predicciones 6 meses de agregación para los clústeres del 1 al 5.**

Fuente: Elaboración propia

La calidad de las predicciones alcanza los valores más bajos en los clústeres con una respuesta inmediata de las variables meteorológicas sobre el caudal, en particular clúster 7 y clúster 11 (más evidentes en el clúster 7). Estos sistemas hídricos, según Pechlivanidis et al. (2020) se caracterizan por una corta memoria hidrológica con respuesta rápida a

la señal de precipitación, alta variabilidad estacional y una pequeña contribución del flujo base (Figura 39).



**Figura 39** Calidad de predicciones 6 meses de agregación para los clústeres del 6 al 11.

Fuente: Elaboración propia


#### 5.3.4 Capacidad de predicción de índices de sequía para 12 meses de agregación

La mayor capacidad de predicción de la sequía se obtiene para periodos de acumulación más largos, se demuestra que la calidad de las predicciones a los 12 meses de agregación es la más alta comparada con las escalas de agregación anteriores, por el uso de datos del pasado que son ya conocidos. En general, los resultados del SPI12, SSMI12 y SRI12 muestran que las sequías se pueden predecir con una buena calidad hasta el séptimo mes de anticipación.

Sutanto & Van Lanen (2022) indican que la resolución temporal mensual utilizada en el cálculo de los índices de sequía es la principal causa que aumenta la capacidad de predicción, que en particular para las sequías meteorológicas sólo tiene una buena capacidad de predicción para unos pocos días de anticipación, inclusive para algunas semanas. Este aspecto es muy importante desde el punto de vista de la predicción de las sequías, debido a que la anticipación de los eventos de sequía no exige una escala temporal tan detallada, como sí la exige las predicciones

meteorológicas e hidrológicas (escala diaria). Las predicciones de sequía necesitan estimaciones de la variable acumulada, las cuales proporcionan información sobre la probabilidad de que los próximos meses sean más húmedos o más secos que la media. Por tanto, en la monitorización de la sequía, sobreestimar o subestimar el valor de la variable en un día no es tan importante, porque esta tendencia se contrarresta al emplear el conjunto de valores del mes.

Los resultados obtenidos, a través de las distintas escalas de agregación empleadas, permiten observar que la capacidad de predicción de las sequías hidrológicas es mucho mayor a las sequías meteorológicas. Sutanto & Van Lanen (2022) afirman que la diferencia podría ser de 2 o 3 meses de anticipación; sin embargo, los resultados evidencian que esta diferencia, en escalas de agregación cortas, está en función de las características de las subcuencas; mientras que para largas escalas de agregación la diferencia podría ser solo de 1 mes de anticipación. Lo anterior también puede cambiar en función del modelo hidrológico y la calibración del modelo (Figura 40 y Figura 41).




**Figura 40 Calidad de predicciones 12 meses de agregación para los clústeres del 1 al 5.**

Fuente: Elaboración propia

En el caso particular de las sequías edáficas e hidrológicas, además de la resolución temporal y del periodo de acumulación, también intervienen el almacenamiento y tipo de respuesta; ya que las grandes masas de aguas, superficiales y subterráneas, tienen la capacidad de

acumular, atenuar y prolongar el efecto de las precipitaciones. Los clústeres con subcuencas de respuesta lenta presentan las sequías con menor intensidad y mayor duración, ya que se deben a cambios en las condiciones de almacenamiento; mientras que cuencas de respuesta rápida muestran cambios a las condiciones meteorológicas, por lo que las sequías tienden a tener mayor intensidad y menor duración.



**Figura 41 Calidad de predicciones 12 meses de agregación para los clústeres del 6 al 11.**

Fuente: Elaboración propia

Sutanto & Van Lanen (2022) también sostiene que la combinación de datos observados con los datos del periodo de referencia de las predicciones (hindcasts) mejora la calidad sobre los índices de sequía, especialmente en las sequías meteorológicas. Los resultados muestran que, para los 12 meses de agregación, se alcanzan predicciones que en promedio presentan calidad para más del 80% de los datos. Estos resultados toman mucha relevancia desde la planificación de recurso hídrico, debido a que predecir las sequías con unos meses de anticipación otorga un cierto margen de ventaja para hacer frente a las sequías si se complementa a los Sistemas de Alerta Temprana de Sequías (SAT).

Empleando predicciones estacionales, los usuarios y gestores podrán saber con cierto nivel de confianza cuando se prevé que inicie y termine una sequía, además de identificar las zonas potencialmente afectadas a través de los diferentes índices de sequía. Con esta información, los



usuarios y los gestores del recurso hídrico pueden tomar medidas de contingencia y la asignación de prioridades del recurso hídrico (uso urbano, cumplimiento de los caudales ecológicos y conservación de ecosistemas, planificación de riego, suministro de energía, etc.)

## Capítulo 6. Síntesis, conclusiones y futuras líneas de investigación.

En este trabajo, se analizó la capacidad de predicción espacio-temporal de las sequías meteorológicas, edáficas e hidrológicas en Europa a través de 4 índices de sequía. Para ello se estudió una muestra de 617 subcuencas simuladas mediante el modelo hidrológico a gran escala E-HYPE, y distribuidas por toda Europa con un fuerte gradiente climatológico, altitudinal e hidrológico.

A partir de las características climáticas y fisiográficas que estableció el modelo E-HYPE en cada clúster, se evaluó la calidad de las predicciones estacionales teniendo en cuenta los procesos hidrológicos dominantes que intervienen en la predictibilidad de las variables de los índices de sequía.

### 6.1 Síntesis y conclusiones

Para evaluar la calidad de las predicciones estacionales de los índices de sequía, primero fue necesario realizar la estandarización y normalización de las variables precipitación, humedad del suelo, precipitación – evapotranspiración potencial y caudal. Por variable, subcuenca y nivel de agregación (1, 3, 6 y 12 meses) se realizó la selección de las funciones de distribución y la estimación de los parámetros para el periodo de referencia del modelo E-HYPE. Las funciones seleccionadas se emplearon para calcular los índices de sequía de las predicciones del pasado o hindcasts y finalmente por clúster estimar el porcentaje de predicciones con calidad (índice CRPSS positivo).

Las subcuencas analizadas presentan, de manera general, dos tipos de respuesta en los mecanismos de producción del caudal. Sistemas de reacción rápida o memoria hidrológica corta, donde las características de las sequías están condicionadas por las precipitaciones. En los sistemas de respuesta rápida también se pueden encontrar otros tipos de procesos hidrológicos importantes como son: procesos de fusión de nieve; largas recesiones; y sistemas regulados a través de embalses. Por otro lado, están los sistemas de reacción lenta, o memoria hidrológica larga, en donde las características de la sequía están condicionadas por el flujo base o por grandes masas de agua (lagos o humedales). Sobre este tipo



de sistemas también pueden existir subcuencas en donde los procesos de nieve son importantes.

Dichos procesos que se presentan de manera regional y se encuentran agrupados por clústeres. Se observó que la regionalización en la respuesta del caudal no es tan determinante en la selección y ajuste de las funciones de distribución, pero si esta muy fuertemente correlacionada con los medios de propagación de las sequías y la calidad de las predicciones estacionales.

Los resultados muestran que, a nivel espacial, no es posible determinar si existe algún patrón físico o proceso hidrológico que influya en la selección de las funciones de distribución. Si bien, al interior de cada clúster existe una función de distribución que tienen mayor frecuencia en la selección, esta selección puede cambiar en los siguientes meses de agregación. Sin embargo, en cuanto al análisis de sequías, si es posible establecer regiones mas afectadas por las sequias (Norte de Europa).

Por otro lado, los resultados también evidencia que uno factores que demostró ser determinante durante todo el proceso, fue la escala temporal. La resolución mensual incide tanto en la selección de las funciones de distribución, la frecuencia e intensidad de las sequias y la calidad de las predicciones, debido a que reducen el efecto de la variabilidad a escala diaria.

Con base en la síntesis anterior, y a la vista de los resultados obtenidos para cada una de las partes de las que se compone este trabajo, se presentan las siguientes conclusiones:

- En relación a las funciones de distribución se observó que no existe una única distribución que domine sobre el resto con mejor ajuste. Las funciones de distribución con mejores resultados son las que emplean mayor número de parámetros para realizar el ajuste.
- De manera general, a medida que se avanza en el tipo de sequía (SPI o SPEI a SSMI y SRI), la capacidad de predicción de variables va en aumento. Esto corrobora que las variables hidrológicas son más fáciles de predecir que las variables meteorológicas porque en su predictibilidad intervienen procesos deterministas

(condiciones iniciales y almacenamiento). No obstante esto requiere que las condiciones iniciales estén bien establecidas.

- Independientemente del índice, la mayor predictibilidad sobre Europa se muestra en las estaciones de primavera y verano, y la calidad disminuye en otoño e invierno por la influencia de las precipitaciones.
- Para 1 mes de agregación, la capacidad de predicción en los índices de sequía edáfica e hidrológica es buena solo para el primer mes de anticipación y se deteriora rápidamente con el aumento de los meses de anticipación.

La escala temporal mensual incide sobre la calidad de las predicciones. Se demuestra que a mayores agregaciones temporales (3, 6 y 12 meses) la capacidad de predicción mejora, debido a que la variabilidad disminuye cuando la variable se agrega, y a que en la agregación intervienen valores pasados ya conocidos.

- Se observa que los clústeres con mejor capacidad de predicción son aquellos que presentan menor variabilidad en el proceso hidrológico dominante (clústeres 1, 3 y 8). En estas subcuencas dominada el flujo base, por lagos o humedales.
- Los clústeres donde los procesos de fusión de nieve son importantes (clúster 1, 2, 3, 4, 5 y 6) tienen una adecuada predicción sobre las sequías edáficas e hidrológicas. Se observa una calidad mayor en las cuencas reguladas por grandes masas de agua (clúster 1 y 3) y peor predicción en cuencas condicionadas por la precipitación (2, 4, 5 y 6).
- Por el contrario, en los clústeres (clúster 7 y 11) donde la precipitación es la variable principal, la capacidad de predicción es menor, dado que la precipitación transfiere su alta variabilidad a los demás procesos hidrológicos.
- Se observó que la diferencia en la calidad de las predicciones de las sequías meteorológicas, edáficas e hidrológicas para una agregación de 1 mes depende de las características del clúster. Para más de 1 mes de agregación la calidad de predicción varía

según el tipo de sequía, las sequías hidrológicas y edáficas muestran uno o dos meses más de anticipación con calidad que las sequías meteorológicas.

## 6.2 Líneas de investigación futuras

Desde experiencia de este trabajo, se abre paso a las siguientes líneas de investigación:

- (i) Mejorar el proceso de ajuste de las funciones de distribución, que no tienen una adecuada normalización. Se podría probar otros métodos para la estimación de parámetros (máxima verosimilitud o la probabilidad de los momentos ponderados - PMW). También se podría realizar el ajuste cambiando el nivel de significancia de los test de normalidad para ampliar el umbral de normalidad de las series.
- (ii) Profundizar sobre el análisis de las sequías que se desarrollan en cada sistema hídrico, incluyendo resultados a escala estacional y que pueda apoyar la toma de decisiones y los Sistemas de Alerta Temprana de Sequías (SAT). Una vez calculados los índices de sequía se pueden realizar muchos análisis en función de la información que se requiera. Información especialmente útil, desde el punto de vista de la gestión integral del recurso hídrico, ya que al proporcionar información sobre la cantidad de agua que se prevé que falte en los próximos meses se pueden tomar decisiones relacionadas con la gestión de embalses, cumplimiento de los caudales ecológicos, régimen de explotación de los acuíferos, planificación de regadíos y/o alertar sobre volúmenes deficitarios para la generación de energía.
- (iii) Aplicar la metodología desarrollada para realizar un estudio similar, con modelos hidrológicos de detalle que permitan probar la calidad de las predicciones estacionales para sistemas concretos, y en donde se pueda evaluar la calidad de las predicciones en función de datos observados de la cuenca y no con datos generados por el mismo modelo hidrológico.



- (iv) Replicar el estudio a otros ámbitos espaciales, se puede aplicar la metodología a otros modelos hidrológicos de gran escala para comprobar la calidad sobre las predicciones HYPE global, VIC-WUR model, LISFLOOD. Para lo que se requiere únicamente tener los datos de insumo, que están disponibles a través de Copernicus.

## Referencias bibliográficas

- AEMET. (2016). *Interpretación del Índice de Precipitación Estandarizado (SPI)—Agencia Estatal de Meteorología—AEMET. Gobierno de España. Interpretación del Índice de Precipitación Estandarizado (SPI).*  
[http://www.aemet.es/es/serviciosclimaticos/vigilancia\\_clima/vigilancia\\_sequía/ayuda](http://www.aemet.es/es/serviciosclimaticos/vigilancia_clima/vigilancia_sequía/ayuda)
- Akaike, H. (1974). A new look at the statistical model identification. *IEEE Transactions on Automatic Control*, 19(6), 716–723.  
<https://doi.org/10.1109/TAC.1974.1100705>
- Amat Rodrigo, J. (2021). *Análisis de normalidad con Python [Análisis de normalidad con Python]. Análisis de Normalidad Con Python.*  
<https://www.cienciadedatos.net/documentos/pystats06-analisis-normalidad-python.html>
- Beguiría, S., Vicente-Serrano, S. M., Reig, F., & Latorre, B. (2014). Standardized precipitation evapotranspiration index (SPEI) revisited: Parameter fitting, evapotranspiration models, tools, datasets and drought monitoring. *International Journal of Climatology*, 34(10), 3001–3023. <https://doi.org/10.1002/joc.3887>
- Carrão, H., Russo, S., Sepulcre-Canto, G., & Barbosa, P. (2016). An empirical standardized soil moisture index for agricultural drought assessment from remotely sensed data. *International Journal of Applied Earth Observation and Geoinformation*, 48, 74–84.  
<https://doi.org/10.1016/j.jag.2015.06.011>
- Cortez, A., Olivares, B. O., Parra, M., & Lobo, D. (2019). Systematization of the calculation of the Standardized Precipitation Index as a methodology to generate meteorological drought information. *Rev. Fac. Agron.*, 15.
- CSIC. (2015). *Monitor de sequía meteorológica. Monitor de Sequía Meteorológica.*  
<https://monitordesequía.csic.es/monitor/?lang=es#index=spi#months=1#week=4#month=1#year=2022>
- D'Agostino, R. B., Belanger, A., & D'Agostino, R. B. (1990). A Suggestion for Using Powerful and Informative Tests of Normality. *The American Statistician*, 44(4), 316. <https://doi.org/10.2307/2684359>
- Donnelly, C., Andersson, J. C. M., & Arheimer, B. (2016). Using flow signatures and catchment similarities to evaluate the E-HYPE multi-



- basin model across Europe. *Hydrological Sciences Journal*, 61(2), 255–273. <https://doi.org/10.1080/02626667.2015.1027710>
- European Drought Observatory. (2017). *Drought Indicators—European Drought Observatory—JRC European Commission*. <https://edo.jrc.ec.europa.eu/edov2/php/index.php?id=1010>
- European Drought Observatory. (2021). *Global Drought System—Global Drought Observatory—JRC European Commission*. <https://edo.jrc.ec.europa.eu/gdo/php/index.php?id=2000>
- European Union. (2021). *EFFIS - Seasonal forecast*. <https://effis.jrc.ec.europa.eu/about-effis/technical-background/seasonal-forecast-explained>
- Gao, Y., Markkanen, T., Thum, T., Aurela, M., Lohila, A., Mammarella, I., Kämäräinen, M., Hagemann, S., & Aalto, T. (2016). Assessing various drought indicators in representing summer drought in boreal forests in Finland. *Hydrology and Earth System Sciences*, 20(1), 175–191. <https://doi.org/10.5194/hess-20-175-2016>
- González, J., & Valdés, J. B. (2006). New drought frequency index: Definition and comparative performance analysis. *Water Resources Research*, 42(11). <https://doi.org/10.1029/2005WR004308>
- Guttman, N. B. (1999). ACCEPTING THE STANDARDIZED PRECIPITATION INDEX: A CALCULATION ALGORITHM <sup>1</sup>. *JAWRA Journal of the American Water Resources Association*, 35(2), 311–322. <https://doi.org/10.1111/j.1752-1688.1999.tb03592.x>
- Hanel, M., Rakovec, O., Markonis, Y., Máca, P., Samaniego, L., Kyselý, J., & Kumar, R. (2018). Revisiting the recent European droughts from a long-term perspective. *Scientific Reports*, 8(1), 9499. <https://doi.org/10.1038/s41598-018-27464-4>
- Hayes, M., Svoboda, M., Wall, N., & Widhalm, M. (2011). The Lincoln Declaration on Drought Indices: Universal Meteorological Drought Index Recommended. *Bulletin of the American Meteorological Society*, 92(4), 485–488. <https://doi.org/10.1175/2010BAMS3103.1>
- Hundecha, Y., Arheimer, B., Berg, P., Capell, R., Musuuza, J., Pechlivanidis, I., & Photiadou, C. (2020). Effect of model calibration strategy on climate projections of hydrological indicators at a continental scale. *Climatic Change*, 163(3), 1287–1306. <https://doi.org/10.1007/s10584-020-02874-4>
- Hundecha, Y., Arheimer, B., Donnelly, C., & Pechlivanidis, I. (2016). A regional parameter estimation scheme for a pan-European multi-



- basin model. *Journal of Hydrology: Regional Studies*, 6, 90–111.  
<https://doi.org/10.1016/j.ejrh.2016.04.002>
- Ionita, M., & Nagavciuc, V. (2021). *Changes in drought features at European level over the last 120 years* [Preprint]. *Atmospheric, Meteorological and Climatological Hazards*.  
<https://doi.org/10.5194/nhess-2021-46>
- Leemis, L. M., & McQueston, J. T. (2008). Univariate Distribution Relationships. *The American Statistician*, 62(1), 45–53.  
<https://doi.org/10.1198/000313008X270448>
- Lindström, G., Pers, C., Rosberg, J., Strömqvist, J., & Arheimer, B. (2010). Development and testing of the HYPE (Hydrological Predictions for the Environment) water quality model for different spatial scales. *Hydrology Research*, 41(3–4), 295–319.  
<https://doi.org/10.2166/nh.2010.007>
- Lloyd-Hughes, B., & Saunders, M. A. (2002). A drought climatology for Europe. *International Journal of Climatology*, 22(13), 1571–1592.  
<https://doi.org/10.1002/joc.846>
- Mamoon, A. A., & Rahman, A. (2019). Uncertainty analysis in design rainfall estimation due to limited data length: A case study in Qatar. In *Extreme Hydrology and Climate Variability* (pp. 37–45). Elsevier.  
<https://doi.org/10.1016/B978-0-12-815998-9.00004-X>
- Marcos García, P., & Pulido-Velazquez, M. (2019). *Sistema de ayuda a la decisión para la adaptación y gestión de sistemas de recursos hídricos en un contexto de alta incertidumbre. Aplicación a la cuenca del Júcar*. [Universitat Politècnica de València].  
<https://doi.org/10.4995/Thesis/10251/125702>
- McKee, T. B., Doesken, N. J., & Kleist, J. (1993). *THE RELATIONSHIP OF DROUGHT FREQUENCY AND DURATION TO TIME SCALES*. 6.
- Mishra, A. K., & Singh, V. P. (2010). A review of drought concepts. *Journal of Hydrology*, 391(1–2), 202–216.  
<https://doi.org/10.1016/j.jhydrol.2010.07.012>
- Mishra, A. K., & Singh, V. P. (2011). Drought modeling – A review. *Journal of Hydrology*, 403(1–2), 157–175.  
<https://doi.org/10.1016/j.jhydrol.2011.03.049>
- Mohd Razali, N. T., & Bee Wah, Y. (2011). Power Comparisons of Shapiro-Wilk, Kolmogorov-Smirnov, Lilliefors and Anderson-Darling Tests. *Journal of Statistical Modeling and Analytics*, 13.



- Nalbantis, I., & Tsakiris, G. (2009). Assessment of Hydrological Drought Revisited. *Water Resources Management*, 23(5), 881–897. <https://doi.org/10.1007/s11269-008-9305-1>
- National Drought Mitigation Center, NOAA, & USDA. (2022). *What is the USDM | U.S. Drought Monitor* [U.S. Drought Monitor]. U.S. Drought Monitor. <https://droughtmonitor.unl.edu/About/WhatistheUSDM.aspx>
- Neuhäuser, M. (2011). Wilcoxon–Mann–Whitney Test. In M. Lovric (Ed.), *International Encyclopedia of Statistical Science* (pp. 1656–1658). Springer. [https://doi.org/10.1007/978-3-642-04898-2\\_615](https://doi.org/10.1007/978-3-642-04898-2_615)
- Newman, J. E., & Oliver, J. E. (2005). Palmer Index/Palmer Drought Severity Index. In J. E. Oliver (Ed.), *Encyclopedia of World Climatology* (pp. 571–573). Springer Netherlands. [https://doi.org/10.1007/1-4020-3266-8\\_159](https://doi.org/10.1007/1-4020-3266-8_159)
- O'Connor, A., Modarres, M., & Mosleh, A. (2016). *Probability Distributions Used in Reliability Engineering*. 215.
- Organización Meteorológica Mundial, (OMM), & Asociación Mundial para el Agua. (2016). *Manual de indicadores e índices de sequía*. 54.
- Owens, R., & Hewson, T. (2018). *The ECMWF Integrated Forecasting System—IFS - Forecast User Guide*. He ECMWF Integrated Forecasting System - IFS - Forecast User Guide. <https://confluence.ecmwf.int/display/FUG/2+The+ECMWF+Integrated+Forecasting+System+-+IFS#id-2TheECMWFIntegratedForecastingSystemIFS-IntegratedForecastingSystem-IFS>
- Palmer, W. C. (1965). *Meteorological\_Drought*. [https://www.droughtmanagement.info/literature/USWB\\_Meteorological\\_Drought\\_1965.pdf](https://www.droughtmanagement.info/literature/USWB_Meteorological_Drought_1965.pdf)
- Palop-Donat, C., Paredes-Arquiola, J., & Andreu, J. (2020). Optimización del indicador de escasez en la cuenca del río Júcar. *Ingeniería del agua*, 24(2), 129. <https://doi.org/10.4995/ia.2020.12275>
- Pechlivanidis, I. G., Crochemore, L., Rosberg, J., & Bosshard, T. (2020). What Are the Key Drivers Controlling the Quality of Seasonal Streamflow Forecasts? *Water Resources Research*, 56(6). <https://doi.org/10.1029/2019WR026987>
- Peña-Gallardo, M., Gámiz-Fortís, S. R., Castro-Diez, Y., & Esteban-Parra, M. J. (2016). Análisis comparativo de índices de sequía en Andalucía





- para el periodo 1901-2012. *Cuadernos de Investigación Geográfica*, 42(1), 67. <https://doi.org/10.18172/cig.2946>
- Podestá, G. (2020). *Descripción de índices para el monitoreo de sequía meteorológica implementados por el Centro Regional del Clima para el Sur de América del Sur*. 26.
- Profillidis, V. A., & Botzoris, G. N. (2019). Trend Projection and Time Series Methods. In *Modeling of Transport Demand* (pp. 225–270). Elsevier. <https://doi.org/10.1016/B978-0-12-811513-8.00006-6>
- Prudhomme, C. (2021). *EFAS hydrological model—Copernicus Services—ECMWF*. Confluence. <https://confluence.ecmwf.int/display/COPSRV/EFAS+hydrological+model>
- Salas, J. D. (Ed.). (1980). *Applied modeling of hydrologic time series*. Water Resources Publications.
- Samaniego, L. (2021). *DROUGHT MODELING AND FORECASTING from Local to Global Scales*. Universitat Potsdam. [https://publishup.uni-potsdam.de/frontdoor/index/index/start/2/rows/10/sortfield/score/sortorder/desc/searchtype/advanced/abstract/arid+desert+drought+dryland+botswana+namibia+kenya+sudan+ethiopia+egypt+siria+iran+iraq+afghanistan+algeria+tunisia+morocco+senegal+mali+burkina+sahel+sahara+chad++/abstractmodifier/contains\\_any/yearfq/2021/nav/next/docId/50803](https://publishup.uni-potsdam.de/frontdoor/index/index/start/2/rows/10/sortfield/score/sortorder/desc/searchtype/advanced/abstract/arid+desert+drought+dryland+botswana+namibia+kenya+sudan+ethiopia+egypt+siria+iran+iraq+afghanistan+algeria+tunisia+morocco+senegal+mali+burkina+sahel+sahara+chad++/abstractmodifier/contains_any/yearfq/2021/nav/next/docId/50803)
- Shukla, S., & Wood, A. W. (2008). Use of a standardized runoff index for characterizing hydrologic drought. *Geophysical Research Letters*, 35(2), L02405. <https://doi.org/10.1029/2007GL032487>
- SMHI. (2020). *HYPE Model Documentation*. <http://www.smhi.net/hype/wiki/doku.php>
- Stagge, J. H., Tallaksen, L. M., Gudmundsson, L., Van Loon, A. F., & Stahl, K. (2015). Candidate Distributions for Climatological Drought Indices (SPI and SPEI). *International Journal of Climatology*, 35(13), 4027–4040. <https://doi.org/10.1002/joc.4267>
- Sutanto, S. J., & Van Lanen, H. A. J. (2022). Catchment memory explains hydrological drought forecast performance. *Scientific Reports*, 12(1), 2689. <https://doi.org/10.1038/s41598-022-06553-5>
- van Ginkel, M., & Biradar, C. (2021). Drought Early Warning in Agri-Food Systems. *Climate*, 9(9), 134. <https://doi.org/10.3390/cli9090134>



- Van Loon, A. F., & Laaha, G. (2015). Hydrological drought severity explained by climate and catchment characteristics. *Journal of Hydrology*, 526, 3–14. <https://doi.org/10.1016/j.jhydrol.2014.10.059>
- Van Loon, A. F., & Van Lanen, H. A. J. (2012). A process-based typology of hydrological drought. *Hydrology and Earth System Sciences*, 16(7), 1915–1946. <https://doi.org/10.5194/hess-16-1915-2012>
- Vega-Viviescas, C., & Rodríguez, E. A. (2018). *Incertidumbre en el Cálculo del índice de Sequías-SPI en la macrocuenca Magdalena-Cauca, Colombia*. 8.
- Vicente Serrano, S. (2021). The evolution of climatic drought studies in Spain over the last few decades. *Geographicalia*, 73, 7–34. [https://doi.org/10.26754/ojs\\_geoph/geoph.2021734640](https://doi.org/10.26754/ojs_geoph/geoph.2021734640)
- Vicente-Serrano, S. M., & Beguería, S. (2016). Comment on ‘Candidate distributions for climatological drought indices (SPI and SPEI)’ by James H. Stagge *et al.*: COMMENT ON JAMES H. STAGGE *ET AL.* *International Journal of Climatology*, 36(4), 2120–2131. <https://doi.org/10.1002/joc.4474>
- Vicente-Serrano, S. M., Beguería, S., & López-Moreno, J. I. (2010). A Multiscalar Drought Index Sensitive to Global Warming: The Standardized Precipitation Evapotranspiration Index. *Journal of Climate*, 23(7), 1696–1718. <https://doi.org/10.1175/2009JCLI2909.1>
- Vicente-Serrano, S. M., & Beguería-Portugués, S. (2003). Estimating extreme dry-spell risk in the middle Ebro valley (northeastern Spain): A comparative analysis of partial duration series with a general Pareto distribution and annual maxima series with a Gumbel distribution. *International Journal of Climatology*, 23(9), 1103–1118. <https://doi.org/10.1002/joc.934>
- Vicente-Serrano, S. M., López-Moreno, J. I., Beguería, S., Lorenzo-Lacruz, J., Azorin-Molina, C., & Morán-Tejeda, E. (2012). Accurate Computation of a Streamflow Drought Index. *Journal of Hydrologic Engineering*, 17(2), 318–332. [https://doi.org/10.1061/\(ASCE\)HE.1943-5584.0000433](https://doi.org/10.1061/(ASCE)HE.1943-5584.0000433)
- Vicente-Serrano, S. M., Miralles, D. G., Domínguez-Castro, F., Azorin-Molina, C., El Kenawy, A., McVicar, T. R., Tomás-Burguera, M., Beguería, S., Maneta, M., & Peña-Gallardo, M. (2018). Global Assessment of the Standardized Evapotranspiration Deficit Index (SEDI) for Drought Analysis and Monitoring. *Journal of Climate*, 31(14), 5371–5393. <https://doi.org/10.1175/JCLI-D-17-0775.1>



- Weingartner, R., Blöschl, G., Hannah, D. M., Marks, D. G., Parajka, J., Pearson, C. S., Rogger, M., Salinas, J. L., Sauquet, E., Srikanthan, R., Thompson, S. E., & Viglione, A. (2013). Prediction of seasonal runoff in ungauged basins. In A. Viglione, G. Blöschl, H. Savenije, M. Sivapalan, & T. Wagener (Eds.), *Runoff Prediction in Ungauged Basins: Synthesis across Processes, Places and Scales* (pp. 102–134). Cambridge University Press.  
<https://doi.org/10.1017/CBO9781139235761.009>
- Wetterhall, F. (2021). *European Flood Awareness System—Copernicus Services—ECMWF Confluence*. Wetterhall.  
<https://confluence.ecmwf.int/display/COPSRV/European+Flood+A+wareness+System>
- World Meteorological Organization. (2012). *Standardized precipitation index user guide*.
- World Meteorological Organization (WMO). (2011). *WMO Publications on Weather, Climate, and Agriculture*. WMO.
- Wu, H., Svoboda, M. D., Hayes, M. J., Wilhite, D. A., & Wen, F. (2007). Appropriate application of the standardized precipitation index in arid locations and dry seasons. *International Journal of Climatology*, 27(1), 65–79. <https://doi.org/10.1002/joc.1371>
- Wu, W., Emerton, R., Duan, Q., Wood, A. W., Wetterhall, F., & Robertson, D. E. (2020). Ensemble flood forecasting: Current status and future opportunities. *WIREs Water*, 7(3), e1432. <https://doi.org/10.1002/wat2.1432>
- Xu, Y., Wang, L., Ross, K., Liu, C., & Berry, K. (2018). Standardized Soil Moisture Index for Drought Monitoring Based on Soil Moisture Active Passive Observations and 36 Years of North American Land Data Assimilation System Data: A Case Study in the Southeast United States. *Remote Sensing*, 10(3), 301. <https://doi.org/10.3390/rs10020301>