

Máster Universitario en Ciencias Actuariales y Financieras
2022-2023

Trabajo Fin de Máster

“Índice Climático Actuarial Español.
Una aplicación a los seguros paramétricos”

Rubén Royo Ruiz

Tutor/es

José Miguel Rodríguez-Pardo del Castillo

Jesús Simón del Potro

Madrid, junio de 2023

DETECCIÓN DEL PLAGIO

La Universidad utiliza el programa **Turnitin Feedback Studio** para comparar la originalidad del trabajo entregado por cada estudiante con millones de recursos electrónicos y detecta aquellas partes del texto copiadas y pegadas. Copiar o plagiar en un TFM es considerado una **Falta Grave**, y puede conllevar la expulsión definitiva de la Universidad.



Esta obra se encuentra sujeta a la licencia Creative Commons **Reconocimiento – No Comercial – Sin Obra Derivada**

Esta tesis es propiedad del autor. No está permitida la reproducción total o parcial de este documento sin mencionar su fuente. El contenido de este documento es de exclusiva responsabilidad del autor, quien declara que no se ha incurrido en plagio y que la totalidad de referencias a otros autores han sido expresadas en el texto.

En caso de obtener una calificación igual o superior a 9.0 (Sobresaliente), autorizo la publicación de este trabajo en el centro de Documentación de la Fundación Mapfre.

Si, autorizo su publicación.

No, desestimo su publicación.

Firmado:

ÍNDICE

1. INTRODUCCIÓN	7
2. CAMBIO CLIMÁTICO	9
2.1 Revisión Literatura	9
2.1.1 Temperatura.....	9
2.1.2 Nivel del Mar.....	11
2.1.3 Acidificación del Mar.....	11
2.1.4 Nivel de hielo polar	11
2.2 Siniestralidad Cat-Nat.	11
3. INDICE CLIMÁTICO ACTUARIAL.....	13
3.1.1 Propósito.....	13
3.1.2 Datos.....	13
3.1.2.1 GHCN-Daily	14
3.1.2.2 GHCNDEX.....	14
3.1.2.3 HadEX2	14
3.1.2.4 Reanálisis	14
3.1.2.5 Permanent Service for Mean Sea Level.....	15
Alternativas.....	15
3.1.2.5.1 TerraClimate.....	15
3.1.2.5.2 E-OBS-CLIMDEX	15
3.1.3 Metodología.....	15
3.1.3.1 Temperatura	19
3.1.3.1.1 Cálidas	19
3.1.3.1.2 Frías	28
3.1.3.2 Precipitación	34
3.1.3.3 Sequía.....	41
3.1.3.4 Viento.....	43
3.1.3.5 Nivel del mar	48
3.1.4 Combinación de Variables.....	54
3.1.5 Combinación de índices	55
4. APLICACIÓN AL SEGURO PARAMÉTRICO	57
4.1 Fundamento del Seguro Paramétrico	57
4.2 Posibles Seguros Paramétricos vinculados al índice Climático Actuarial.	58
4.2.1 Cobertura para protección de arrecifes de coral.	58

4.2.1.1	Casos reales.....	58
4.2.1.2	Costal Risk Index (CRI)	60
4.2.2	Pólizas para la protección de industrias pesqueras.....	61
4.2.3	Pólizas para la protección ante rachas de viento anómalos.	61
5.	INDICE DE RIESGO CLIMÁTICO ACTUARIAL.....	63
5.1	Metodología	63
5.1.1	Propósito.....	63
5.1.2	Dato	63
5.1.3	Modelización	63
5.1.3.1	Modelo A	64
5.1.3.2	Modelo B	64
5.2	Resultados y Conclusión	65
6.	LIMITACIONES INDICE CLIMATICO ACTUARIAL.	67
7.	CONCLUSIONES.....	68
8.	REFERENCIAS.....	69
9.	ANEXO	74
9.1	Anexo Figuras	74
9.2	Anexo Warming Stirpes	77
9.3	Anexo Código	80

ÍNDICE FIGURAS

Figura 2.1 Climate stripes Madrid.....	10
Figura 2.2 Climate stripes Málaga.....	10
Figura 3.1.1. Anomalía invernal Soria	17
Figura 3.1.2 Anomalía Primavera Soria	18
Figura 3.1.3 Anomalía Estival Soria	18
Figura 3.1.4 Anomalía Otoñal Soria.....	19
Figura 3.2.1. Umbrales diarios temperatura máxima Soria.....	21
Figura 3.2.2. Frecuencia anual temperaturas cálidas anómalas.....	24
Figura 3.2.3. Frecuencia mensual temperaturas cálidas.	25
Figura 3.2.4. Distribución temperaturas máximas mensuales peínsula ibérica.....	26
Figura 3.2.5. Anomalía estandarizada y media movil	28
Figura 3.3.1. Umbrales diarios temperaturas cálidas y frías P90 y P10.....	29
Figura 3.3.2. Frecuencia anual temperaturas frías anómalas.....	31
Figura 3.3.3. Frecuencia mensual temperaturas frías.	32
Figura 3.3.4. Distribución temperaturas mínimas diarias por año de la peínsula ibérica	33
Figura 3.3.5. Anomalía estandarizada temperatura frías.	34
Figura 3.4.1. Base de datos netCDF para la variable t.	35
Figura 3.4.2. Ilustración base de datos GHCNDEX.....	35
Figura 3.4.3. Precipitación máxima acumulada por 5 días consecutivos mes enero.....	36
Figura 3.4.4. Precipitación máxima mensual en 5 días consecutivos Central Park	37
Figura 3.4.5. Anomalías precipitación.....	38
Figura 3.4.6. Precipitación máxima mensual en 5 días consecutivos Soria.	39
Figura 3.4.7. Distribución precipitación máxima acumulada en 5 días mensual Soria...	40
Figura 3.4.8. Anomalía estandarizada Soria.....	40
Figura 3.5.1. Número de días consecutivos sin precipitación	42
Figura 3.5.2. Anomalía estandarizada máximo número de días consecutivos sin precipitación.....	43
Figura 3.6.1. Umbral mensual wind power	47
Figura 3.6.2. Anomalía estandarizada viento.	47
Figura 3.7.1 Nivel del mar San Fernandina Beach, FLO	49
Figura 3.7.2. Medias nivel del mar por meses.....	50
Figura 3.7.3. Anomalía nivel del mar.....	51
Figura 3.7.4. Anomalía estandarizada nivel del mar San Fernandina Beach, FLO.....	52
Figura 3.7.5. Media nivel del mar por meses Málaga	53

Figura 3.8.1. ACI Soria	55
Figura 3.9.1. ACI agregado	56
Figura 4.2.1. Flujograma del análisis exposición al riesgo	59
Figura 4.2.2. Nivel del mar costas Hawai.....	60

ÍNDICE TABLAS

Tabla 2.1. Impacto eventos cat-nat para el grupo Mapfre	12
Tabla 2.2. Impacto eventos cat-nat y man-made globales.....	12
Tabla 3.1.1. Identificador estación metereológica, mareógrafo y ubicación.....	16
Tabla 3.2.2. Media y desviación típica de la frecuencia de temperaturas anómalas altas.	24
Tabla 3.2.3. Media y desviación típica de la frecuencia de observaciones por encima del umbral para temperaturas anómalas bajas.	24
Tabla 3.3.1. Media y desviación típica de la frecuencia de temperaturas frías extremadamente frías por meses.....	31
Tabla 3.3.2. Media y desviación típica de la frecuencia de temperaturas frías extremadamente cálidas por meses.....	31
Tabla 3.4.1. Media y desviación típica precipitación máxima acumulada en 5 días consecutivos por meses.....	37
Tabla 3.4.2. Media y desviación típica precipitación máxima acumulada en 5 días consecutivos por meses.....	38
Tabla 3.4.3. Media y desviación típica precipitación máxima acumulada en 5 días consecutivos por meses.....	39
Tabla 3.5.1. Media y desviación típica de la frecuencia de temperaturas frías extremadamente cálidas por meses.....	42
Tabla 3.6.1. Ranking rachas de viento máxima Soria	45
Tabla 3.6.2. Escala Saffir-Simpson	45
Tabla 3.6.3. Umbral mensual variable viento.....	47
Tabla 3.7.1. Media y desviación típica nivel del mar.....	49
Tabla 3.7.2 media y desviación típica nivel del mar originales.	50
Tabla 3.7.3. Media y desviación típica nivel del mar Málaga.....	52
Tabla 4.3.1. Ejemplo condiciones pago STORM.....	62
Tabla 5.1.1. Resumen de los parámetros estimados significativos al 90%.	65
Tabla 5.1.2. Pérdidas estimadas ACRI, observadas y ajustadas a la exposición por región	66

1. INTRODUCCIÓN

En las últimas décadas el cambio climático está tomando una mayor consideración y efecto en diferentes ámbitos, alcanzando aspectos desde la cesta de la compra de la población general hasta a la toma de decisiones por parte responsables de la gerencia una entidad. Y es que, los efectos de este efecto son cada vez más visibles, observándose con una mayor frecuencia eventos extremos denominados en la jerga aseguradora como Cat-Nat.

Entendiendo el concepto de “cambio climático” como el cambio en el largo plazo del patrón histórico de eventos climáticos tales como temperatura mínima y máxima, precipitaciones, niveles del mar entre otros muchos indicadores. Una primera pregunta que podría surgir es, qué o quién está detrás de este efecto. Y es que, es algo natural. Sin embargo, el ser humano es uno, si no, el principal contribuyente del aceleramiento en las últimas décadas.

Este evento afecta a prácticamente todo aquello que pudiéramos imaginar desde los precios de la cesta de alimentos básica, a la calidad del género, a la esperanza de vida del ser humano o de cualquier especie animal que se pueda imaginar, a la construcción de una vivienda o incluso a los negocios más tradicionales, y como no, a las entidades aseguradoras y reaseguradoras.

Como bien es conocido, las entidades aseguradoras y reaseguradora son una parte fundamental del desarrollo económico y social, y por tanto del interés general. En su papel de mitigación del riesgo es evidente la irrupción del cambio climático. Es por esto que se encuentran desarrollando acciones que incentiven actividades que no contribuyesen o que en su defecto contribuyesen en menor medida al cambio climático como el desarrollo de productos sostenibles.

Algunos de ellos ya los encontramos en el mercado, como los seguros de ramos personales de auto “Pay As You Drive”, en el que, en base al estilo de conducción, busca premiar al asegurado cuya conducción sea más eficiente. También encontramos otros más enfocados a la industria energética, como pueden ser seguros de proyectos energéticos, que les protegen de litigaciones y efectos patrimoniales desde el diseño hasta la distribución de la energía a la red. Incluso se puede encontrar productos que incentivan la adquisición y uso de tecnología que permita hacer una trazabilidad del estado, ya sea en aspectos como la temperatura, del producto durante la distribución del producto, lo que permite un menor desperdicio de alimentos.

Otros elementos en los que las entidades aseguradoras y reaseguradoras ya trabajan en relación con el cambio climático son la exploración de nuevos nichos de negocio como los seguros paramétricos, o el desarrollo de índices climáticos que en una primera fase permitiese hacer seguimiento de este fenómeno, temas en los que vamos a centrar nuestra atención durante el desarrollo de esta investigación.

Los seguros paramétricos y su comercialización comienzan a ser habitual desde 1990 por parte de la reaseguradora SwissRe, en esencia, no difiere mucho de un seguro tradicional pues ambos se han visto beneficiados por el boom del dato. Un seguro paramétrico descansa sobre un índice o parámetro, el cual cuando dicho índice o parámetro alcanza o es alcanzado, esto activa el pago de la indemnización.

En la definición anterior se menciona la necesidad de un índice que en función del evento asegurado variará de uno u otro, pero siendo en la actualidad la mayoría de índole

climática. Pudiendo ser de especial interés para el desarrollo de estimaciones y seguimiento interno la existencia de un índice que otorgue a los actuarios de información relevante sobre eventos extremos climáticos que pudiesen activar este tipo de seguros.

El Actuarial Climate Index surge en 2016 fruto de la colaboración de varias sociedades actuariales. El Actuarial Climate Index, en adelante ACI, nace con la intención de conocer mejor el efecto del cambio climático realizado. Por su reciente publicación no se ha encontrado mucha literatura acerca de su potencial uso como predictor de variables actuariales.

Este trabajo está dividido como se comenta a continuación. En la sección 2 se dedica un espacio al cambio climático, desarrollando el concepto y escenarios para diferentes variables climáticas o indicadores naturales que se están viendo alterados con respecto a lo que se denominaba clima tradicional. En la sección 3 se introduce el índice climático actuarial y se procede a desarrollar su cálculo para una de las seis ciudades españolas cuyos índices serán utilizados como proxy de un índice climático actuarial para España. La Sección 4 da una introducción al seguro paramétrico siendo la construcción de estos una posible aplicación de este tipo de índices climático-actuariales y se describen algunos de los seguros paramétricos más curiosos describiendo el proceso de evaluación de un riesgo climático y como finalmente mediante este tipo de seguros se mitiga el riesgo. La sección 5, describe el índice de riesgo climático actuarial, donde los autores del índice climático actuarial buscan mediante alguna de las variables del índice climático actuarial la relación con una variable actuarial, en su caso, la siniestralidad para el negocio de property. Finalmente, en la sección 6, se extrae una conclusión de estos tipos de índices y sus limitaciones.

Durante el presente documento el objetivo principal será replicar las variables que han sido utilizadas para la construcción del ACI Español siguiendo la metodología original utilizando dato de España, teniendo así una aproximación de cuanto ha variado el clima en término de frecuencia e intensidad.

2. CAMBIO CLIMÁTICO

2.1 Revisión Literatura

En las recientes décadas el foco mediático está cada vez apuntando más y más a cambio climático, y es que, desde la revolución industrial la actividad intensiva en gases de efecto invernadero ha provocado que se observen cambios en diferentes variables meteorológicas tales como la temperatura, precipitación, cantidad de hielo en los polos, nivel del mar, etc.

Se van a enumerar, a continuación, efectos del cambio climático en diferentes variables meteorológicas.

2.1.1 Temperatura

Spencer Glendon de Probable Futures, en el Milliman Climate Resilience Forum (2021), presenta que tradicionalmente el clima no era estable, pero era “perfecto”, por el balance entre temperaturas y polos que permitan que toda área fuese habitable para el ser humano. Sin embargo, desde la época post industrial se viene avisando de posibles cambios en el clima y es cierto, los veranos se están extendiendo y la primaveras y otoño se están acortando.

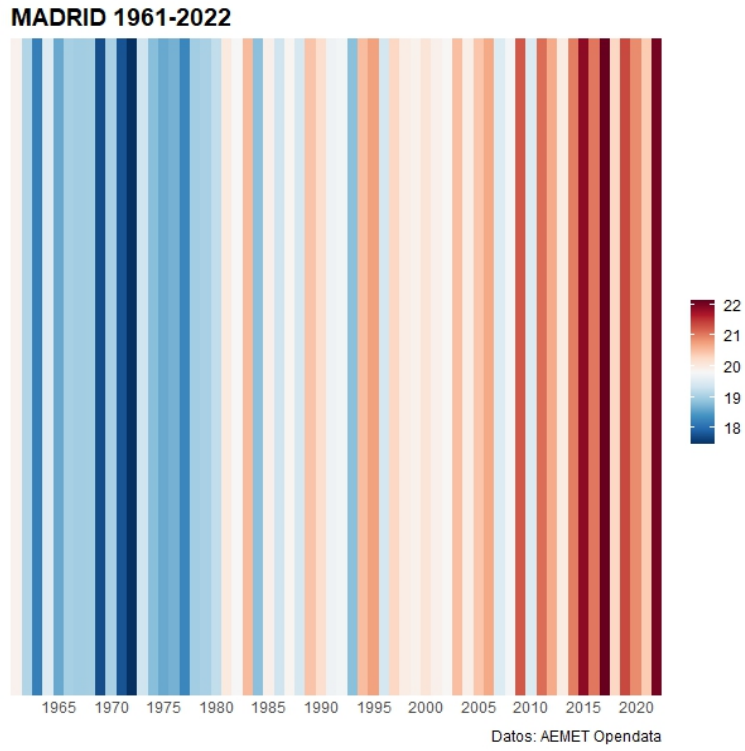
También muestra como el número de semanas por encima de 35° en las últimas décadas del siglo XX para España se encontraba en cifras de en torno a 2-3 semanas. Dicho esto, realiza un análisis “what if” si se incrementa la temperatura para cada día 2° y el resultado es que, para España, que no es una de las regiones que más llaman la atención de todo el planeta pasa a estar en torno a 3-4-5 semanas con temperaturas máximas por encima de los 35°. (Milliman Climate Resilience Forum, 2021)

A su vez, un incremento de la temperatura de 2° supone una probabilidad de experimentar episodios de sequía anual en prácticamente la totalidad del territorio español de entorno al 40-60% de probabilidad, mientras que para finales del siglo XX este % lo cifra entorno al 0-20% de probabilidad de experimentar episodios de sequía al año. (Milliman Climate Resilience Forum, 2021)

De igual manera hace el análisis, pero para temperaturas por debajo de los 0°, siendo los resultados de un total de entre 1-2 semanas para el territorio español por debajo de los cero grados. Mientras que, para las últimas décadas del siglo XX, la mayoría del territorio nacional se situaba en torno a las 3-4 semanas con temperaturas mínimas por debajo de los cero grados. (Milliman Climate Resilience Forum, 2021)

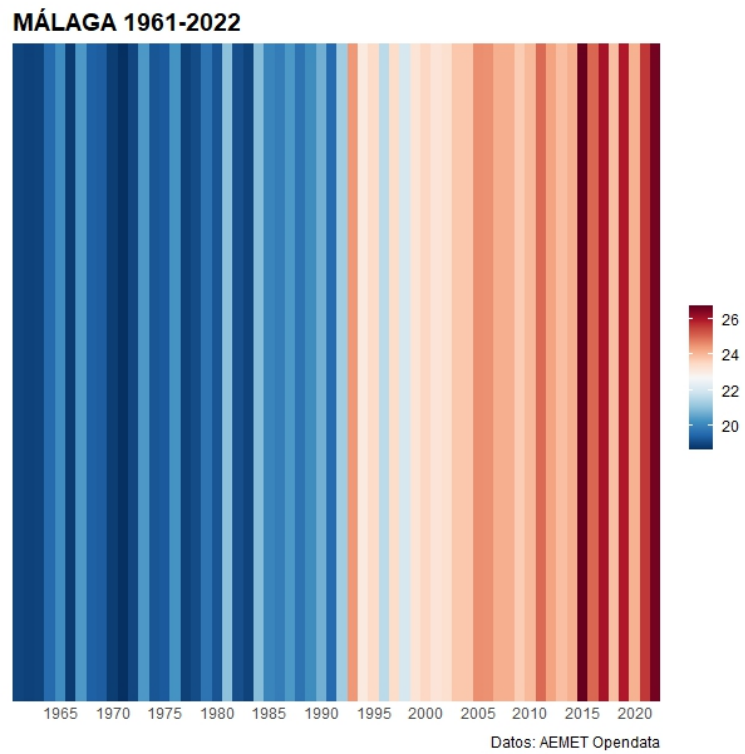
Con el fin de demostrar el cambio desde que se ha experimentado en las temperaturas máximas a lo largo de los últimos años en las ciudades que se ha propuesto calcular el índice climático actuarial, se ha decidido realizar la visualización originalmente creada por Hawkins (2018). En la que se muestra de manera muy intuitiva en franjas el cambio relativo de la temperatura del año en concreto con respecto a la media. De tal manera que para el caso que se va a mostrar a continuación, colores azules representarían años en los que la temperatura máxima media del año ha sido menos cálida que la media. Mientras que las franjas rojas representarían años en los que la temperatura máxima media del año ha sido más cálida que la media de las temperaturas máximas.

Figura 2.1 Climate stripes Madrid.



Fuente: Elaboración propia.

Figura 2.2 Climate stripes Málaga.



Fuente: Elaboración propia.

Observándose como desde 1990 las temperaturas máximas medias son cada vez mayores con respecto a la media de las temperaturas máximas en el periodo indicado.

Este efecto que se observa en Madrid y Málaga se repite de manera sistemática para el resto de las ciudades, pudiéndose observar la representación en el anexo.

2.1.2 Nivel del Mar

El cambio climático provoca cambios en diferentes aspectos como venimos comentando, estos a su vez, afectan a glaciares como vamos a comentar más adelante pero también a las precipitaciones, cambios que “están provocando un incremento de en torno a 0,2 metros en el nivel del mar con respecto a 1900”. (Intergovernmental Panel on Climate Change [IPCC], 2021).

Este cambio en los niveles del mar puede provocar graves siniestros en zonas costeras que pueden verse anegadas, con un impacto estimado de más de un trillón de dólares anuales a partir de 2050. (Hallegatte, 2013)

2.1.3 Acidificación del Mar

“El mar absorbe el 30% del dióxido de carbono que es emitido a la atmosfera”. (Joint Forum on Actuarial Regulation [JFAR], 2022).

En este proceso de absorción, el agua y el dióxido se combinan generando ácido carbónico que genera que el océano sea ácido, sin embargo, “en los últimos 200 años el ph de la superficie del océano se ha incrementado en 0,1 unidades de pH, lo que representa un 30% de incremento en la acidez del océano”. (Lindsey y Scott, 2022)

Esto puede provocar que ciertas especies marinas se vean afectadas y existan dos posibilidades, una que tengan que emigrar a otros ecosistemas o dos que directamente comiencen a desaparecer como puede ser el caso de los arrecifes de coral.

2.1.4 Nivel de hielo polar

Actualmente “los niveles de hielo en los polos en verano se están situando en niveles mínimos desde hace 100 años”. (JFAR,2022). Estimándose que “el polo ártico estará sin hielo entorno al 2050”. (IPCC, 2021). Este evento provocaría que “las temperaturas se incrementasen de manera excepcional en áreas de altas latitudes”. (JFAR, 2022). Así como un “incremento de los niveles del mar de en torno a 13,5 mm \pm 1,3 mm” (IPCC, 2021).

Por otro lado, la tendencia para la Antártida no es tan clara como en el ártico, sin embargo, el hecho de que se derritiera podría provocar “un incremento del nivel del mar de en torno a 7,4 mm \pm 1,5 mm” (IPCC, 2021).

2.2 Siniestralidad Cat-Nat.

Pero todo lo mencionado hasta ahora son elementos en mayor o menor medida que no aportan una dimensión del impacto que se generan en las entidades que se encargan de mitigar el riesgo.

Así pues, vamos a recorrer para una de las entidades aseguradoras internacionales más grandes las cuentas anuales de los últimos años, para recoger, cifras de eventos relacionados.

Para el Grupo MAPFRE:

Tabla 2.1. Impacto eventos Cat-Nat para el grupo MAPFRE

Dato en millones de EUR.

Año	Ubicación	Breve descripción	Impacto
2022	Brasil y Paraguay	Sequía Cuenca Paraná	67,2
2021	Europa	Tormenta Bern	92,8
2020	Puerto Rico	Terremotos	39,3
2019	Japón	Tifón Faxai	106,5

Fuente: MAPFRE^{1 2 3}.

A escala mundial Swiss Re, ofrece el siguiente dato para 2021, siendo el impacto de catástrofes naturales aseguradas de 105 billones americanos de dólares para 2021 y de 90 para 2020, suponiendo un incremento porcentual anual de un 17%. (Swiss Re, 2021a).

Y para los últimos años se muestra la siguiente tabla:

Tabla 2.2. Impacto eventos Cat-Nat y Man-Made globales.

Dato en billones americanos de USD.

Año	2014	2015	2016	2017	2018	2019	2020	2021
Cat-Nat	33,1	31,7	52,3	154,1	89,8	56,7	89,6	105
Man-Made	8,0	10,8	9,7	7,2	9,2	9,8	9,6	7,3

Fuente: Swiss Re⁴

Siendo el dato de 2017 explicado por los huracanes Harvey, Irma y Maria.

Como se puede ver los eventos atmosféricos ya suponen un gran impacto en las cuentas anuales de las entidades.

¹ <https://www.mapfre.com/media/accionistas/2022/cuentas-anuales-e-informe-gestion-individuales-2022.pdf>

² <https://www.mapfre.com/media/accionistas/2022/05-informe-anual-consolidado-2021.pdf>

³ https://www.mapfre.com/statics/juntasgenerales/2020/Cuentas_anuales_e_informes_gestion_consolidados.pdf

⁴ <https://www.swissre.com/media/press-release/nr-20211214-sigma-full-year-2021-preliminary-natcat-loss-estimates.html>

3. INDICE CLIMÁTICO ACTUARIAL

3.1.1 Propósito

El Actuarial Climate Index, ACI en adelante es publicado en 2016 como resultado de colaboración de las siguientes academias, asociaciones e institutos actuariales: Canadian Institute of Actuaries, Casual Actuarial Society, Society of Actuaries y American Academies of Actuaries. A su vez, colaboró en su creación Solterra Solution dando apoyo y bagaje en el campo climático.

El ACI nace como una “herramienta educacional que pretende ser de ayuda a actuarios, instituciones públicas e incluso al público general”. (American Academy of Actuaries et al., 2018a). La construcción de este no sigue el fin de ofrecer proyecciones del clima, si no, una herramienta que permita hacer, en una primera fase, un seguimiento del clima, dar una visión objetiva del cambio climático en las pasadas décadas, en otras palabras, cuantificar el cambio climático realizado y desarrollar una primera rama de investigación Climático-Actuarial.

El ACI se centra en dar respuesta a la frecuencia de los eventos extremos, por ello incorpora en el cálculo del mismo temperaturas extremas ya sean cálidas o frías, episodios de precipitación extremos como sequías o lluvias torrenciales, vientos fuertes y el nivel del mar. Y es que, en estos episodios, es donde la severidad se ve fuertemente incrementada, distorsionando la que a priori podría ser una función de distribución de severidad, a posteriori, se descubre que la distribución cuenta con una cola extraordinariamente larga incurriendo las entidades aseguradoras y reaseguradoras en tensiones de capital. Siendo por este motivo, especialmente interesante, para la práctica actuarial.

El ACI originalmente es aplicable solamente a Norteamérica, no obstante, se han desarrollado índices similares para otros continentes e incluso países, el Institute and Faculty of Actuaries (2015), ya constituyó un grupo de trabajo para evaluar la viabilidad de crear un símil europeo al ya existente americano. Otro caso, ya existente, es el Australian Actuarial Climate Index creado por el Actuaries Institute of Australia y que presenta una alta similitud al ACI. También se conoce la propuesta de desarrollo de metodologías similares para la India, Turquía, China o España donde se encuentra actualmente trabajando el Instituto de Actuarios Españoles y cuya presentación de resultados preliminares se realizó en junio de 2023.

3.1.2 Datos

El dato mediante el cual se determina el ACI y que permite que sea científicamente robusto requiere una serie de características.

1. Extensión territorial, preferiblemente global.
2. En cuanto a la resolución, preferiblemente con el mayor grado de resolución y ofrecido en cuadrículas geográficas
3. Cobertura temporal suficiente, en el caso del ACI requiere información desde 1960 hasta la actualidad, permitiendo tomar un periodo de referencia lo suficientemente extenso para hacer un análisis estadístico robusto.
4. Frecuencia del dato, preferiblemente, diario para poder capturar mejor los eventos extremos. Como mínimo mensuales.
5. Frecuencia de actualización mínima en cada estación. (Trimestral)

6. El dato han de ser observaciones reales, no admite valores resultantes de modelos.
7. Requiere de un amplio número de variables más allá de temperatura y precipitación.

A continuación, se presentarán las bases de datos que se han considerado por los diferentes grupos de trabajo para determinar el ACI.

3.1.2.1 GHCN-Daily

Se trata de una base de datos cuyo origen proviene de las distintas estaciones meteorológicas. De alcance global con formato de cuadrícula. Dispone de registros desde enero de 1950 hasta noviembre de 2022.

Un mayor detalle de la base de datos puede encontrarse en Menne et al. (2012)

3.1.2.2 GHCNDEX

Base de datos derivada de GHCN-Daily, que contiene 27 variables climáticas.

La granularidad del dato cuenta con una cuadrícula de (2,5° de longitud por 2,5° de latitud), aproximadamente, unos 278,3 km por 277,5 km, esto supone una escala relativamente superior al nivel de estación meteorológica que es lo que comúnmente se usa en investigación climática.

Actualmente encontramos registros desde 1961 hasta 2022, y esta es actualizada cada varios meses, con una frecuencia menos que el GHCN-Daily.

Un mayor detalle de la base de datos puede encontrarte en Donat et al. (2013a).

3.1.2.3 HadEX2

HadEX2 es una base de dato global análoga a GHCNDEX, incluye como fuente de datos la gran mayoría de las mismas estaciones meteorológicas, pero teniendo un mayor peso estaciones meteorológicas con un control de calidad del dato.

Esta base de datos tiene una mayor resolución contando con una cuadrícula de 3,75° de longitud por 2,5° de latitud.

Un mayor detalle de la base de datos puede encontrarte en Donat et al. (2013b).

3.1.2.4 Reanálisis

Los reanálisis climáticos ofrecen dato global, con formato en cuadrícula que incluyen un mayor número de variables climáticas que las que podrían encontrarse en una base de datos estándar y que en ocasiones se utilizan como alternativas a una base de dato real. Los reanálisis climáticos combinan observaciones pasadas con modelos generando series temporales consistentes de diferentes variables climáticas.

Un mayor detalle de la base de datos de la reanálisis puede encontrarse en Kalnay, et al. (1996)

3.1.2.5 Permanent Service for Mean Sea Level

Se trata de un repositorio del dato mensual para el nivel medio del mar, el dato es extraído de las estaciones mareográficas. De este repositorio se extrae la variable del índice Nivel del mar.

La descripción completa de la base de dato se puede encontrar en Permanent Service for Mean Sea Level (2023) y un mayor detalle sobre la construcción de la base de datos se puede encontrar en Holgate et al. (2013)

Alternativas

En la revisión de la literatura se han encontrado propuestas de posibles bases de datos alternativas que podrían cumplir las características mencionadas al inicio de este apartado.

3.1.2.5.1 TerraClimate

Se trata de una base de datos global cuya cuadrícula es de 4km por 4 km lo que supone una excepcional resolución en comparación con los 278 km por 277,5 km de la base de dato GHCDNX, sin embargo, presenta dato mensual, aunque contiene variables similares a las que son necesarias para la construcción del ACI.

Un mayor detalle puede encontrarse en Abatzoglou et al. (2018).

Como se ha mencionado el ACI original se ha planteado para otros continentes y países, como Europa o China, para el caso europeo, IFoA (2015), propone varias bases de datos que en mayor o menor medida cumplen con las características descritas anteriormente, tres de las cuatro alternativas que se proponen son las mismas que las propuestas para Norteamérica, pues como se ha descrito se tratan de bases de datos globales y estas son GHCNDEX, HadEX2 y Reanálisis.

Sin embargo, hay una base de datos alternativa y que puede ser de gran utilidad debido a sus características. E-OBS-CLIMDEX, se trata de una base de datos con las siguientes características, horizonte temporal desde 1950 hasta 2022, con dato diario y actualización mensual. A su vez se trata de una base de datos con formato de cuadrícula con una resolución de $0.25^{\circ} \times 0.25^{\circ}$ o $0.5^{\circ} \times 0.5^{\circ}$.

3.1.2.5.2 E-OBS-CLIMDEX

Contempla las siguientes variables, temperatura media diaria, temperatura máxima y mínima diaria (TN/TX), precipitación acumulada diaria y presión media del mar.

Un mayor dato de este puede encontrarse en Cornes et al. (2018)

3.1.3 Metodología

El Índice Climático Actuarial, ACI por sus siglas en inglés, está creado a partir de seis variables, cada una de esta variable cuenta con una serie temporal de extensa cobertura espacial y temporal como se han comentado anteriormente. Las variables involucradas con las siguientes:

- Frecuencia de las temperaturas cálidas por encima del percentil 90. (T90)

- Frecuencia de las temperaturas frías por debajo del percentil 10. (T10)
- Precipitación acumulada máxima en los últimos 5 días. (P)
- Máximo número de días secos consecutivos. (D)
- Frecuencia de rachas de viento por encima del percentil 90. (W)
- Cambios en el nivel del mar. (S)

En cuanto a las series temporales para cada una de estas variables, se cuenta con dato diario desde 1920 procedente de la red de estaciones meteorológicas españolas. A este dato se puede acceder desde AEMET, (2023a).

Ante la heterogeneidad de las diferentes variables involucradas se procederá a calcular las anomalías estandarizadas, para el periodo de referencia que se entenderá como tal un horizonte temporal de 30 años concretamente desde 1961 al 1990, justificando como fecha de origen 1961 como consecuencia una mayor calidad y cantidad en los registros de la base de dato. (AAA et al. 2018b)

La métrica seleccionada clave, es una media móvil, con una ventana temporal de 5 años, argumentando los autores originales del ACI que el tamaño de la ventana temporal ha sido seleccionado de manera cuidadosa buscando la minimización del ruido generado por las series temporales. (AAA et al. 2018b)

Siguiendo la metodología de AAA et al. (2018a, 2018c) el ACI presente se ha creado para cada una de las 6 ciudades españolas tal y como originalmente hacen, pero por regiones, dividiendo Norteamérica en doce regiones.

Dentro del objetivo de este trabajo de investigación se busca tratar de replicar la metodología que se menciona en los documentos oficiales del ACI, utilizando dato diario para España.

El cálculo se ha realizado para 6 ciudades española, de las 274 estaciones que AEMET dispone en territorio español.

Tabla 3.1.1. Identificador estación metereológica, mareógrafo y ubicación.

Localización	Id estación AEMET	Id mareógrafo PSMSL
Barcelona, Fabra	0200E	1811
Bilbao, Aeropuerto	1082	1806
Madrid, Retiro	3195	N/A
Málaga, Aeropuerto	6155A	1810
Sevilla	5783	N/A
Soria	2030	N/A

Fuente: Elaboración propia.

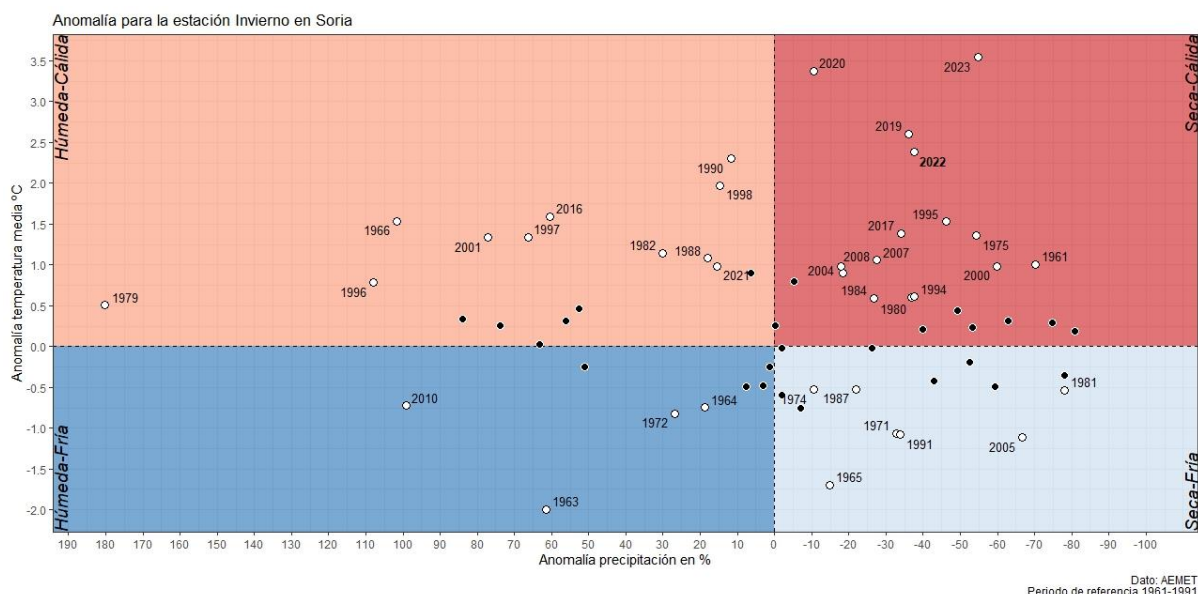
A continuación, se describirá la construcción de cada una de las variables involucradas, para una de las ciudades, encontrándose los resultados del resto de ciudades en el correspondiente anexo, pero antes, se procederá a hacer un análisis para cada estación de

los diferentes años de los que se dispone de registros para la estación española de Soria con el fin de establecer un primer contacto con el clima experimentado en la región seleccionada.

Para ello se ha procedido a catalogar por estación a cada año en cuatro posibles regiones ,en función de si el valor de la temperatura media y precipitación media para esa estación de ese año en concreto está por encima o debajo de la media del periodo de referencia, siendo las posibles regiones: Estación: Húmeda-Cálida, en caso de que tanto la media tanto de temperatura media como de precipitación de la estación para el año en cuestión sea superior a la media de estas dos variables para el periodo de referencia. Húmeda-Fría, En caso de que la media para la estación seleccionada de la precipitación sea superior a la media del periodo de referencia, sin embargo, esto no se cumpla para la variable temperatura. Seca-Fría, región en la que caerán aquellos años cuya estación seleccionada presente una temperatura media por debajo de la media para el periodo de referencia y que a su vez la media de la precipitación sea también menor que la media para el periodo de referencia. Seca-Cálida, que será la región en la que caerán los años para los que la estación seleccionada presente una precipitación media por debajo de la media para el periodo de referencia y una temperatura media por encima de la media del periodo de referencia.


Los resultados para Soria que ha sido la estación seleccionada han sido los siguientes.

Figura 3.1.1. Anomalía invernal Soria




Fuente: Elaboración propia.

Figura 3.1.2 Anomalía primaveral Soria




Fuente: Elaboración propia.

Figura 3.1.3 Anomalía estival Soria



Fuente: Elaboración propia.

Figura 3.1.4 Anomalía otoñal Soria



Fuente: Elaboración propia.

Pudiendo observarse como coinciden en la región superior derecha mayoritariamente años a partir del 2000, lo que ofrece una intuición de que el clima está siendo claramente más caluroso puesto que la mayoría de las observaciones se sitúan en la región norte del gráfico y en un mayor porcentaje las observaciones tienden a estar en la región derecha lo que denota una menor cantidad de precipitaciones con respecto al periodo de referencia.

3.1.3.1 Temperatura

Las variables relacionadas con la temperatura originalmente son determinadas basándose en la base de datos GHCN-Daily, de igual manera para el objetivo que se sigue en este trabajo se toman la frecuencia de valores mensuales de las temperaturas diarias máximas y mínimas por encima del percentil 90 y por debajo del percentil 10, tomando como percentiles de referencia los obtenidos de la variables TX10, TX90 (temperaturas máximas diarias) y TN10, TN90 (temperaturas mínimas diarias) de la base de datos Opendata de AEMET.

3.1.3.1.1 Cálidas

Una de las variables más relevantes a la hora de construir el ACI son las temperaturas cálidas. El ACI considera temperaturas cálidas en base a unos umbrales que se fija para cada día del año, tomando el percentil 90 de las temperaturas de 5 días, pero en este trabajo se ha decidió también hacerlo para 25 días, siendo así para el día central estimado el umbral.

Es de vital importancia analizar el comportamiento de las temperaturas cálidas durante todo el año, pues sus efectos pueden ser completamente diferentes de la época en la que se diesen dicho fenómeno.

Si se piensa en unas temperaturas cálidas en el periodo estival los efectos podrían variar desde incrementos de mortalidad a alteraciones en las migraciones de ciertas especies, evento que ya este pasado periodo estival experimentó Europa provocando un incremento

en la mortalidad de diferentes países como Alemania o España, donde en este último, el sistema de monitorización de la mortalidad diaria o MoMo ha registrado 1.893 fallecimientos atribuibles a la temperatura. (Ministerio para la transición ecológica y el reto demográfico, 2022). Por otro lado, en un supuesto de una ola de calor en primavera, otoño o invierno podría alterar las migraciones de ciertas especies, así como podría afectar a los periodos de floración, polinización y afectar a los rendimientos agrícolas.

Nótese que el componente tiene en cuenta temperaturas cálidas “máximas” y temperaturas cálidas “mínimas” y no temperaturas diurnas y nocturnas. Y es que normalmente las temperaturas cálidas máximas alcanzadas por el día y las temperaturas cálidas mínimas son alcanzadas durante la noche, pero no necesariamente. Por este motivo el componente hace referencia a temperaturas máximas y mínimas en vez de temperaturas diurnas y nocturnas.

Para el caso español, se ha usado la base de datos AEMET Opendata que proporciona una serie de dato diario de temperaturas máximas que será la utilizada para esta primera variable relacionada con la temperatura, en el caso de Soria, existen observaciones estables desde los años 1941 hasta 2023.

La base de datos seleccionada, en concreto, la generada por la estación meteorológica de Soria, situada en el siguiente par de coordenadas Latitud, Longitud (41,775, -02,483) presenta alguna laguna de registros ⁵especialmente en 2011.

Otra característica que presenta el dato es la ausencia de registros en los años previos a 1960, si es cierto que de manera idónea estaríamos interesados en disponer de registros los 5 años previos para realizar las correspondientes medias móviles para los mismos años de periodo de referencia, pero esto no es un impedimento mayor para descartar la base de datos.

En cuanto al tratamiento del dato se ha decidido eliminar los días 29 de febrero de la serie para así poder tener series homogéneas de 365 días para cada año.

También se han desechado los registros del 2023, por ser el año en el que se encuentra desarrollándose este trabajo final de máster y encontrarse incompleto el año.

Una vez limpiado y preparado y visualmente analizado el dato sin identificar valores inconsistentes se ha procedido a calcular los umbrales que permitirán determinar cuándo una temperatura observada debe considerarse anómala o no.

Según los autores AAA et al. (2018c), los umbrales se han determinado en base al periodo de referencia (1961-1990). Para la construcción del ICA en este trabajo, se ha seguido la misma metodología citada.

Zhang et al. (2005), citado en AAA et al. (2018c), propone dos técnicas para determinar los umbrales de temperatura, para ambas metodologías el autor propone dos tamaños de muestras para determinar el umbral siendo estos 5 días o 25 días, en nuestro caso se ha realizado el cálculo para ambas ventanas temporales, la primera metodología (SD) consiste en, para el día del año para el cual se va a determinar el umbral, se toman las observaciones del día en cuestión y los otros 4 días involucrados serán aquellos que se encuentre en una secuencia de 5 días. Para hacerlo más intuitivo, se va a desarrollar un ejemplo. Por ejemplo, si se desea estimar el umbral para el día 1 de enero, se tomarán las

⁵ Para el tratamiento de los datos ausentes se ha decidió estimarlos mediante interpolación lineal.

observaciones del uno de enero para cada uno de los años del periodo de referencias. Y a su vez se tomarán las observaciones para los días 6, 11, 361 y 356 del año para los años del periodo de referencia y se procederá a calcular el percentil seleccionado para la construcción del umbral.


La segunda metodología (CD) consiste en tomar las observaciones para los días consecutivos anteriores y posteriores en función de número de días que se elija ventana temporal siempre encontrándose el día en cuestión para el cual se está calculando el umbral en la posición central.

Tras esto se calcula el percentil seleccionado para las observaciones dentro de la ventana temporal seleccionada.

Durante el proyecto se desarrolló la subrutina que ordenase el dato y eligiese los valores para la columna en la cual se recoja la probabilidad seleccionada, puesto que todas las series tienen el mismo número de observaciones, pero se ha optado por usar la función implementada en Excel.

Los resultados de aplicar la anterior metodología para los datos obtenidos por la estación meteorológica de Soria.

Figura 3.2.1. Umbrales diarios temperatura máxima Soria



Fuente: Elaboración propia.

Pudiéndose observar que para los meses invernales se encuentra el umbral para el percentil 90 se encuentra en torno a los 12 grados de media, para posteriormente progresivamente incrementarse con la llegada de la primavera para llegar en los meses estivales a los máximos que rozan los 35 grados.

Para el percentil 10 el umbral se comporta de manera similar.

En el gráfico se puede observar dos líneas que prácticamente se superponen una con otra, estos umbrales, se diferencian en el tamaño de la ventana temporal seleccionada, siendo la que presenta menos suavidad la calculada tomando 5 días y la que presenta un comportamiento más suave el resultante de utilizar 25 días como ventana temporal.

Una vez determinado el umbral ya se puede continuar a la siguiente fase, para determinar la variable que se utilizará en la construcción del ACI.

A continuación, disponiendo de dato diario para cada año hasta el 2022, se ha procedido a generar una función lógica o hit-or-miss que indique si cada día del año supera o no el umbral 90 de las temperaturas máximas para cada día en cuestión.

Fórmula 3.2.1. Hit-or-Miss para temperaturas cálidas extremadamente altas

$$\psi_{max}(i, j, k) = \begin{cases} 1, & T_{max}(i, j, k) < Threshold_{p90}(i) \\ 0, & T_{max}(i, j, k) > Threshold_{p90}(i) \end{cases}$$

Siendo:

$i=1,2,3...365$

$j= 1$ (Enero), 2 (Febrero), ..., 12(Diciembre)

$k = 1961, 1962 \dots 2022.$

Como anteriormente se ha comentado se ha decidido prescindir de las observaciones del 29 de febrero para los años bisiestos, de tal manera que se consigue una distribución homogénea de los días por mes para cada año.

Definido el número de días para cada mes y aplicando la función hit-or-miss anteriormente presentada se procede a calcular la frecuencia de temperaturas anómalas o que superan el umbral para el año y por mes.

Para esto será necesario:

Fórmula 3.2.2. Frecuencia anual temperaturas cálidas extremadamente altas.

$$FT ANN: Warm_{max}(k) = \frac{\sum_{i=1}^{365} \psi_{max}(i, k)}{365}$$

Siendo:

$k=1961,1962...2022$

Fórmula 3.2.3. Frecuencia mensual temperaturas cálidas extremadamente altas.

$$FT: Warm_{max}(j, k) = \frac{\sum_{i=1}^{n^{\circ} \text{ días mes } j} \psi_{max}(i, j, k)}{n^{\circ} \text{ días mes } j}$$

Siendo:

$j= 1, 2, \dots 12$

$k=1961, 1962, \dots 2022$

El promedio para $FT ANN: Warm_{max}$ durante el periodo de referencia se alcanza un 9,62% de días al año que se podrían considerar como temperaturas cálidas anómalas por exceso, esta constante será recogida por la variable $\mu_{ref} FT: warm(j)$ por igual para cada j . Siendo $j =$ Enero, Febrero...Diciembre. Esta variable será utilizada posteriormente para calcular las anomalías estandarizadas.

Sin embargo, para el periodo outsample (1991-2022) se observa que la media para $FT ANN: Warm_{max}$ es un 14,15% observándose un incremento sustancial en el % de días que podrían considerarse con una temperatura máxima anómala.

De igual manera se ha realizado el mismo proceso para el umbral creado a partir del percentil 10 de las observaciones dentro de la ventana temporal de 5 días para los años del periodo de referencia. Pudiéndose entender este umbral como el límite mínimo que determinará si una temperatura cálida es anormalmente baja.

Como el objetivo del índice es la creación de una herramienta que permita monitorizar la frecuencia con la que eventos climáticos adversos tienen lugar, se ha realizado un análisis similar pero que recoja la frecuencia de temperaturas cálidas anormalmente bajas, para ello se ha modificado la función hit-or-miss,

Fórmula 3.2.4. Hit-or-Miss para temperaturas cálidas extremadamente bajas.

$$\psi_{min}(i, j, k) = \begin{cases} 1, & T_{max}(i, j, k) < Threshold_{P10}(i) \\ 0, & T_{max}(i, j, k) > Threshold_{P10}(i) \end{cases}$$

Siendo:

$i = 1, 2, 3 \dots 365$

$j = 1$ (Enero), 2 (Febrero), ... 12 (Diciembre)

$k = 1961, 1962 \dots 2022$.

De igual manera,

Fórmula 3.2.5. Frecuencia mensual temperaturas calidas extremadamente bajas.

$$FT: Warm_{min}(j, k) = \frac{\sum_{i=1}^{n^{\circ} \text{ días mes } j} \psi_{min}(i, j, k)}{n^{\circ} \text{ días mes } j}$$

Siendo:

$j = 1, 2, \dots 12$

$K = 1961, 1962, \dots 2022$

Una vez calculada la frecuencia con para cada mes en el intervalo de tiempo 1961-1991 se procederá a calcula la esperanza de las frecuencias para cada mes, así como su desviación típica, tanto para los casos de temperaturas cálidas anómalas por exceso como por defecto de temperatura.

Tabla 3.2.2. Media y desviación típica de la frecuencia de temperaturas anómalas altas.

Dato en % y para el periodo de referencia.

Momento	Ene	Feb	Mar	Abr	May	Jun	Jul	Ago	Sep	Oct	Nov	Dic
Media	9,46	9,64	10,11	9,89	10,11	9,89	9,35	9,25	9,00	9,68	9,44	9,57
Desv. tpca.	11,8	11,2	13,5	11,8	12,5	12,1	7,8	8,4	12,0	12,9	11,1	10,5

Fuente: Elaboración propia.


Tabla 3.2.3. Media y desviación típica de la frecuencia de observaciones por encima del umbral para temperaturas anómalas bajas.

Dato en % y para el periodo de referencia.

Momento	Ene	Feb	Mar	Abr	May	Jun	Jul	Ago	Sep	Oct	Nov	Dic
Media	9,68	9,29	9,14	9,11	9,68	9,67	9,35	9,35	10,01	9,78	9,33	9,25
Desv. tpca.	9,43	8,47	9,21	7,83	10,02	9,60	9,52	8,14	11,45	10,11	7,80	7,93

Fuente: Elaboración propia.

Figura 3.2.2. Frecuencia anual temperaturas cálidas anómalas.




Fuente: Elaboración propia.

Mediante los umbrales presentados anteriormente y utilizando la fórmula 2.1. calculamos la frecuencia de temperaturas cálidas, pudiéndose observar cómo durante el periodo outsample (1991-2022) la frecuencia con la que se están superando los umbrales de temperaturas cálidas por exceso es bastante superior a lo que se podía observar en el periodo de referencia. A su vez, la frecuencia con la que observan temperaturas cálidas

anómalas por encima de los umbrales para ser temperaturas extraordinariamente bajas se comporta al unísono.

La línea gris indica lo que en líneas generales estamos comentando, puesto que, para el periodo de referencia, arrojando que, durante el periodo de referencia, en promedio se experimentaron un 9,62% de días con temperaturas máximas extremas. Sin embargo, para el periodo de proyección este % se dispara hasta el 14,15%, confirmando que durante los años (1991-2022) se ha observado un mayor número, en promedio, de eventos extremos.

Figura 3.2.3. Frecuencia mensual temperaturas cálidas.



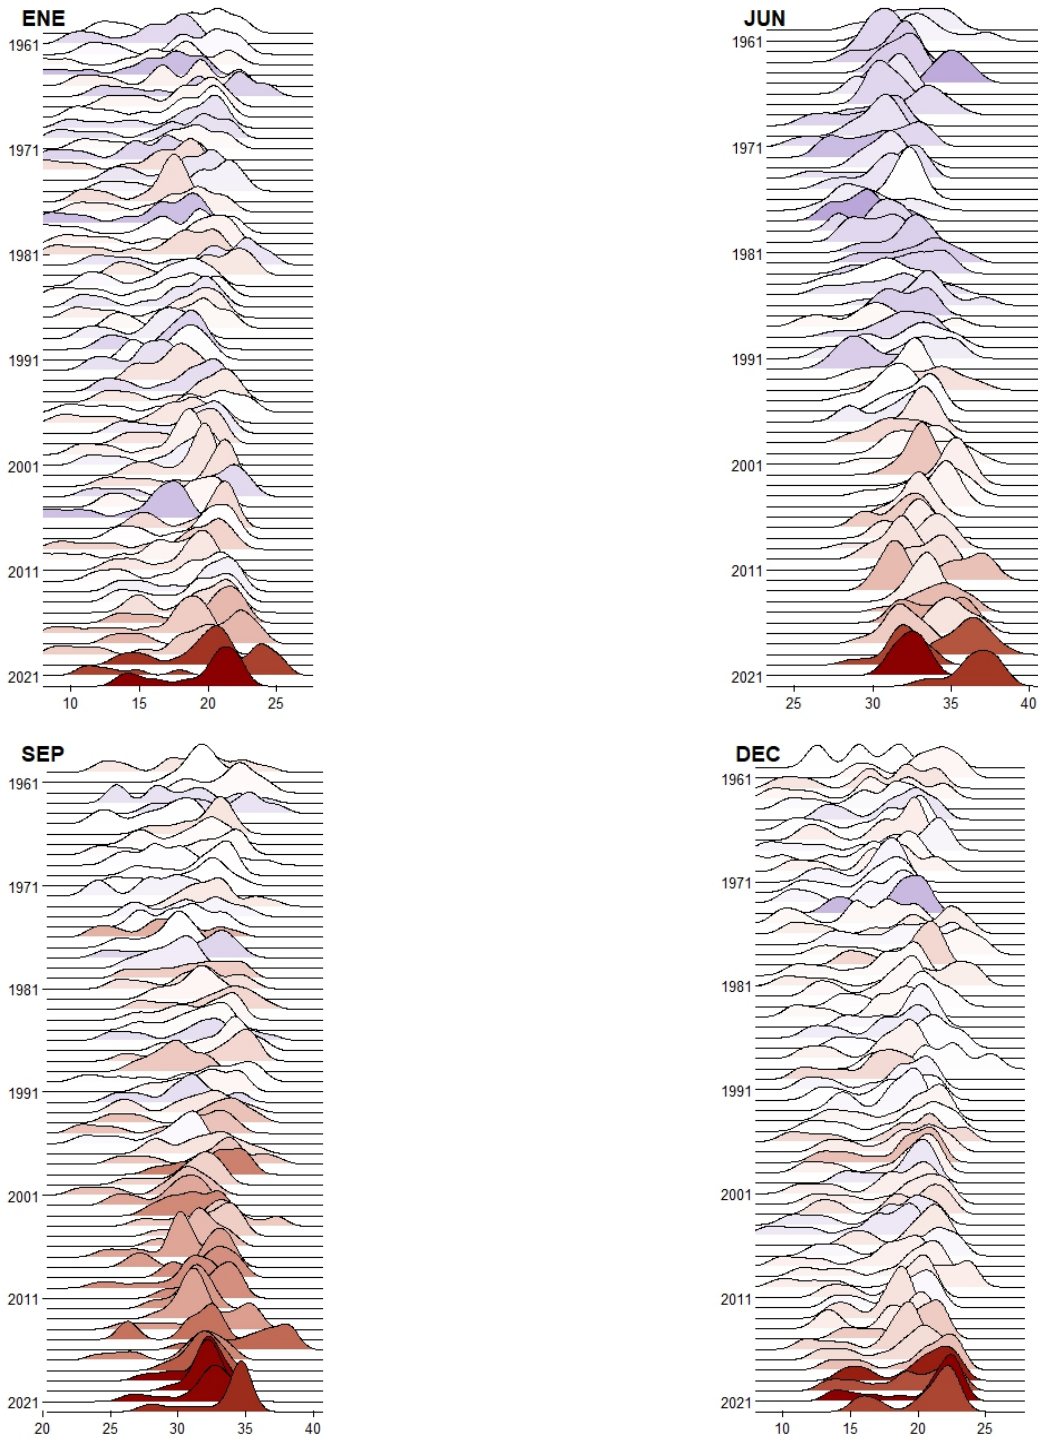
Fuente: Elaboración propia.

En el gráfico anterior se observa una creciente tendencia del % de días que al mes se experimentan temperaturas extraordinariamente cálidas, llegándose a encontrar a partir del 1991, meses con una alta frecuencia que el 50% de sus días superaron el umbral. E incluso a alcanzarse valores del 80% como es el caso de febrero de 2019 que aparentemente fue catalogado como un mes de récord por la AEMET. (AEMET, 2019). y Julio de 2022 que coincide con la pasada ola de calor experimentada en todo el territorio español y que se proclamó como el mes más cálido en España desde que hay registros. (Ministerio para la transición ecológica y el reto demográfico, 2022).

También se encuentran noticias relacionadas que confirman esta tendencia en los últimos años, así pues, encontramos que “siete de los diez años más cálidos se han registrado en la última década.” (AEMET, 2022b). O “el verano y el otoño más cálidos convierten a 2022 en el año más cálido en España desde 1961.” (Ministerio para la transición ecológica y el reto demográfico, 2023)

Tomando la base de dato GHCND y solamente las coordenadas en lo que al territorio español refiere se ha procedido a hacer un análisis de la distribución de las temperaturas máximas de un mes en concreto en el horizonte temporal 1960-2022, de tal manera que se han graficado las diferentes distribuciones para cada año de manera consecutiva, lo que nos permite de una manera visual, percibir alguna tendencia en nivel o en términos de simetría y curtosis. A su vez se han pintado las distribuciones en una escala de colores que van de azul a blanco y rojo, estos colores representan como se encuentra el percentil 50 con respecto a un punto que se ha sido seleccionado tomando como referencia 1960.

Figura 3.2.4. Distribución temperaturas máximas mensuales peínsula ibérica.



Fuente: Elaboración propia.

Como se puede observar la gama pasa de colores blancos a colores más rojizos especialmente desde 1991, lo que nos trasmite que desde 1991 la distribución de las temperaturas máximas cada vez se desplaza más hacia la derecha. Lo que confirma que temperaturas para ciertos meses que anteriormente no era frecuente alcanzar ahora a priori van a comenzar a incrementar su probabilidad.

Con el fin de calcular las anomalías estandarizadas el ACI requiere el cálculo de las siguientes variables que permiten reducir el ruido de las observaciones.

Fórmula 3.2.6. Media frecuencia temperaturas cálidas anómalas

$$FT: warm(j, k) = \frac{[FT: warm_{max}(j, k) + FT: warm_{min}(j, k)]}{2}$$

Siendo:

j= 1,2, ...12

k=1961, 1962, ...2022

Fórmula 3.2.7. Desviación típica temperaturas cálidas anómalas

$$\sigma_{ref} FT: warm(j) = \frac{[\sigma_{ref} FT: warm(j) + \sigma_{ref} FT: warm(j)]}{2}$$

Siendo:

j= 1,2, ...12

Fórmula 3.2.8. Anomalías estandarizadas variable temperaturas cálidas

$$FT: warm_{std}(j, k) = \frac{[FT: warm(j, k) - \mu_{ref} FT: warm(j)]}{\sigma_{ref} FT: warm(j)}$$


Siendo:

j= 1,2, ...12

k=1961, 1962, ...2022

$\mu_{ref} FT: warm(j) = 9,62\%$

Figura 3.2.5. Anomalía estandarizada y media móvil



Fuente: Elaboración propia.

En la anterior figura, donde se presenta la anomalía estandarizada, se observa un cambio de tendencia de la media móvil desde el 2001, pudiéndose observar como el nivel de la media móvil se va incrementando durante las siguientes décadas.

Alcanzando para lo últimos años valores de entorno al 0.6, lo que implica que las temperaturas máximas de media en los últimos 5 años está 0.6 desviaciones típicas por encima con respecto al periodo de referencia, esto implica que existe mayor probabilidad de experimentar eventos anómalos en cuanto a lo que a temperaturas anómalas cálidas se refiere, con un impacto directo en la mortalidad, que a nivel nacional presenta una correlación entre mortalidad en olas de calor y temperaturas de en torno a un 27%. (Crisóstomo Mazaira, 2022)

3.1.3.1.2 Frías

Otra medida utilizada en la construcción del índice son las temperaturas frías, cabe esperar que como consecuencia del calentamiento global se observase una reducción de la frecuencia de temperaturas frías. Lo que implicaría que la distribución de la temperatura esté desplazada hacia la derecha.

El ACI incorpora las temperaturas frías como el porcentaje de temperaturas mensuales por debajo del percentil 10 mediante el umbral fijado para un determinado día del calendario durante el periodo de referencia.

La ausencia de temperaturas frías provoca cambios en las floraciones, rendimientos agrícolas, alteración periodos de alergias, nuevas alergias, entre otros.

La metodología seguida es igual que la seguida para las temperaturas cálidas, con esta segunda variable lo que se trata es de capturar la cola izquierda de las temperaturas, por lo que ahora en vez que realizar el cálculo sobre las temperaturas máximas se toman las temperaturas mínimas.

Nuevamente el dato presenta alguna deficiencia, pero no lo suficiente importante como para descartar el uso de esta base de datos, estas deficiencias nuevamente son registros perdidos durante la serie y un vacío de registros más serio durante 2011, que quizás se deba a alguna tarea de mantenimiento o incluso reemplazo de la estación.


Viendo los resultados anteriores para las temperaturas cálidas, a priori, es de esperar una disminución de la frecuencia con la que se vienen dando temperaturas frías anómalas, lo que corroboraría los síntomas del calentamiento global y es por este motivo por el cual esta variable en la construcción del índice se incorpora con signo negativo, pues una menor frecuencia de eventos anómalos en cuanto a temperaturas frías se considera un incremento del riesgo.

Para poder llegar a estas conclusiones primero se debe determinar los umbrales para los cuales se considerará como una temperatura fría anómala.

La metodología no difiere de la seguida para las temperaturas cálida y que sigue los procedimientos de Zhang et al., (2005).

A continuación, se mostrarán gráficamente los umbrales para cada día del año basado en los percentiles 90 y 10 para las temperaturas mínimas del periodo 1961-1991 y variando el tamaño de la ventana temporal, 5 o 25 días.

Figura 3.3.1. Umbrales diarios temperaturas cálidas y frías P90 Y P10



Fuente: Elaboración propia.

Como se puede observar los umbrales de temperaturas cálidas y frías llegan incluso a superponerse.

En cuanto a los umbrales para las temperaturas frías, observamos nuevamente una tendencia creciente durante la primavera hasta llegar a su máximo en torno a junio y agosto. Para los meses invernales encontramos el umbral en torno a los -5° , en otras palabras, esperamos que el 90% de los días de invierno las temperaturas mínimas no sean inferiores a -5° .

Determinados los umbrales para cada día del año para las temperaturas frías en base al periodo de referencia (1961-1990) se procede a calcular la frecuencia con la que se ha experimentado temperaturas frías extremadamente frías.

Para ello, nuevamente se ha implementado una función hit-or-miss que indique si estamos ante una temperatura fría anómala.

Como se viene vislumbrando, el objetivo del índice es monitorizar la frecuencia con la que se vienen observando eventos anómalos, en esta variable lo que se desea es monitorizar es la frecuencia con la que se han estado dando eventos de temperaturas frías con cifras muy bajas u altas.

Para determinar si estamos ante una temperatura fría extremadamente fría se ha utilizado:

Fórmula 3.3.1. Hit-or-Miss para temperaturas frías extremadamente frías

$$\psi'_{min}(i, j, k) = \begin{cases} 1, & T_{min}(i, j, k) < Threshold_{P10}(i) \\ 0, & T_{min}(i, j, k) > Threshold_{P10}(i) \end{cases}$$

Mientras que para las temperaturas frías extremadamente calurosas.

Fórmula 3.3.2. Hit-or-Miss para temperaturas frías extremadamente cálidas

$$\psi'_{max}(i, j, k) = \begin{cases} 1, & T_{min}(i, j, k) > Threshold_{P90}(i) \\ 0, & T_{min}(i, j, k) < Threshold_{P90}(i) \end{cases}$$

Al igual que para la variable de temperaturas cálidas se ha procedido a calcular las frecuencias de estos eventos para ello se han seguido la misma metodología que para la variable temperaturas cálidas.

Fórmula 3.3.3. Frecuencia anual temperaturas frías extremadamente frías

$$FT ANN: Warm_{min}(k) = \frac{\sum_{i=1}^{365} \psi'_{min}(i, k)}{365}$$

Fórmula 3.3.4. Frecuencia mensual temperaturas frías extremadamente frías

$$FT: Cold_{min}(j, k) = \frac{\sum_{i=1}^{n^{\circ} \text{ días mes } j} \psi'_{min}(i, j, k)}{n^{\circ} \text{ días mes } j}$$

Fórmula 3.3.5. Frecuencia mensual temperaturas frías extremadamente cálidas

$$FT: Cold_{max}(j, k) = \frac{\sum_{i=1}^{n^{\circ} \text{ días mes } j} \psi'_{max}(i, j, k)}{n^{\circ} \text{ días mes } j}$$

Para esta variable también se han calculado las medias y desviaciones típicas de las frecuencias de eventos extremos para cada mes en el periodo (1961-1990)

Tabla 3.3.1. Media y Desviación típica de la frecuencia de temperaturas frías extremadamente frías por meses.

Dato en %.

Momento	Ene	Feb	Mar	Abr	May	Jun	Jul	Ago	Sep	Oct	Nov	Dic
Media	9,67	9,40	8,81	9,22	8,70	9,67	9,35	8,92	9,67	9,35	9,33	9,35
Desv. tpca.	10,0	11,1	5,92	8,56	6,89	8,11	8,18	7,46	10,5	9,96	8,27	10,8

Fuente: Elaboración propia.


Tabla 3.3.2. Media y Desviación típica de la frecuencia de temperaturas frías extremadamente cálidas por meses.

Dato en %.

Momento	Ene	Feb	Mar	Abr	May	Jun	Jul	Ago	Sep	Oct	Nov	Dic
Media	9,14	9,40	9,67	9,22	9,13	9,11	9,67	9,56	9,00	9,03	9,11	9,35
Desv. tpca.	10,3	10,4	8,92	9,41	9,62	8,70	8,47	7,31	8,49	7,15	11,47	12,3


Fuente: Elaboración propia.

Figura 3.3.2. Frecuencia anual temperaturas frías anómalas



Fuente: Elaboración propia.

Figura 3.3.3. Frecuencia mensual temperaturas frías.



Fuente: Elaboración propia.

En esta ocasión se puede observar que durante el periodo outsample (1991-2022) se identifican con cierta frecuencia porcentajes en torno al 40%. Por otro lado, se observan dos meses con un porcentaje de días con temperaturas frías extremadamente frías por encima de 0,4, uno concretamente es diciembre de 2001, que tras acudir a AEMET encontramos explicación al alto porcentaje, donde comenta AEMET en una nota de prensa que en diciembre de 2001 se dieron unos episodios de frío intenso que llegaron a ser incluso la temperatura mínima diaria de la serie histórica 1961-1990. (AEMET, 2002). El otro porcentaje mensual con un alto valor se sitúa en febrero de 2005, que nuevamente se trata de una ola de frío. (EFE, 2005).

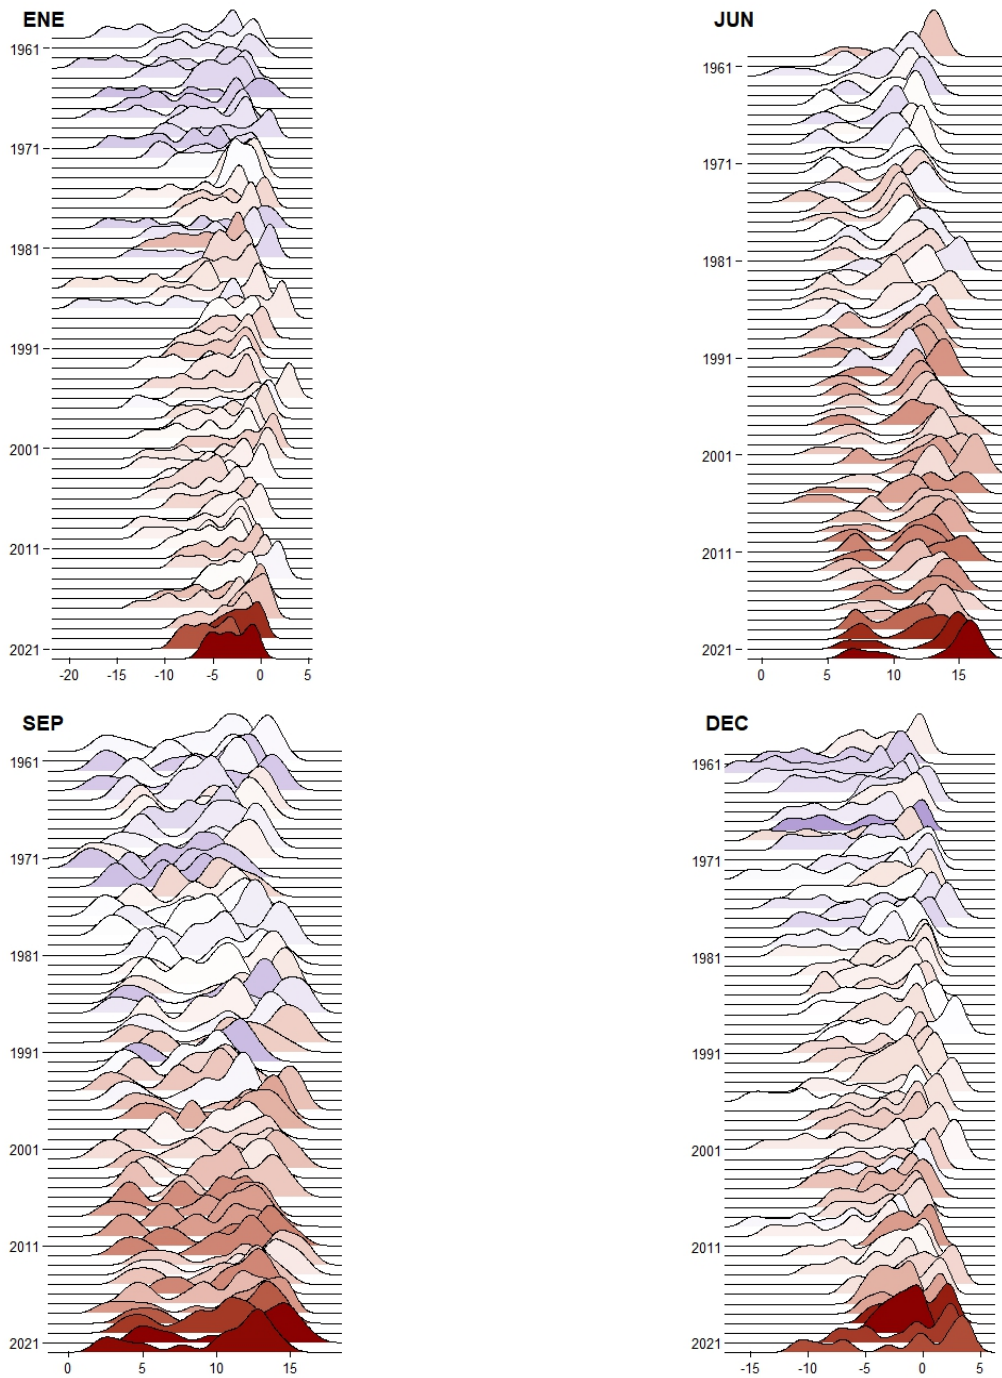
Lo que responde a nuestras dudas sobre estos % tan elevados.

Con el fin de dar soporte a la tendencia que ha observado se ha realizado el mismo análisis gráfico que para las temperaturas máximas, graficando cada una de las distribuciones para los diferentes años, pero en este caso la distribución de las temperaturas mínimas mensuales, tomando solamente el dato de las cuadrículas de la península ibérica dentro de la base de datos GHCND.

Según el análisis realizado con el dato de AEMET, se observa una frecuencia menor de eventos anómalos en cuanto a temperaturas frías.

Nuevamente el criterio a la hora de colorear las distribuciones no varía con respecto a la metodología seguida para las temperaturas máximas.


Figura 3.3.4. Distribución temperaturas mínimas diarias por año de la peínsula ibérica



Fuente: Elaboración propia.

Pudiéndose observar cómo los tonos rojos comienzan a aparecer desde 1991 aproximadamente, lo que nos transmite que la distribución se está desplazando hacia la derecha lo que implica que la probabilidad de que se observen temperaturas inferiores anómalas será cada vez menos frecuente y que entra en sintonía con lo que se ha demostrado con el dato de AEMET.

Figura 3.3.5. Anomalía estandarizada temperatura frías.



Fuente: Elaboración propia.

De la última ilustración se extrae que desde 2003 se observa una media móvil con valores negativos, lo que indica que las temperaturas mínimas han estado por debajo de la media del periodo de referencia durante un tiempo prolongado.

Llegando a valores de incluso -0.5, lo que transmite que la temperatura mínima de media en los últimos 5 años ha estado 0.5 desviaciones típicas por debajo de la media del periodo de referencia.

3.1.3.2 Precipitación

La variable precipitación se centra en eventos extremos, para la construcción del ACI se toman los registros de la variable MaxP5day dentro de la base de datos GHCNDEX.

Esta variable recoge la precipitación máxima acumulada de los últimos 5 días para una región de 2,5° de longitud por 2,5° de latitud.

A priori, se espera que la función de distribución de la precipitación no es normal, presentando un mayor peso la cola derecha de la distribución,


El objetivo de incorporar esta variable dentro del índice es capturar la cola derecha de la distribución de la precipitación, puesto que para recoger la cola izquierda de la misma se incorporará la variable sequía que se explicará a continuación.

La variable Precipitación si se ha podido replicar para la base de datos GHCNDEX, para ello, se ha utilizado el software RStudio al tratarse de una base de datos en formato netCDF, estas bases de datos se caracterizan por su extenso uso en la ciencia del clima, pues es comúnmente necesario que el dato cumpla características como un alto nivel de compatibilidad y alta capacidad de almacenaje. De ahí surgió el formato netCDF (NetworkCommon Data Form), tratándose de dato multidimensional.

El dato contiene las dimensiones, temporal y espacial, ya sea con una cuadrícula o píxel regular o irregular.

Las principales características de las bases de datos netCDF cuya extensión es “.nc” es el uso de un sistema de coordenadas de n dimensiones, incorporación de diversas variables y el uso o no de una cuadrícula regular.


Figura 3.4.1. Base de datos NetCDF para la variable T.



Fuente: Royé (2022).

El dato trabajado es la base de datos GHCNDEX, Donat et al. (2013b), presenta una estructura como se muestra en la siguiente figura.

Figura 3.4.2. Ilustración base de datos GHCNDEX



Fuente: Royé (2022).

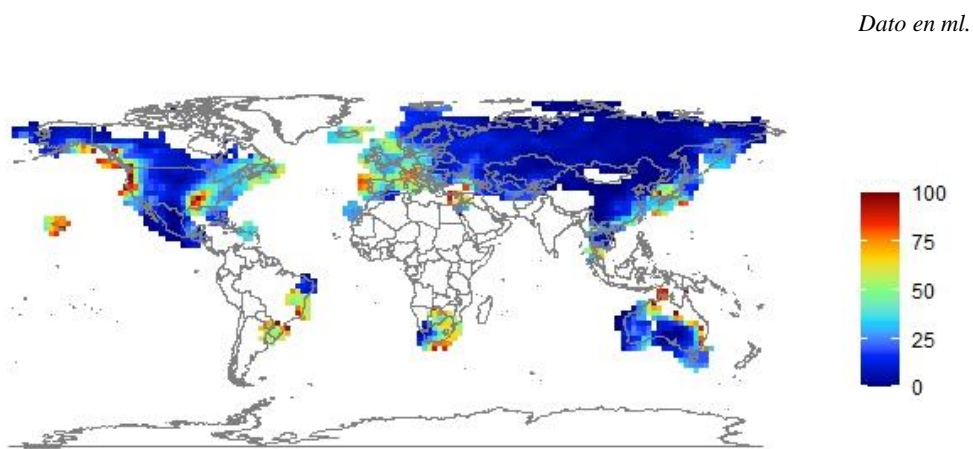
En el caso de la base de datos GHCNDEX, la posición fila 1, columna 1 de la matriz para el momento de tiempo 1, será el registro para la variable en cuestión seleccionada para el área de $2,5^{\circ}$ de latitud por $2,5^{\circ}$ grados de longitud siendo esta área la cuadrícula geográfica delimitada por los siguientes pares de coordenadas. Latitud -90 Longitud 0 Latitud -90 Longitud 2,5, Latitud -87,5, Longitud 0, Latitud -87,5, Latitud 2,5 que coincide con el polo sur, de manera que a medida que vayamos bajando en la posición de

filas en la matriz se irá ascendiendo en términos de latitud. Y a su vez a medida que vayamos avanzando en posiciones en columnas se irá recorriendo el globo terráqueo hacia la derecha.

Así pues, teniendo en cuenta que cada posición de la matriz representa un área de $2,5^{\circ}$ por $2,5^{\circ}$ es trivial averiguar que se va a disponer de cada capa, que representará un año en concreto, dentro del fichero netCDF, matrices de 72 filas por 144 columnas.

A su vez, hay que mencionar que dentro del fichero se dispone de diferentes variables, que son los meses, de tal manera que se podrá extraer la observación del mes elegida de la variable meteorológica seleccionada para todas las regiones del planeta tierra que aporte dato y para cualquier año en el rango de año 1941-2022.

Figura 3.4.3. Precipitación máxima acumulada por 5 días consecutivos mes enero



Fuente: Elaboración propia.

Para la replicar la variable precipitación máxima acumulada por 5 días consecutivos se ha necesitado utilizar el software Rstudio y a su vez ha sido necesario un arduo trabajo del dato y de interpretación del origen del dato, pues como se ha comentado el dato viene ofrecido por meses, por lo que se ha tenido que ir extrayendo por meses y para el periodo temporal preciso para una posición geográfica concreta.

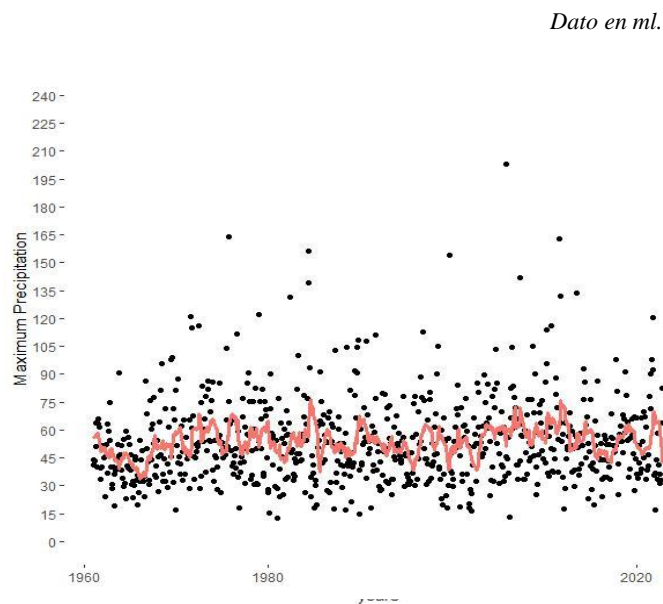
El ACI en su demostración de cálculo selecciona el distrito de Central Park en New York, así que, se ha tratado de seleccionar la cuadrícula que a priori era la más próxima y precisa que recogía dicho distrito.

La cuadrícula seleccionada para los cálculos que se van a mostrar a continuación recoge el siguiente par de coordenadas: Latitud: 40 Longitud: -72,5.

En su documento no especifican que cuadrícula han seleccionado, pero por cercanía el dato debería ser semejante, y es aquí uno de los puntos donde pueden surgir disparidades con sus resultados.

En primer lugar, lo que se ha realizado es un análisis visual tras tratar el dato para agruparlo en un único dataframe para todos los meses y se ha procedido a calcular la media móvil de las precipitaciones máximas acumuladas en 5 días consecutivos, siendo el resultado el siguiente.

Figura 3.4.4. Precipitación máxima mensual en 5 días consecutivos Central Park



Fuente: Elaboración propia.

En una segunda fase, se ha procedido a calcular la media y desviación típica para cada mes para el periodo de referencia, siendo el resultado el siguiente:

Tabla 3.4.1. Media y desviación típica Precipitación máxima acumulada en 5 días consecutivos por meses.

Dato para Central Park NY, USA.

	Ene	Feb	Mar	Abr	May	Jun	Jul	Ago	Sep	Oct	Nov	Dic
Media periodo ref.	44,09	44,57	49,96	53,69	54,45	56,06	56,65	61,24	58,52	55,31	53,75	47,45
Desv. tpca. periodo ref.	22,18	14,26	16,03	20,64	23,53	31,94	21,93	26,73	30,43	17,79	20,18	15,72
Media periodo outsample	42,38	40,27	51,12	58,39	51,55	56,23	57,53	63,65	64,36	68,19	51,09	52,32
Desv. tpca. periodo outsample	10,97	15,03	20,28	23,08	17,03	25,36	17,09	25,36	31,28	34,65	14,62	17,15

Fuente: Elaboración propia.

Mientras que los resultados que el ACI original muestra para en teoría la misma región es:

Tabla 3.4.2. Media y desviación típica precipitación máxima acumulada en 5 días consecutivos por meses.

Dato para Central Park NY, USA.

	Ene	Feb	Mar	Abr	May	Jun	Jul	Ago	Sep	Oct	Nov	Dic
Media periodo ref.	45,9	46,9	53,1	58,8	57,9	52,4	56,7	66,3	64,8	55,2	63,5	50,0
Desv. tpca. periodo ref.	30,0	20,7	24,6	27,8	31,8	32,7	31,0	47,3	50,0	27,3	46,6	19,4

Fuente: AAA et al., (2018c)⁶

A continuación, se mostrará el gráfico de las diferencias o anomalías con respecto a la media.


Fórmula 3.4.1. Anomalías precipitación acumulada.

$$\Delta MaxP^{(5-day)} = [MaxP^{(5-day)}(j, k) - \mu_{ref}MaxP^{(5-day)}(j)]$$

Siendo el resultado obtenido:

Figura 3.4.5. Anomalías precipitación

Dato en ml.



Fuente: Elaboración propia.

Para determinar la variable se procede a calcular las anomalías que serán determinadas como:


⁶ <https://actuariesclimateindex.org/wp-content/uploads/2019/05/SampleCalcEng.5.19.pdf>

Fórmula 3.4.2. Anomalía estandarizada.

$$MaxP^{(5-day)}_{std} = \frac{[MaxP^{(5-day)}(j, k) - \mu_{ref}MaxP^{(5-day)}(j)]}{\sigma_{ref}MaxP^{(5-day)}(j)}$$

A continuación, se mostrarán los resultados para esta variable, siguiendo la misma metodología con el dato de AEMET, pero para Soria.

Figura 3.4.6. Precipitación máxima mensual en 5 días consecutivos Soria.



Fuente: Elaboración propia.

Tabla 3.4.3. Media y desviación típica Precipitación máxima acumulada en 5 días consecutivos por meses.


Dato en ml.

	Ene	Feb	Mar	Apr	May	Jun	Jul	Aug	Sep	Oct	Nov	Dic
Media per ref	24,00	30,81	21,78	30,94	26,34	34,43	20,24	17,59	21,26	22,90	32,82	27,03
Desv. tpc. periodo ref.	16,14	16,23	13,64	21,59	15,14	16,82	15,29	18,94	18,24	18,74	21,16	21,11
Media outsample	31,73	26,22	27,71	32,38	34,85	28,91	22,87	21,29	24,43	39,38	39,53	37,03
Desv. tpc. periodo outsample	28,28	25,88	19,26	22,14	20,17	21,73	20,85	14,61	22,51	24,06	40,95	34,80

Fuente: Elaboración propia.

Figura 3.4.7. Distribución precipitación máxima acumulada en 5 días mensual Soria.


Dato en ml.



Fuente: Elaboración propia.

Como se puede observar que la tendencia no es clara, incluso percibiéndose que se recogen mayores precipitaciones acumuladas en cinco días en el periodo outsample, y es algo que puede entrar en sintonía viendo algunas noticias relacionadas que publican como “los estudios indican que se tiende hacia periodos de sequía salpicados de episodios de fuertes precipitaciones que pueden provocar inundaciones y que las DANAS van a ser cada vez más frecuentes.” (El Confidencial, 2021).

Figura 3.4.8. Anomalía estandarizada Soria



Fuente: Elaboración propia.

Al estar claramente relacionada esta variable con las lluvias torrenciales se puede observar que puede ser explicado ese incremento en las precipitaciones acumuladas en cinco días frente a lo observado en el periodo de referencia, estos eventos pueden provocar graves consecuencias como riadas viéndose anegadas poblaciones enteras e incluso provocando pérdidas humanas.

3.1.3.3 Sequía

La presente variable pretende capturar la cola izquierda de la distribución de las precipitaciones, esta variable nuevamente ha podido ser replicada usando el dato de AEMET Opendata, (AEMET, 2023a).

Esta base de datos presenta ciertas deficiencias menores, puesto que se encuentran ausencias de registros puntualmente. El tratamiento de estos valores se ha decidido estimarlo mediante interpolación lineal. A su vez la base de datos presenta registros que vienen expresados como “lp” que vienen a recoger días de precipitación menor que 1 ml, estos registros han sido tratados y considerados como ceros, a su vez, se han quitado las observaciones para los días 29 de cada año bisiesto.

Posteriormente, tomando el dato crudo de precipitación se ha procedido a realizar el cálculo del número de días consecutivos sin precipitaciones, para ello:

Fórmula 3.5.1. Días consecutivos de

$$Consecutive_{norain}(i) = \begin{cases} 0, & Prec(i) \Rightarrow 1 \text{ ml} \\ Consecutive_{norain}(i - 1) + 1, & Prec(i) = 0 \end{cases}$$

A continuación, se selecciona el máximo número de días consecutivo para cada año.

Fórmula 3.5.2. Máximo números de días consecutivos sin precipitación

$$CCD(k) = Max(Consecutive_{norain}(i, k))$$

Siendo:

k= 1961, 1962, ...2022.

Una vez calculado el máximo de cada año, este será considerado como el valor del mes 12 para cada año, de tal manera que, para los meses 1-11 de cada año se aplicará una interpolación lineal.


Una vez que se han extraído las observaciones estimadas para cada uno de los meses se ha procedido a calcular la esperanza y desviación típica para cada mes en el periodo de referencia.

Tabla 3.5.1. Media y Desviación Típica de la frecuencia de temperaturas frías extremadamente cálidas por meses.

Momento	Ene	Feb	Mar	Abr	May	Jun	Jul	Ago	Sep	Oct	Nov	Dic
Media	28,56	28,55	28,55	28,55	28,54	28,53	28,52	28,52	28,51	28,51	28,50	28,50
Desv. tpca.	8,89	8,34	7,88	7,53	7,32	7,25	7,33	7,55	7,91	8,37	8,94	9,58

Fuente: Elaboración propia.

Figura 3.5.1. Número de días consecutivos sin precipitación



Fuente: Elaboración propia.

Buscando explicación a los valores más extremos que observables en la anterior gráfica destacando los valores que se alcanzan entre 1983-1986, 1994 y 2004, que coinciden con los que (AEMET, 2020), denomina periodos de sequías de larga duración e intensidad. También destaca 2017. Investigando nuevamente si estos valores tienen una explicación coherente encontramos ciertas publicaciones que dan explicación a estos registros para estas fechas. (El Confidencial, 2018).

Encontramos también un repunte en el número de días consecutivos sin precipitación en 2022 y que como corrobora AEMET en 2022 se vivió uno de los inviernos más secos desde 1961. (AEMET, 2022c).

Pese a ser información referente a toda la península da una intuición de que puede haber ocurrido.

En cuanto a la tendencia no se ve un claro cambio de un periodo frente a otro y es que la precipitación es una de las variables con mayor dificultad para estimar una tendencia clara. (Serrano-Notivoli, 2018)

A continuación, se procederá a calcular la anomalía estandarizada para la variable sequía cuya expresión matemática es la siguiente:

Fórmula 3.5.3. Anomalía estandarizada máximo número de días consecutivos sin precipitación.

$$MaxCDD_{std}(j, k) = \frac{[MaxCDD(j, k) - \mu_{ref}MaxCDD]}{\sigma_{ref}MaxCDD}$$

Siendo:


$\mu_{ref}MaxCDD$ = Media número máximo de días cosecutivos sin precipitación

Para Soria este parámetro es 28,75

$\sigma_{ref}MaxCDD$ =Desviación típica del número máximo de días consecutivos sin precipitación.

Para Soria este parámetro es 7,81

Figura 3.5.2. Anomalía estandarizada máximo número de días consecutivos sin precipitación.



Fuente: Elaboración propia.

3.1.3.4 Viento

La variable Viento ha sido posible replicarla con la base de datos de AEMET puesto que se dispone de dato diario para la racha /velocidad de viento, ya sea velocidad de viento media o racha de viento máxima. Para el cálculo de esta variable se ha hecho uso del dato de la velocidad de viento medio.

El dato vuelve a presentar ciertas anomalías, pero no lo suficientemente graves como para ser descartado, así pues, nuevamente, encontramos ausencia de registros en 2011.

Por seguir un criterio uniforme se ha procedido a retirar las observaciones para los días 29 de febrero para los años bisiestos. Consiguiéndose series de 365 días para cada año y la distribución de los días del mes será siempre uniforme.

El tratamiento de los registros ausentes se ha estimado mediante interpolación lineal siguiendo un criterio uniforme.

Tras tratar el dato, se ha realizado una conversión del dato para la racha de viento media diaria medida en metros/segundo averiguando el valor para la fuerza eólica (*wind power*).

Esta conversión se ha hecho a través de la siguiente equivalencia

Fórmula 3.6.1. Equivalencia Wind Power

$$WP = \frac{1}{2} \rho c^3$$

Siendo:

$\rho = \text{Densidad del aire} = 1,32 \text{ kg/m}^3$

$c = \text{velocidad media}$

Que viene expresada en,

Fórmula 3.6.2. Unidades Wind Power (WP)

$$WP = \frac{1}{2} \rho c^3 [=] \frac{1 \text{ kg}}{2 \text{ m}^3} \left(\frac{\text{m}}{\text{s}}\right)^3 = \frac{\text{kg}}{\text{s}^3} = \frac{\text{W}}{\text{m}^2}$$

Siendo:

$\text{kg} = \text{kilogramos}$

$\text{m} = \text{metros}$

$\text{s} = \text{segundo}$

$\text{W} = \text{vatios}$

Una vez averiguada la magnitud en la que vamos a manejar la variable Wind Power (WP) se procederá con el cálculo de la variable Viento.

Para ello se determina la nueva magnitud para cada día considerando para ello:

$\rho = \text{densidad del aire constante en el tiempo} = 1,23 \text{ kg/m}^3.$

Observando la serie de valores racha de viento máxima para conocer un poco más los posibles valores extremos, se identifican los siguientes valores máximos, que vamos a clasificar según la escala de Saffir-Simpson (Saffir H., 1973) (Simpson R., 1974).

Tabla 3.6.1. Ranking rachas de viento máxima Soria

Posición	Fecha	Racha máxima m/s	Categoría Saffir-Simpson
1	25/02/1989	33,9	1
2	29/01/1988	31,9	TS
3	25/05/1986	28,9	TS
4	20/12/1988	28,1	TS
5	21/12/2019	27,8	TS

Fuente: Elaboración propia.

Tabla 3.6.2. Escala Saffir-Simpson

Categoría	Descripción	m/s	knots	mph	km/h
5	Daños catastróficos	≥ 70	≥ 137	≥ 157	≥ 252
4	Daños catastróficos	58–70	113–136	130–156	209–251
3	Daños devastadores	50–58	96–112	111–129	178–208
2	Vientos extremadamente peligrosos que pueden generar grandes daños	43–49	83–95	96–110	154–177
1	Vientos muy peligrosos que pueden generar ciertos daños	33–42	64–82	74–95	119–153
TS	Tormenta tropical	18–32	34–63	39–73	63–118
TD	Depresión tropical	≤ 17	≤ 33	≤ 38	≤ 62

Fuente: NOAA⁷.

Concluyendo que no se han observado vientos que hubieran generado daños masivos, a lo mucho solamente existe una observación que podría categorizarse como vientos peligrosos.

Conociendo más el comportamiento de la variable viento, se procederá a continuar con el cálculo de la variable viento.

⁷ <https://www.nhc.noaa.gov/aboutsshws.php>

En primer lugar, será necesario determinar el umbral para cada día con el que se considerará cuando una observación se trata de una racha de viento anómala para posteriormente determinar la frecuencia mensual y anual.

Para determinar estos umbrales se ha utilizado la siguiente expresión y se han calculado usando las observaciones del periodo de referencia (1961-1990):

Fórmula 3.6.3. Umbrales variable viento.

$$WP_{ref}(i,j) = \frac{\sum_{i=1}^{30} WP(i,j,k)}{30} + 1.28 \sqrt{\frac{\sum_{i=1}^{30} (WP(i,j,k) - \frac{\sum_{i=1}^{30} WP(i,j,k)}{30})^2}{30}}$$

Esta fórmula trata de determinar lo que sería el umbral asumiendo que, la variación o ruido de la racha media de viento diaria en el periodo de referencia se comportase como una $N(0,1)$, de tal manera que, para determinar el percentil 90 utilizamos la escala del valor medio para cada día y el ruido lo determinamos a partir del percentil 90 de una $N(0,1)$.

Una vez determinado el umbral para cada mes en base al histórico del periodo de referencia, se ha determinado cuándo un valor es anómalo o no, para ello se ha creado una función hit-or-miss de características similares a las utilizadas en variables anteriores.

Fórmula 3.6.4. Hit-or-Miss para temperaturas cálidas anomalas superiores

$$\psi_{WP}(i,j,k) = \begin{cases} 1, & WP(i,j,k) > WP_{ref}(i,j) \\ 0, & WP(i,j,k) < WP_{ref}(i,j) \end{cases}$$

Posteriormente, se ha calculado la frecuencia mensual para cada mes.


Fórmula 3.6.5. Frecuencia mensual rachas de viento media anómala.

$$F WP(j,k) = \frac{\sum_{i=1}^{n^{\circ} \text{ días mes } j} \psi_{WP}(i,j,k)}{n^{\circ} \text{ días mes } j}$$

Fórmula 3.6.6. Anomalía estandarizada variable viento.

$$FWP_{std}(j,k) = \frac{[F WP(j,k) - \mu_{ref}(j)]}{\sigma_{ref}(j)}$$

Figura 3.6.1. Umbral mensual Wind Power




Fuente: Elaboración propia.

Tabla 3.6.3. Umbral mensual variable viento.

Magnitud	Ene	Feb	Mar	Abr	May	Jun	Jul	Ago	Sep	Oct	Nov	Dic
WP	339,3	359,2	279,9	262,9	199	132,8	145,3	94,2	108,1	192,3	205,8	254,6
m/s	7,8	7,9	7,6	7,4	6,7	5,9	6	5,3	5,4	6,5	6,8	7,3
Km/h	28,3	28,5	27,3	26,8	24,1	21,1	21,7	18,9	19,4	23,4	24,3	26,1

Fuente: Elaboración propia.

Figura 3.6.2. Anomalía estandarizada viento.



Fuente: Elaboración propia.

3.1.3.5 Nivel del mar

En cuanto a la variable nivel del mar, no se ha replicado para la región seleccionada puesto que, para Soria, lógicamente, la variable nivel del mar no aplica, pero si se ha podido realizado la réplica para la misma región norteamericana que muestran los autores originales en el documento de cálculo y se ha realizado la misma metodología para Málaga.

Para la construcción de esta variable, el ACI original, hace uso de la base de datos proveída por el Permanent Service for Mean Sea Level. (PSMSL, 2023). Donde se ha obtenido el dato para la misma estación mareográfica que el documento original. En concreto se trata de la estación 112 situada en San Fernandina Beach, Florida.

En cuanto al dato se han encontrado ciertas deficiencias, pero no lo suficientemente graves para que impidiesen continuar con la base de datos, además, en esta ocasión se han encontrado unos resultados sumamente próximos a lo que publicaron originalmente, gracias a que los autores han sido más específicos acerca de que dato están utilizando.


En cuanto a las deficiencias, se ha encontrado un periodo continuo entre 1995 y 1998 sin observaciones para la estación 112, los cuales se han decidido estimar mediante interpolación lineal.

También se ha de comentar que el dato está expuesto al efecto que puede provocar el movimiento de arena, provocando cierta imprecisión en el dato recogido por las estaciones mareográficas, pero esto es otro factor climático que recoge esta variable y que es la modificación del entorno marino.

Otro comentario sobre el dato es que, viene proporcionado en ml escalándolo a 7000 mm con el fin de evitar valores negativos.

En principio, es de esperar encontrar valores valle en el periodo estival por la evaporación y menor precipitación de estos meses.

Figura 3.7.1 Nivel del Mar San Fernandina Beach, FLO



Fuente: Elaboración propia.

Pudiendo observar en color rojo la serie creada como la media móvil anual de las observaciones de nivel de mar para la región seleccionada.

Posteriormente, se ha calculado la media y desviación típica para cada uno de los meses teniendo en cuenta solamente las observaciones del periodo de referencia.

Tabla 3.7.1. Media y desviación típica nivel del mar.

*Dato para San Fernandina FLO, USA
Estación 112 PSMSL (2023).*

	Ene	Feb	Mar	Abr	May	Jun	Jul	Ago	Sep	Oct	Nov	Dic
Media periodo ref.	7097	7104	7115	7125	7179	7189	7118	7177	7346	7375	7277	7155
Desv. tpca. periodo ref.	95,4	91,6	83,7	53,9	65,8	82,4	61,5	60,7	61,8	78,3	75,7	72,6
Media para el periodo outsample	7196	7205	7127	7237	7278	7256	7214	7214	7439	7457	7374	7250
Desv. tpca. periodo outsample	99,7	92,2	74,8	73,4	64,9	89,6	66,5	71,4	108,6	104,2	104,7	91,2

Fuente: Elaboración propia.

Tabla 3.7.2 Media y desviación típica nivel del mar originales.

Dato para San Fernandina FLO,USA Estación 112 PSMSL (2023).


	Ene	Feb	Mar	Abr	May	Jun	Jul	Ago	Sep	Oct	Nov	Dic
Media periodo ref.	7097	7104	7115	7124	7179	7189	7119	7177	7346	7377	7277	7152
Desv. tpca. periodo ref.	93,9	90,1	82,3	53,8	64,7	81,1	60,5	59,8	60,8	77,2	75,7	71,2

Fuente: AAA et al., (2018c)⁸

Observándose como los resultados son sumamente próximos.

Figura 3.7.2. Medias nivel del mar por meses.

Dato para San Fernandina FLO,USA Estación 112 PSMSL (2023).



Fuente: Elaboración propia.


A continuación, se ha procedido a calcular las anomalías como las variaciones absolutas para cada mes u observación con respecto a su media del periodo de referencia, que posteriormente, será nuestro numerador para el cálculo de las anomalías estandarizadas.

Fórmula 3.7.1. Anomalías por meses.

$$\Delta S(j, k) = S(j, k) - \mu_{ref} S(j)$$

⁸ <https://actuariesclimateindex.org/wp-content/uploads/2019/05/SampleCalcEng.5.19.pdf>

Figura 3.7.3. Anomalía nivel del mar.



Fuente: Elaboración propia.


Pudiéndose observar una clara tendencia alcista de la anomalía en el nivel del mar desde 2012.

Posteriormente se ha calculado la anomalía estandarizada para esta variable.

Fórmula 3.7.2. Anomalía estandarizada nivel del mar.

$$S_{std}(j, k) = \frac{[S(j, k) - \mu_{ref}(j)]}{\sigma_{ref}S(j)}$$

Figura 3.7.4. Anomalía estandarizada nivel del mar San Fernandina Beach, FLO



Fuente: Elaboración propia.

A continuación, se muestran los resultados para Málaga pues para Soria es una variable que no entra en escena.


Tabla 3.7.3. Media y desviación típica nivel del mar Málaga

	Ene	Feb	Mar	Abr	May	Jun	Jul	Ago	Sep	Oct	Nov	Dic
Media periodo ref.	6878	6868	6867	6868	6877	6895	6916	6929	6932	6942	6943	6909
Desv. tpca. periodo ref.	76,6	50,9	50,8	44,6	43,4	41,9	36,4	35,6	42,1	48,0	57,6	69,1
Media periodo outsample	6941	6929	6938	6948	6962	6978	7001	7025	7034	7056	7035	6990
Desv. tpca. periodo outsample	85,8	85,2	75,8	79,8	72,5	70,3	69,9	71,8	75,2	77,5	84,9	75,2

Fuente: Elaboración propia.

Figura 3.7.5. Media nivel del mar por meses Málaga

Dato en ml.




Fuente: Elaboración propia.

Siendo impactante el incremento del nivel del mar que recoge el mareógrafo para la ciudad de Málaga, comparando la media de los meses del periodo de referencias frente a la media de los meses para el periodo outsample.

Fórmula 3.7.6. Anomalía nivel del mar Málaga.

Dato en ml.




Fuente: Elaboración propia.

Y es que el crecimiento del mar como se observa sigue imparable desde 1991 y así lo confirman algunas noticias relacionadas con titulares como “El nivel del mar no ha parado

de crecer: aumenta unos tres centímetros por decenio desde los años 90". (El Confidencial, 2022a).

Y noticias que directamente ya hablan de planes de resiliencia del gobierno para la provincia de mismo nombre que la ciudad que se muestra, como la Estrategia para la Protección de la Costa en la provincia de Málaga y evitar que Málaga quede anegada por la subida de la mar presentada por el secretario de estado de medio ambiente como publica El Confidencial (2022b)

Fórmula 3.7.7. Anomalía estandarizada nivel del mar Málaga.



Fuente: Elaboración propia.

En la anterior figura se puede observar cómo los valores positivos no paran de crecer desde 1991, lo que indica que el nivel del mar en Málaga ha estado por encima de la media histórica durante los anteriores 5 años. Esto podría tener implicaciones significativas para una entidad aseguradora que opera en esa región, especialmente en relación con los riesgos asociados al aumento del nivel del mar tal como el riesgo de inundaciones costeras, la intrusión de agua salada en acuíferos o el deterioro de muelles y paseos marítimos.


3.1.4 Combinación de Variables

La construcción del final ACI se construye mediante la media de las 5 o 6 variable involucradas, en este caso en concreto para Soria, tan solo se ha de realizar la media para 5 variables.

Fórmula 3.8.1. Acturial Climate Index (ACI)

$$ACI(j, k) = \frac{MaxCDD_{std}(j,k) + S_{std}(j,k) + Max P_{std}^{(5-day)} + FT:warm_{std}(j,k) - FT:cool_{std}(j,k) + FWP_{std}(j,k)}{6^*}$$

Figura 3.8.1. ACI SORIA



Fuente: Elaboración propia.


El resto de las ciudades pueden encontrarse en el anexo.

3.1.5 Combinación de índices

Fórmula 3.9.1. Actuarial Climate Index (ACI) proxy para España

$$ACI_{ESP}(j, k) = \frac{ACI_{Soria}(j, k) + ACI_{Madrid}(j, k) + ACI_{Barcelona}(j, k) + ACI_{Bilbao}(j, k) + ACI_{Sevilla}(j, k) + ACI_{Malaga}(j, k)}{6}$$

Figura 3.9.1. ACI AGREGADO



Fuente: Elaboración propia.

Recaltar en el título el concepto proxy, pues pese a recoger varias de las ciudades más grandes del estado español, no incluyen todas las ciudades ni estaciones climáticas que proporciona AEMET, por lo que técnicamente no puede considerarse el Índice Actuarial Climático definitivo para España.

En cuanto al índice se observa como desde 1991 se ha experimentado unas décadas hasta la actualidad con una frecuencia e intensidad de eventos climáticos anómala con respecto al periodo de referencia para casi todas las ciudades para las que se ha hecho el análisis.

También resaltar que para las últimas observaciones de 2022 el índice ronda el valor de 0.2 siguiendo una tendencia creciente desde 1991, lo que interpretamos como una señal de un cambio gradual en las condiciones climáticas. El hecho de que el índice se mantenga alrededor de 0.2 lo que indica que las condiciones climáticas han experimentado un incremento constante, pero no drástico, en relación con la media histórica.

Esta tendencia creciente sugiere que ha habido un aumento gradual en el número e intensidad de los eventos climáticos que están siendo medidos por el índice. Si bien el valor de 0.2 puede parecer relativamente pequeño, es importante considerar el impacto en variables como mortalidad y severidad.

A su vez, es necesario realizar un análisis más detallado para comprender la magnitud y la relevancia de este cambio gradual en las condiciones climáticas.

Se considera vital continuar monitoreando y analizando la evolución de este índice climático en los próximos años para evaluar la continuidad de esta tendencia creciente y su posible impacto en los diferentes aspectos relacionados con el clima.

4. APLICACIÓN AL SEGURO PARAMÉTRICO

4.1 Fundamento del Seguro Paramétrico

El seguro paramétrico puede parecer ser una versión novedosa o de reciente creación del seguro, sin embargo, más de uno se sorprendería al descubrir que los seguros paramétricos ya estaban en el mercado en las primeras décadas del pasado siglo. (Swiss Re, 2022a)

En concreto fueron reaseguradoras como Swiss Re, entre otras, quienes dieron un paso adelante en la concepción de esta versión dentro del seguro moderno debido a las nuevas y cada vez más exigentes necesidades de sus clientes.

“Estas necesidades eran principalmente una mayor agilidad a la hora de tramitar y liquidar las compensaciones, por ejemplo, los bancos exigían tener coberturas en sus carteras inmobiliarias ante la posibilidad de que estas pudiesen ser destruidas” (Swiss Re, 2022a)

Y es que, los seguros paramétricos son ahora mismo un tipo de seguro que pese a tener ya un cierto tiempo en el mercado asegurador, tiene un futuro más que prometedor gracias sus diversas posibilidades, pudiendo definirse para la cobertura de un ciberataque, lucros cesantes para una industria por cualquier evento climático, entre otros. Y todo esto gracias a la revolución del dato.

Dentro de las partes en el seguro paramétrico obviamente encontramos a: la aseguradora o reaseguradora y la parte interesada en el seguro o asegurado. Pero a diferencia del seguro tradicional, aparece una tercera parte que se encarga de proveer el dato como podría ser el centro nacional de huracanes de los Estados Unidos o AEMET en España y una vez definido este proveedor se comenzaran a establecer las bases del seguro paramétrico.

Dentro de estas bases emerge el concepto de “trigger event” o evento desencadenante que será un evento o un cierto nivel de un índice que hará que automáticamente se proceda a desembolsar la suma asegurada. En esta última parte, como se viene comentando, surge su principal virtud, la velocidad de liquidación, y es que no hace falta que un perito determine si realmente se ha incurrido en una sequía extrema que ha hecho que se haya perdido la cosecha. Es el índice o un evento como el número consecutivos sin precipitación por ejemplo quien determine ese evento, previa demostración de que dicho evento tiene una relación con el daño, sin que las partes pudiesen entrar en matices.

Aparentemente no parece que destaquen en volumen de pólizas emitida, sin embargo, la industria del seguro paramétrico ha generado 11,7 billones americanos de dólares y se estima que para 2031 pueda ascender a los 29,3 billones americanos. (Swiss Re, 2022a).

Hasta ahora la mayoría de esta industria parece que se sostiene sobre eventos climáticos sin embargo tiene un horizonte prometedor y es que a medida que el dato y los registros históricos sean más robustos y fiables más coberturas se podrán dar y que coberturas tradicionales reniegan por las pérdidas históricas que acumulan.

Por ejemplo, un mercado emergente son las estructuras (antenas y derivados) que necesitan las entidades de telecomunicación para prestar su negocio, estas veían fuerte dificultades para asegurar estas estructuras pues este tipo de seguros ha ayudado a las empresas de teleco a mitigar el riesgo al que estaban expuestas.

4.2 Posibles Seguros Paramétricos vinculados al índice Climático Actuarial.

Como venimos comentando el seguro paramétrico además de las dos partes interesadas existe una tercera quien proveerá del dato o del índice. A su vez, también se ha comentado que la mayoría del negocio del seguro paramétrico recae sobre eventos climáticos.

Dicho esto, en búsqueda de aplicaciones actuariales para este índice climático actuarial para varias ciudades españolas y con dato del mayor proveedor de dato climático nacional, se van a proponer, varias aplicaciones que ya se han usado a nivel internacional y que se podrían traer a casuísticas nacionales, pero antes vamos a analizar en profundidad como alguna de las coberturas más curiosas de este tipo de seguros llegan a acordarse.

4.2.1 Cobertura para protección de arrecifes de coral.

4.2.1.1 Casos reales

Como todo contrato de seguro es vital la existencia de un riesgo, en este caso son los arrecifes de coral y es que el 10% del coral mundial ha desaparecido en los últimos años y el 60% está siendo amenazado por actividades antropogénicas según Storlazzi et al. (2019).

Estas actividades han provocado cambios en el calentamiento del mar, incremento del nivel del mar, la acidificación del mar, cambios en las precipitaciones como se ha podido demostrar para ciertas ciudades españolas.

Y es que, es cierto que las costas mundiales han vivido una fuerte transformación, explotándose sus virtudes turísticas y residenciales, pero esto a su vez ha generado la necesidad de pensar en la protección de nuestras costas. Protección que ofrecen los arrecifes de coral y fauna diversa que ayudan a mantener la estructura de las costas marinas, permitiendo así mitigar el riesgo de manera natural de inundaciones o daños en infraestructuras costeras e incluso pérdidas humanas, que llegaron a tener un volumen de pagos por parte de las aseguradoras de 300 billones americanos de dólares en la última década. (WordBank, 2016). Impactos que el coral podría haber ayudado a mitigar incluso el 97% de la energía generada de las olas. (Ocean Risk and Resilience Action Alliance, 2022).

A la hora de determinar el impacto de la fauna marina en la mitigación de este riesgo se plantean varias metodologías.

Metodologías basadas en índices como el Coastal Vulnerability Module of InVEST. Su creador, Arkema et al. (2013), modeliza la exposición en diferentes puntos de la costa a los efectos de la erosión, inundaciones, usando para ello dos variables bio-geofísicas que a su vez están compuestas por otras variables.

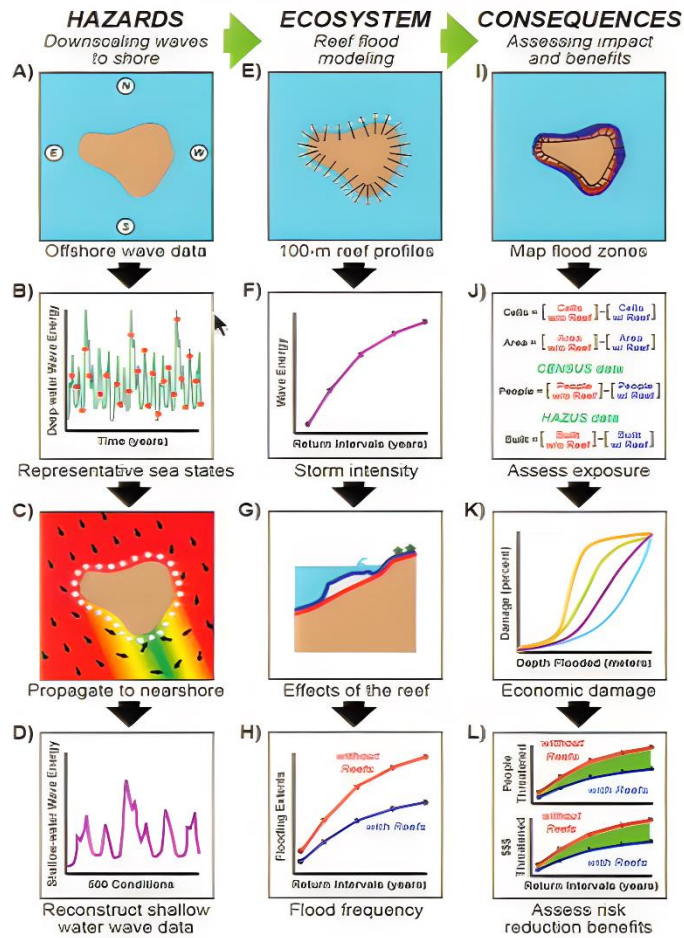
Estas dos variables tratan de representar la variación dentro de unas características naturales y geomórficas, así como representar la densidad de población costera.

Hasta ahora, ya se ha hablado del posible interés, que quizás si uno no entra en detalle no llega a pensar en el cambio a la exposición del riesgo que puede generar la alteración de un elemento de la naturaleza como pueden ser los corales.

Sin embargo, es necesario hacerse más preguntas y dar respuesta a ellas para llegar a la mitigación del riesgo que será donde entrase el seguro paramétrico.

Estas preguntas deben seguir el siguiente esquema.

Figura 4.2.1. Flujograma del análisis exposición al riesgo



Fuente: Storlazzi et al. (2019)

Del apartado G) y J) del anterior flujograma ya se ha hablado en mayor o menor medida en los párrafos anteriores, los apartados A), B), C), D), E) Y F), dependen en gran parte del área geográfica de la que originalmente se haya decidido hacer el análisis, que en este caso por la presencia del coral en sus costas hablamos de las Islas Marianas, Hawái, Florida, Las Islas Vírgenes de los Estados Unidos, Puerto Rico y México. Pero para hacer un comentario de cada fase se va a comentar algún dato que arroja el estudio de Storlazzi et al. (2019).


En cuanto a las fases A) y B) detalla la aportación a este estudio de las universidades españolas, y es que el Paula Camus de la Universidad de Cantabria, desarrolló una técnica que permitió dar utilidad al dato marítimo que viene normalmente determinada por una cuadrícula geográfica de $0.1^\circ - 1^\circ$, sin embargo, esta resolución no era lo suficientemente granular para el estudio de ciertas variables climáticas, así que consiguió a través de una técnica conocida como “Downscaling” reduciendo significativamente el esfuerzo y necesidades de CPU.

Hasta ahora, ya se dispone del dato a una granularidad adecuada, así que, se procede a comentar los puntos C) Y D) que para la región en cuestión usando el modelo Simulating Waves in the Nearshore (SWAN) de Booij et al. (1996) que permite realizar escenarios de altura del oleaje.

Posteriormente con ese dato se baja a una mayor granularidad para poder recoger por cada 100 metros de costa un nivel de altura de oleaje, con el que se modelizará la distribución de la altura del oleaje en diferentes intervalos de tiempo, siendo aquí la variable meteorológica que más va a afectar a la altura del oleaje serán las tormentas.

En las fases G) y H) gracias al dato que la NOAA dispone sobre el % de arrecife de coral en las costas de ciertas regiones y a su vez (Yates et al., 2017) y a través del modelo XBeach US Army, desarrollado por Delft University of Technology et al., (2010) consiguiendo definir las escalas del nivel del mar con y sin estas áreas de corales.

Figura 4.2.2. Nivel del mar costas Hawaii



Fuente: Storlazzi, C.D. et al. (2019)

“Pudiéndose demostrar esta variación del nivel del mar con o sin arrecifes de mar tras 1002 días de computación.” (Storlazzi et al., 2018)

Pasando al último punto del análisis L), es aquí donde el seguro paramétrico entra en escena, y es que, The Nature Conservancy organización mundial que se dedica a conservar los recursos naturales, ya en 2019 adquirió la primera póliza de seguro paramétrico con la colaboración de WTW y siendo la aseguradora Munich Re. Quien denomino la operación como “Resilience Risk Transfer” en la que con el estudio anteriormente desarrollado y otros como el de Reguero et al., (2019), dieron justificación al interés en asegurar dicho riesgo.

Póliza la cual fue ejecutada por el huracán Delta para el arrecife de Quintana Roo, en México y en el arrecife de Belice por el huracán Lisa. (Nature, 2022).

Y es que, recientemente, cuando estas pólizas están extendiéndose al territorio norteamericano, en concreto, a Hawái. Pactando una póliza de seguro de reaseguro donde el evento desencadenante serán vientos superiores a 57 metros por hora lo suficientemente cerca al área en cuestión, póliza que tendrá duración hasta el final del periodo de huracanes de 2023. (Nature, 2022).

4.2.1.2 Costal Risk Index (CRI)

AXA XL dentro de la iniciativa “Ocean Risk” y en colaboración de la Ocean Risk and Resilience Action Alliance y diferentes universidades, entre ellas, la Universidad de Cantabria, han desarrollado un índice, que englobando la metodología que se ha descrito anteriormente, ha logrado desarrollar un índice que ofrece la visualización del riesgo de inundación actualmente, en 30 años y en 50 años, incluyendo el impacto en poblaciones costeras como Filipinas. (ORRAA, 2022).

Hoy en día, se encuentra en desarrollo con apoyo de los Estados Unidos de una plataforma donde se publicarán los estudios y el dato utilizado, no obstante, ya hay datos publicados para Filipinas.

Como se viene comentando, este tipo de índices permiten, entre otras cosas, comprender y concienciar sobre el riesgo asociado a los cambios en la naturaleza.

4.2.2 Pólizas para la protección de industrias pesqueras.

Otras necesidades en la que este tipo de índices climáticos, pueden o podrían ser una pieza clave en el desarrollo de seguros paramétricos, es, por ejemplo, para la protección ante el lucro cesante que sufren los pescadores filipinos durante las épocas de clima adverso en las que salir a faenar puede ser suponer un alto riesgo.

Para ello, nuevamente WTW y Rare, están desarrollando un índice que ofrezca una aproximación del número agregado de días de faena perdidos mensuales sobre el cual se sustente el índice paramétrico. (ORRAA, 2022).

El origen de la necesidad de un seguro paramétrico que cubra es que, en Filipinas, 6,5 millones de habitantes basan sus ingresos fundamentalmente en la pesca local y además el 11,5% de la dieta filipina se basa en pescado. (ORRAA, 2022).

Así pues, eventos como lluvia intensa, rachas de viento fuertes, tormentas de niebla o tormentas marinas pueden provocar que estos ingresos se vean drásticamente reducidos.

Finalmente, este producto fue desarrollado tras superar los correspondientes análisis actuariales que arrojaron viabilidad combinando tres variables climáticas dentro de un seguro tradicional. (ORRAA, 2022).

Este producto hoy en día está en un proyecto piloto de prueba, ofreciendo un pago a los pescadores locales en caso de que ejecute la condición climática, siendo el tomador de la póliza el estado de Filipinas.

Resaltar que en la pasada COP27, el estado de Canadá anunció mayor soporte a este proyecto en los próximos dos años, entrando en un proyecto piloto durante 2023 y 2024 en el que aproximadamente 50.000 pescadores van a estar cubiertos, siendo el pago máximo anticipado 100 dólares por póliza que se equivale al ingreso perdido del mes de faena. (ORRAA, 2022).

España es también un importante consumidor de pescado y tiene la suerte de no tener que salir a adquirir la mercancía, esto hace que haya una industria pesquera que sería directamente quien podría verse protegida bajo esta cobertura.

4.2.3 Pólizas para la protección ante rachas de viento anómalos.

Swiss Re (2022b), ha desarrollado un seguro paramétrico al que han llamado STORM, este producto, se sustenta en el dato que les provee RMS HWind, que les otorga de un dato de alta granularidad temporal y geográfico. Siendo el nivel de reporte temporal al minuto.

Entrando más en los detalles de la póliza, STORM, tiene un límite asegurado de 50 millones de dólares, comprometiendo el pago de la indemnización en 30 días.

Ofreciendo una gran transparencia y facilidad de demostrar el evento pues todo recae en los parámetros elegidos y ofreciendo una cobertura de entre 1 y 3 años.

Swiss Re, ofrece un caso de uso, antes de nada, es necesario que determinar una única localización de la propiedad asegurada, tras esto se identifica la fuente de dato de RMS Hwind más próxima. Posteriormente se determina los límites por ocurrencia y agregada y por último se negocia las posibles condiciones del pago.

Tabla 4.3.1. Ejemplo condiciones pago STORM

Max racha de viento en 1-minuto continuado	Pago (% del límite)
+105 MPH	100
105-95	75%
95-85	50%
85-75	15%
75-65	5%

Fuente: Swiss Re⁹

Por cuestiones de confidencialidad no mencionan que metodología sigue el modelo o el dato histórico que pueda proveer RMS.

Otros usos podían ser para la generación de escenarios “What If” dentro del proceso ORSA siempre y cuando estos índices pudiesen ser utilizados para proyectar ciertas variables actuariales, este estudio se ha realizado para el Actuarial Climate Index original por lo que a continuación se le va a dedicar un epígrafe donde se comentaran los resultados que se han extraído del desarrollo del Actuarial Climate Risk Index por la American Actuarial Academy (2020).

Otro posible uso es como elemento disuasorio y preventivo de elemento extraordinarios si se pudiesen demostrar indicadores adelantados.

⁹ <https://corporatesolutions.swissre.com/dam/jcr:9632f8a3-85c5-4d3a-9ead-4a6a0cba9ca9/STORM-parametric-windstorm-solutions.pdf>

5. INDICE DE RIESGO CLIMÁTICO ACTUARIAL

5.1 Metodología

5.1.1 Propósito

El Actuarial Climate Risk Index, ACRI en adelante, surge de la búsqueda de respuesta a la pregunta, ¿cuánto daño ha generado el cambio de clima con respecto al periodo de referencia 1961-1990? (American Actuarial Academy [AAA] , 2020).

Así pues, la American Actuarial Academy (2020) desarrolla un estudio preliminar en que trata de responder a esta incógnita.

Otros propósitos que pueden verse cubiertos en la búsqueda de respuesta a esta pregunta es mediante cuatro variables climáticas modelizar la relación entre los cambios en el clima y el daño a la vida humana y propiedades.

Esto permite dar un control de la exposición al riesgo, así como permite identificar posibles comportamientos estacionarios a nivel macro pero sin llegar a un alto nivel de granularidad.

Durante el desarrollo de la respuesta, la AAA decide a qué tipo de modelización se asemeja más el ACRI. En este caso, concluyen que se asemeja más a una modelización cuyo objetivo encuadra en la definición de Disaster Risk Index. (American Actuarial Academy, 2020).

Este tipo de modelización tiene por objetivo desarrollar una metodología que permita estimar cuanto daño, ya sean número de fallecidos o cantidad monetaria, para cada país. Basándose en fenómenos climáticos y la situación socioeconómica del país en cuestión.

A su vez, este tipo de modelización es más sencillo que otros tipos de modelización Cat-Nat, como lo son los modelos integrados o modelos catastróficos, pues tan solo muestra el impacto de la situación socioeconómica en pérdidas humanas y materiales a causa de Cat-Nat.

5.1.2 Dato

Para la modelización del ACRI la AAA (2020), hace uso de la base de datos SHELDUS. (Center for Emergency Management and Homeland Security, 2020). Que contiene información desde 1961 y de 18 tipos de eventos climáticos como avalanchas, tornados, sequias, tsunamis o bancos de niebla entre otros.

A su vez, esta base de datos ofrece información del lugar de ocurrencia de dicho evento, así como el importe estimado para los daños provocados por dicho evento.

El ACI, al ser originalmente construido para Norteamérica, también se valoró incorporar una base de datos para siniestros canadienses, pero finalmente fue descartada por el poco volumen que presentaban las bases de datos. (AAA, 2020)

5.1.3 Modelización

A la hora de modelizar, el primer comentario que hace la AAA, es la eliminación de dos de las variables que componen el ACI, siendo excluidas, la variable número de días consecutivos sin precipitación por ser la única variable cuyo dato mensual es estimado a partir de dato anual y la variable nivel del mar por no estar presente en todas las regiones.

En cuanto a la exposición al riesgo, como el análisis se ha decidido hacer sobre property (no vida), se procede a estimar lo que llaman “Property at Risk” que trata de estimar el valor de las propiedades de una región, para ello, toman la mediana del valor las propiedades de un área y lo multiplican por el número de propiedades en el área. (AAA, 2020)

Otros comentarios que hace la AAA, es acerca de la dimensión geográfica, matizando que el cálculo se hace por regiones calculando los parámetros para cada región por su heterogeneidad ente las mismas. (AAA, 2020).

Otro matiz que hacen es el comportamiento estacional del clima lo que explica su decisión de estimar los parámetros por región y mes.

A continuación, se presentarán los modelos candidatos que presenta la American Actuarial Academy en el ACRI publicado en 2020.

5.1.3.1 Modelo A

Fórmula 5.1.1. Modelo A AAA (2020)

$$Loss = I * Exposure^e * Precipitation^p * LowTemperature^l * High Temperature^h * Wind^w$$

Siendo:

Fuente: AAA (2020) basado en Peuzzi (2009)

Loss: Pérdidas en propiedades de la región, en dólares.

I: Deriva.

Exposure: Exposición estimada mediante la metodología mencionada anteriormente.

Precipitation, Low Temperature, High Temperature, Wind variables calculadas y explicadas en el ACI.

e,p,l,h,w: coeficientes en caso de que la variable del ACI sea significativa.

En búsqueda de facilidad a la hora de la estimación de los parámetros, se procede a transformar el anterior modelo mediante logaritmos, obteniéndose:

5.1.3.2 Modelo B

Fórmula 5.1.2. Modelo Ln(A) AAA (2020)

$$\begin{aligned} \ln(Loss) = & \ln(I) + \ln(Exposure) * e + \ln(Precipitation) * p + \ln(Low Temperatures) * l \\ & + \ln(High Temperatures) * h + \ln(wind) * w \end{aligned}$$

Fuente: AAA (2020)

Una vez definidos los modelos, se muestran en la siguiente tabla los resultados de la estimación de los parámetros y su correspondiente nivel de significatividad basados en los resultados obtenidos para cada región (8) y mes.

Tabla 5.1.1. Resumen de los parámetros estimados significativos al 90%.

Variable	Veces significativo al 90%	Media para cada región y mes de los parámetros de la variable significativa	Media para todos los parámetros
Exposure	70%	1,84	1,29
Rx5Day	54%	4,13	2,21
T10	12%	1,12	0,13
T90	195	1,11	0,21
Wind	15%	2,80	0,42

Fuente: AAA (2020)¹⁰

5.2 Resultados y Conclusión

Para la construcción del ACRI es necesario mencionar ciertas características inherentes de la construcción de este y que se han de cumplir según AAA (2020).

1. La suma de las pérdidas estimadas por el ACRI durante el periodo de referencia ha de ser cero.
2. Las pérdidas estimadas por el ACRI para una variable no significativa del ACI ha de ser cero.
3. La correlación parcial entre la exposición y las pérdidas estimadas por el ACRI debe ser cero pues el ACRI busca reflejar los cambios del clima, no de la exposición.

Durante la construcción del ACRI la AAA se dio cuenta de los pobres resultados que estaba dando el modelo, así que decidió analizar las fuentes de incertidumbre del modelo. Habiendo dos posibles fuentes intrínsecas y extrínsecas.

Definiendo como incertidumbre intrínseca la asociada a la incertidumbre del ajuste de la ecuación e incertidumbre extrínseca a la asociada a las particularidades de la distribución de las variables del clima. (AAA, 2020).

¹⁰ <https://www.actuary.org/sites/default/files/2020-01/ACRI.pdf>

Tabla 5.1.2. Pérdidas Estimadas ACRI, observadas y ajustadas a la exposición por región*Dato en billones americanos de USD.*

	ACRI	Observed Losses	Exposure-Adjusted Losses
USA	23,78	493,61	711,95
ALA	0,01	0,51	0,72
CEA	-3,00	51,53	60,71
CWP	-0,16	5,39	8,19
MID	0,28	57,07	79,54
SEA	22,42	277,65	420,84
SPL	2,69	65,81	92,18
SWP	1,55	35,65	49,77

Fuente: AAA (2020)¹¹

Observándose como lo resultados entre los valores del ACRI y las observaciones reales son débiles y que incluso el ACRI estima que para momentos del tiempo en el que el clima experimenta condiciones menos severas que lo que se toma como clima de referencia el ACRI estima como una especie de recobros o de ganancias que no deberían darse.

Finalmente, la AAA concluye con una serie de limitaciones que serán tratadas de corregir para la próxima versión 2.0.

Estas limitaciones se resumen en los siguientes puntos que publica la AAA (2020).

- El modelo arroja un r-cuadrado de 0,62 para el modelo transformado a logaritmos.
- Los coeficientes de la ecuación son inconsistentes entre meses para una región dada.
- El modelo funciona mejor a nivel agregado nacional que por región arrojando un r-cuadrado de 0,36 vs. 0,24.
- El modelo presenta un alto nivel de incertidumbre.

¹¹ <https://www.actuary.org/sites/default/files/2020-01/ACRI.pdf>

6. LIMITACIONES INDICE CLIMATICO ACTUARIAL.

Durante la construcción de este índice español siguiendo los documentos oficiales no se han encontrado referencia a filtros ante dato anómalo o erróneo, se entiende que es un trabajo que se ha tenido que realizar durante el mismo, como se ha realizado durante la construcción de esta versión.

Utilizan diferentes proveedores de datos, pudiendo ser interesante que solamente hubiese un único proveedor de reconocido prestigio y con una mayor granularidad geográfica y temporal.

También sería necesario ajustar cada índice climático actuarial a la realidad geográfica de cada país, pues países de interior no tendría sentido calcular la variable nivel del mar, pero quizás el nivel del caudal de los ríos podría ser de gran interés.

Otra variable que podría incorporarse para países con un fuerte componente marítimo sería la variable temperatura del mar, puesto que se viene experimentando desde 1980 anomalías positivas para la temperatura del mar, según JFAR (2022). Lo que provoca el agotamiento del oxígeno en el mar, provocando el fallecimiento de muchas especies y ecosistemas, como podemos observar en BBC (2023). A raíz de esto también existen índices que miden la cantidad de oxígeno en el mar pudiendo ser interesante según el país su incorporación, más información puede encontrarse en Strips (2013).

Si se abandona el enfoque puramente centrado en la frecuencia de los eventos anómalos estrictamente climáticos y se plantea la incorporación de variables que muestren eventos que pudiesen estar relacionados, como la frecuencia de incendios con un área afectada mayor a un número x de hectáreas, así como variables si fuese posible que indicase si realmente se está reduciendo la emisión de carbono vía impuestos al carbono o simplemente aplicar escenarios para intentar conseguir información prospectiva del índice.

Hay que mencionar que existen alternativas a estos índices como podrían ser índices basados en ranking que proveen de una puntuación para cada país, siendo esa puntuación un indicador de riesgo puro en cuanto a riesgo climático, no dando información sobre impactos económicos.

Estos índices lo que tratan es capturar estimaciones de impactos económicos, puntuaciones de exposición a riesgos climáticos y las capacidades de cada país para enfrentar el cambio climático.

Swiss Re (2021b), reporta una descripción de la metodología que siguen para la construcción de este índice. En dicho documento explican las tres fases que siguen, en primer lugar, mencionar que Swiss Re divide las “fuerzas climáticas” en dos tipos, las crónicas como puede ser el incremento del mar, o eventuales en la que consideran eventos como inundaciones. Posteriormente si es un evento crónico, procede a calcular impactos en el PIB del país mediante escenarios con ayuda d Moody’s Analytics para cada variable, por otro lado, si estamos ante una variable eventual tal como las inundaciones Swiss Re extrae unas puntuaciones en base a la metodología que se puede encontrar en Lüthi et al. (2020). Y por último a estos dos pasos comentados anteriormente se le une un tercero en el cual agregan estas variables e incorporan la capacidad adaptativa de cada país en concreto.

7. CONCLUSIONES.

Este tipo de índices, solos o relacionados con alguna variable tienen varios agentes interesados como las entidades aseguradoras llegando hasta el público general y pasando por los gobiernos.

En cuanto a las entidades aseguradoras, estas pueden utilizarlo para la construcción de seguros paramétricos o incluso para incorporarlos, si dichos índices pudiesen ser proyectables, en el proceso ORSA. También podrían ser utilizados como driver que les permitiese mediante la demostración de la relación entre el índice y una línea de negocio o riesgo concreto lo que les permitiría incorporar un margen climático en la estimación de las reservas de la compañía o en la tarificación ajustándose lo máximo posible al riesgo real.

Dicha relación entre índice y variable abre una ventana de investigación de vital interés como se ha comentado en este TFM, donde ya se comienza a trabajar en una versión del índice por estaciones que pudiese relacionarse con las muertes atribuidas a exceso de calor que nos proporciona el MoMo.

Otro agente beneficiado son los inversores públicos y privados, y es que estas herramientas podrían proveer de la capacidad de poder generar escenarios a largo plazo permitiendo incorporar esta información en la planificación de inversiones en determinadas áreas, permitiéndoles tomar decisiones más acordes con objetivos climáticos y aportando valor a la sociedad.

También es gran ayuda a los gobiernos, pues la apuesta por este tipo de índices como se ha comentado puede llegar a aportar una perspectiva a largo plazo lo que permitiría comenzar a preparar posibles planes de resiliencia ante el incremento en la frecuencia e intensidad de eventos extremos climáticos, para los que los diferentes estados deberán estar con antelación lo suficientemente preparados, pues pese a estar hablando de posibles tendencias a largo plazo durante el mismo se vienen generando episodios de eventos anómalos climáticos o catástrofes naturales dónde la velocidad de toma de decisión o un ejercicio de prevención puede suponer una reducción drástica de las pérdidas humanas y económicas.

En cuanto al público en general, el hacer público las visualizaciones, construcción y dato permite generar a la población una opinión y argumentos robustos para continuar con su concienciación sobre el cambio climático, así como, la posibilidad de incorporar esta información en la toma de decisiones desde lo más cotidiano como puede ser la compra diaria o incluso a la hora de llevar a cabo una inversión.

8. REFERENCIAS

- Abatzoglou, J. T., Dobrowski, S. Z., Parks, S. A., y Hegewisch, K. C. (2018). *TerraClimate, a high-resolution global dataset of monthly climate and climatic water balance from 1958–2015*. [Dataset]. <https://doi.org/10.1038/sdata.2017.191>
- Agencia Estatal de Meteorología, (2002). *Mínimos de diciembre de 2001*. <https://www.aemet.es/es/noticias/2002/01/Ola>
- Agencia Estatal de Meteorología, (2019). *Febrero de 2019, un mes de récords*. https://www.aemet.es/documentos/es/noticias/2019/avance_climatico_feb_2019.pdf
- Agencia Estatal de Meteorología, (2020). *Comportamiento de las precipitaciones en España y periodos de sequía (Periodo 1961-2018)*.
- Agencia Estatal de Meteorología, (2022a). *Informe sobre el estado del clima de España 2021*. https://www.aemet.es/documentos/es/conocerlas/recursos_en_linea/publicaciones_y_estudios/publicaciones/Informes_estado_clima/Resumen_ejecutivo_informe_clima_2021.pdf
- Agencia Estatal de Meteorología, (2022b). *Avance Climático Nacional del invierno 2021-2022*. https://www.aemet.es/es/noticias/2022/03/rueda_prensa_estacional_primavera_2022#enlaces_asociados
- Agencia Estatal de Meteorología, (2023a). *AEMET OpenData*. [Dataset]. https://www.aemet.es/es/datos_abiertos
- Agencia Estatal de Meteorología, (2023b). *Informe sobre el estado del clima de España 2022*. https://www.aemet.es/documentos/es/conocerlas/recursos_en_linea/publicaciones_y_estudios/publicaciones/Informes_estado_clima/IECLI_2022_baja_res.pdf
- American Academy of Actuaries, Canadian Institute of Actuaries, Casualty Actuarial Society, Society of Actuaries. (2018a). *Actuaries Climate Index Executive Summary*. <https://actuariesclimateindex.org/wp-content/uploads/2016/04/ACI.ExecutiveSummary5.18.pdf>
- American Academy of Actuaries, Canadian Institute of Actuaries, Casualty Actuarial Society, Society of Actuaries. (2018b). *Actuaries Climate Index Development and Design*. <https://actuariesclimateindex.org/wp-content/uploads/2019/05/ACI.DevDes.2.20.pdf>
- American Academy of Actuaries, Canadian Institute of Actuaries, Casualty Actuarial Society, Society of Actuaries. (2018c). *Sample Calculations*. <https://actuariesclimateindex.org/wp-content/uploads/2019/05/SampleCalcEng.5.19.pdf>
- Arkema, K., Guannel, G., Verutes, W., (2013). Coastal habitats shield people and property from sea-level rise and storms. *Nature ClimChange*, 77(3), 913–918 <https://doi.org/10.1038/nclimate1944>
- BBC. (13 de junio, 2023). Thousands of fish wash up on Texas coast. *BBC*. <https://www.bbc.com/news/av/world-us-canada-65885497>
- Booij, N., Holthuijsen, L.H. y R.C. Ris (1996). The SWAN wave model for shallow water, *Proc. 25th Int. Conf. Coastal Engng.*,1, 668-676. <https://doi.org/10.9753/icce.v25.%25p>

Center for Emergency Management and Homeland Security, Arizona State University. (2022). Spatial Hazard Events and Losses Database for the United States, Version 20.0 [Dataset].

Cornes, R., van der Schrier, G., van den Besselaar, E.J.M., y Jones, P.D. (2018). *An Ensemble Version of the E-OBS Temperature and Precipitation* [Dataset]. <https://doi.org/10.1029/2017JD028200>

Crisóstomo Mazaría, C. (2022). *Modelo actuarial de la medida del impacto del cambio climático en los riesgos de mortalidad y longevidad*. [Trabajo fin de máster, Universidad Carlos III de Madrid]. E-Archivo. https://e-archivo.uc3m.es/bitstream/handle/10016/36527/TFM_CCAAFF_Carlos_Crisostomo_Mazarira_2022.pdf?sequence=3

Delft University of Technology, Deltares, and UNESCO-IHE Institute for Water Education. (2010). *XBeach model* [Software].

Donat, M. G. (2013b). *Updated analyses of temperature and precipitation extreme indices since the beginning of the twentieth century: The HadEX2 dataset*. [Dataset].

Donat, M.G., Alexander L.V., Yang, H.,Durre, I.,Vose y R.,Caesar, J. (2013a). *Global Land-Based Datasets for Monitoring Climatic Extremes*. [Dataset]. <http://dx.doi.org/10.1175/BAMS-D-12-00109.1>

EFE, (2005). *Meteorología (INM) asegura que España sufre la peor ola de frío en 20 años*. <https://www.elmundo.es/elmundo/2005/01/27/sociedad/1106830455.html>

El Confidencial, (2017). *No es la "peor sequía en 20 años", será la peor de la historia de España: el desastre en datos"* https://www.elconfidencial.com/tecnologia/ciencia/2017-11-26/deje-decir-sequia-2017-peor-de-la-historia-espana_1482616/

El Confidencial, (2021). *Acostúmbrate a las DANA: por qué las lluvias torrenciales serán la norma a partir de ahora* https://www.elconfidencial.com/tecnologia/ciencia/2021-09-03/acostumbrate-dana-lluvias-torrenciales-norma_3268162/

El Confidencial, (2022a). *El nivel del mar no ha parado de crecer: aumenta unos tres centímetros por decenio desde los años 90*. https://www.lespanol.com/enclave-ods/noticias/20220212/nivel-no-parado-crecer-aumenta-centimetros-decenio/649435463_0.html

El Confidencial, (2022b). *El plan del Gobierno para evitar que Málaga quede inundada por la subida de nivel del mar*. https://www.lespanol.com/enclave-ods/noticias/20220420/gobierno-evitar-malaga-queda-inundada-subida-nivel/666433469_0.html

Hallegatte, S., Green, C., Nicholls, R., Corfee.Morlot J., (2013). Future flood losses in major coastal cities. *Nature Clim Change* 3, 802–806 <https://doi.org/10.1038/nclimate1979>.

Hawkins, E. (2018). Warming Stripes. *Climate Lab Book*. <https://www.climate-lab-book.ac.uk/2018/warming-stripes/>.

Holgate, J.S.,Matthews, A., Philip,Woodworth, L.,Rickards, L.J.,Mark, Tamisiea, E., Bradshaw, E.,Foden P.R., Gordon, K.M.,Jevrejeva, S. y Pugh, J. (2013). *New Data Systems and Products at the Permanent Service for Mean Sea Level*. [Dataset]. <https://doi.org/10.2112/JCOASTRES-D-12-00175.1>

Institute and Faculty of Actuaries. (2015). *Extension of the Actuaries Climate Index to the UK and Europe a feasibility study*. https://www.actuaries.org.uk/system/files/field/document/UK_ACI_scoping_FINAL.pdf

Intergovernmental Panel on Climate Change. (2021). *Summary for Policymakers*. In: *Climate Change 2021: The Physical Science Basis. Contribution of Working Group I to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change*.

Joint Forum on Actuarial Regulation. (2022). *The Science of Climate Change*.

Kalnay, E., Kanamitsu, M., Kistler, R., Collins, W., Deaven, D., Gandin, L., Iredell, M., Saha, S., White, G., Woollen, J., Zhu, Y., Chelliah, M., Ebisuzaki, W., Higgins, W., Janowiak, J., Mo, K.C., Ropelewski, C., Wang, J., Leetmaa, A., . . . Joseph, D. (1996). The NCEP/NCAR 40-Year Reanalysis Project. *Bulletin of the American Meteorological Society*, 77(3), 437-471. <https://doi.org/fg6rf9>.

Lindsey R Scott M, (18 de Octubre,2022). Climate Change: Arctic Sea ice summer minimum. *Climate.gov*. <https://www.climate.gov/news-features/understanding-climate/climate-change-arctic-sea-ice-summer-minimum>

Lüthi, S., Gloor, M., & Walz, M. (2020). *Climate risk score – a framework to quantify an insurance portfolio's exposure and contribution to climate change*. <https://doi.org/10.5194/egusphere-egu2020-9877>

MAPFRE S.A. (2019). *Cuentas Anuales e Informe de Gestión Consolidado*. https://www.mapfre.com/statics/juntasgenerales/2020/Cuentas_anuales_e_informes_gestion_consolidados.pdf

MAPFRE S.A. (2021). *Cuentas Anuales Consolidadas*. <https://www.mapfre.com/media/accionistas/2022/05-informe-anual-consolidado-2021.pdf>

MAPFRE S.A. (2022). *Cuentas Anuales e Informe de Gestión Consolidado*. <https://www.mapfre.com/media/accionistas/2022/cuentas-anuales-e-informe-gestion-individuales-2022.pdf>

Menne, M. J., Imke, D., Korzeniewski, B., McNeill, S., Thomas, K., Xungang, Y., Anthony, S., Ron, R., Russell, S., Vose, E. y Tamara, G. (2012): *Global Historical Climatology Network - Daily (GHCN-Daily), Version 3*. [Dataset] <https://doi.org/10.7289/V5D21VHZ>

Milliman Climate Resilience Forum. (02-04 de marzo, 2021) Spencer Glendon. *Its more profound than you think. The risk posed by climate change*. [Video]. https://players.brightcove.net/5716634434001/YaL1J8g8di_default/index.html?videoId=6260857412001

Ministerio para la Transición Ecológica y el Reto Demográfico, (2022). *Ficha de casos: Ola de calor de julio de 2022. Plan nacional de adaptación al cambio climático 2021-2030*.

Ministerio para la Transición Ecológica y el Reto Demográfico, (2023). *2022 continúa la tendencia y se posiciona como el año más cálido en España desde que hay registros*. https://www.miteco.gob.es/es/prensa/230123np_resumenclimatico_2022_tcm30-552262.pdf

Ministerio para la Transición Ecológica y el Reto Demográfico, (2022). *Balance Climático de Julio de 2022*. https://www.miteco.gob.es/es/prensa/220808np_balance_climatico_julio_tcm30-543826.pdf

National Oceanic and Atmospheric Administration. (01 de abril, 2020). Ocean acidification. *NOAA Resources*. <https://www.noaa.gov/education/resource-collections/ocean-coasts/ocean-acidification>

Nature. (2022). The Nature Conservancy Announces First-Ever Coral Reef Insurance Policy in the U.S.

Ocean Risk and Resilience Action Alliance. (2022). Action Report for 2022. <https://oceanriskalliance.org/wp-content/uploads/Action-Report-2022-24-Feb-2023-FINAL.pdf>

Peduzzi, P., Dao, H., Herold, C., & Mouton, F. (2009). Assessing global exposure and vulnerability towards natural hazards: the Disaster Risk Index. *Nat. Hazards Earth Syst. Sci.*, 9, 1149–1159. <https://doi.org/10.5194/nhess-9-1149-2009>

Permanent Service for Mean Sea Level (2023), *Tide Gauge Data*, [Dataset] <http://www.psmsl.org/data/obtaining/>

Reading University (2020). Climate stripes Representing global temperature rise over two centuries. <https://www.reading.ac.uk/planet/climate-resources/climate-stripes>.

Reguero, B. G., Beck, M. W., Schmid, D., Stadtmüller, D., Raeppe, J., Schüssele, S., y Pfliegner, K. (2020). Financing coastal resilience by combining nature-based risk reduction with insurance. *Ecological Economics*. Volumen 162. <https://doi.org/10.1016/j.ecolecon.2019.106487>

Royé D. (08 de marzo, 2022). Uso de datos multidimensionales espaciales. *Geographic data. Understanding the World*. <https://dominicroye.github.io/es/2022/uso-de-datos-multidimensionales-espaciales/>

Saffir, H. (1973). *The Military Engineer*.

Serrano-Notivoli R. (13 de agosto, 2018) Las Rachas Secas en España. *Geografía Infinita*. <https://www.geografiainfinita.com/2018/08/cuanto-puede-estar-sin-llover-en-espana-las-rachas-secas/>

Simpson, R.,(1974). *Weatherwise*.

Stips, A. (2013). EMIS - Oxygen Depletion Risk Index. European Commission, Joint Research Centre (JRC) [Dataset] <http://data.europa.eu/89h/cb0eab6e-0221-486e-b128-56d4aa0c11d3>

Storlazzi, C.D., Reguero, B.G., Cole, A.D., Lowe, E., Shope, J.B., Gibbs, A.E., Nickel, B.A., McCall, R.T., van Dongeren, A.R., and Beck, M.W., (2019). Rigorously valuing the role of U.S. coral reefs in coastal hazard risk reduction. *U.S. Geological Survey Open-File Report 2019–1027*, 42, <https://doi.org/10.3133/ofr20191027>.

Storlazzi, C.D., Reguero, B.G., Cole, A.D., Lowe, E., Shope, J.B., Gibbs, A.E., Nickel, B.A., McCall, R.T., van Dongeren, A.R., and Beck, M.W., (26 de abril, 2018). *Rigorously valuing the role of U.S. coral reefs in coastal hazard risk reduction*. [Video]. <https://www.usgs.gov/media/videos/pubtalk-42018-coral-reefs>

Swiss Re (16 de septiembre, 2022a). Parametric insurance – a long history, a bright future. *Swiss Re Corporate Solutions*. <https://corporatesolutions.swissre.com/insights/knowledge/evolution-of-parametric-insurance.html>

Swiss Re (2022b) STORM A parametric data-based insurance solution. <https://corporatesolutions.swissre.com/dam/jcr:9632f8a3-85c5-4d3a-9ead-4a6a0cba9ca9/STORM-parametric-windstorm-solutions.pdf>

Swiss Re. (14 de diciembre, 2021a). Global insured catastrophe losses rise to USD 112 billion in 2021, the fourth highest on record. Swiss Re. Desde: <https://www.swissre.com/media/press-release/nr-20211214-sigma-full-year-2021-preliminary-natcat-loss-estimates.html>

Swiss Re. (2021b). The economics of climate change: no action not an option. *Swiss Re Institute*. <https://www.swissre.com/dam/jcr:e73ee7c3-7f83-4c17-a2b8-8ef23a8d3312/swiss-re-institute-expertise-publication-economics-of-climate-change.pdf>


Yates, K. K., Zawada, D. G., Smiley, N. A., y Tiling-Range, G. (2017). Divergence of seafloor elevation and sea level rise in coral reef ecosystems. *Biogeosciences*, 14(6), 1739. <https://doi.org/10.5194/bg-14-1739-2017>

Zhang, X., Hegerl, G., Zwiers, F. y Kenyon, J. (2005). *Avoiding Inhomogeneity in Percentile-Based Indices of Temperature Extremes*. <https://doi.org/10.1175/JCLI3366.1>


9. ANEXO

9.1 Anexo Figuras

ACI MADRID




ACI BARCELONA




*Barcelona no incluye la variable viento por errores en el dato.


ACI MÁLAGA




ACI BILBAO



ACI SEVILLA




ACI SORIA




9.2 Anexo Warming Stirpes

Stripes MADRID




Stripes BARCELONA



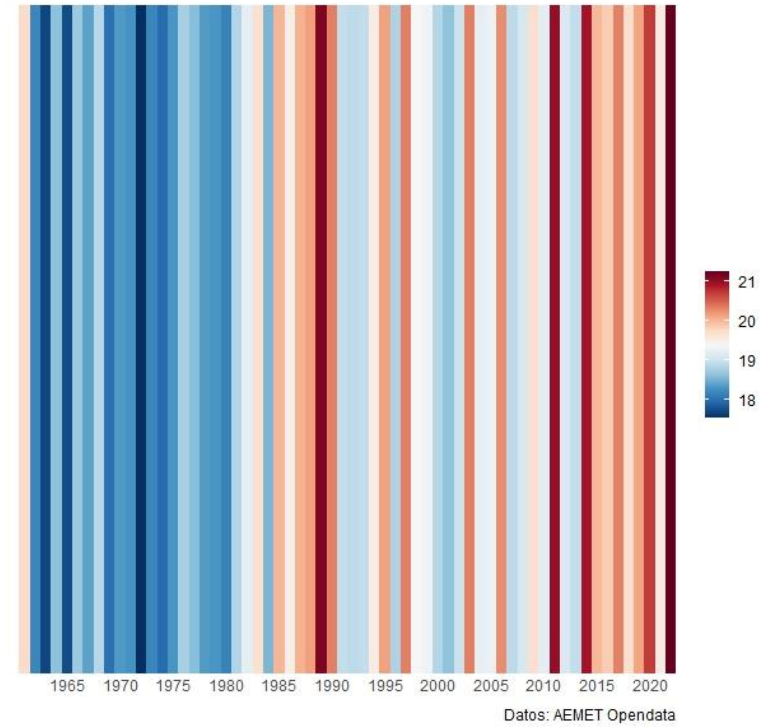
Stripes MÁLAGA

MÁLAGA 1961-2022




Stripes BILBAO

BILBAO 1961-2022




Stripes SEVILLA

SEVILLA 1961-2022



Stripes SORIA

SORIA 1961-2022



9.3 Anexo Código

```
#####
#Calculo de la variables para el spartial data del ACI original
#####

rm(list=ls())
options(scipen = 999)

#Packetería
library(writexl)
library(raster)
library(RNetCDF)
library(ggplot2)
library(gridExtra)
library(grid)
library(ncdf4)
library(dplyr)
library(cowplot)
library(openxlsx)
library(reshape2)
library(grid)
library(scales)

#Carga de dato

setwd("C:/Users/ROYORUI/OneDrive - MAPFRE/Escritorio/TFM/ghcndex-gridded-
20230304")

data_rain<-raster("GHCND_Rx5day_1951-
2023_RegularGrid_global_2.5x2.5deg_m4.nc")

print(data_rain)

plot(data_rain)

data_rain_r<-rotate(data_rain)

plot(data_rain_r)

#formato df

df <- as.data.frame(data_rain_r, xy = TRUE)

#Paleta
```

```

# define jet colormap
jet.colors <- colorRampPalette(c("#00007F", "blue", "#007FFF", "cyan",
"#7FFF7F", "yellow", "#FF7F00", "red", "#7F0000"))

#graf 1
ggplot() +
  geom_raster(data = df, aes(x=df$x, y=df$y, fill=df$Jan)) +
  scale_fill_gradientn(colors = jet.colors(7), limits = c(0,100),
na.value = "white") +
  coord_quickmap()+
  borders()+
  theme(axis.text.x=element_blank(),
        axis.text.y=element_blank(),
        axis.ticks =element_blank(),
        axis.title.y =element_blank(),
        axis.title.x=element_blank(),
        rect=element_blank())

#graf 2
ggplot(df, aes(y=df$y, x=df$x, color=df$Jan)) +
  geom_point(size=3, shape=15) +
  borders('world', xlim=range(df$x), ylim=range(df$y), colour='black')
+
  scale_color_distiller(palette='Spectral') +
  coord_map('ortho', orientation = c(40, -40, 0))

#Con Stack pillo todas las variables que son meses.

all_data_rain<-stack("GHCND_Rx5day_1951-
2023_RegularGrid_global_2.5x2.5deg_m4.nc", varname="Jan")
print(all_data_rain)

#los extraemos para cada mes.
#Extraer ubicación
#Central Parkj
#y= latitud 40
#x = longitud -72.5

months=c("Jan", "Feb", "Mar", "Apr", "May", "Jun", "Jul", "Aug", "Sep", "Oct", "Nov", "Dec")
folder_name<-"GHCND_Rx5day_1951-2023_RegularGrid_global_2.5x2.5deg_m4.nc"

#Jan
rain_jan<-stack(folder_name, varname=months[1])
rain_jan_r<-rotate(rain_jan)

```

```

df <- as.data.frame(rain_jan_r, xy = TRUE)
step1<-df[df$x== -72.5,]
rain_jan_CP<-step1[step1$y==40,]

#Feb
rain_feb<-stack(folder_name, varname=months[2])
rain_feb_r<-rotate(rain_feb)
df <- as.data.frame(rain_feb_r, xy = TRUE)
step1<-df[df$x== -72.5,]
rain_feb_CP<-step1[step1$y==40,]

#Mar
rain_mar<-stack(folder_name, varname=months[3])
rain_mar_r<-rotate(rain_mar)
df <- as.data.frame(rain_mar_r, xy = TRUE)
step1<-df[df$x== -72.5,]
rain_mar_CP<-step1[step1$y==40,]

#Apr
rain_apr<-stack(folder_name, varname=months[4])
rain_apr_r<-rotate(rain_apr)
df <- as.data.frame(rain_apr_r, xy = TRUE)
step1<-df[df$x== -72.5,]
rain_apr_CP<-step1[step1$y==40,]

#May
rain_may<-stack(folder_name, varname=months[5])
rain_may_r<-rotate(rain_may)
df <- as.data.frame(rain_may_r, xy = TRUE)
step1<-df[df$x== -72.5,]
rain_may_CP<-step1[step1$y==40,]

#Jun
rain_jun<-stack(folder_name, varname=months[6])
rain_jun_r<-rotate(rain_jun)
df <- as.data.frame(rain_jun_r, xy = TRUE)
step1<-df[df$x== -72.5,]
rain_jun_CP<-step1[step1$y==40,]

#Jul
rain_jul<-stack(folder_name, varname=months[7])
rain_jul_r<-rotate(rain_jul)
df <- as.data.frame(rain_jul_r, xy = TRUE)
step1<-df[df$x== -72.5,]
rain_jul_CP<-step1[step1$y==40,]

#Aug
rain_aug<-stack(folder_name, varname=months[8])
rain_aug_r<-rotate(rain_aug)

```

```

df <- as.data.frame(rain_aug_r, xy = TRUE)
step1<-df[df$x== -72.5,]
rain_aug_CP<-step1[step1$y==40,]

#Sep
rain_sep<-stack(folder_name, varname=months[9])
rain_sep_r<-rotate(rain_sep)
df <- as.data.frame(rain_sep_r, xy = TRUE)
step1<-df[df$x== -72.5,]
rain_sep_CP<-step1[step1$y==40,]

#Oct
rain_oct<-stack(folder_name, varname=months[10])
rain_oct_r<-rotate(rain_oct)
df <- as.data.frame(rain_oct_r, xy = TRUE)
step1<-df[df$x== -72.5,]
rain_oct_CP<-step1[step1$y==40,]

#Nov
rain_nov<-stack(folder_name, varname=months[11])
rain_nov_r<-rotate(rain_nov)
df <- as.data.frame(rain_nov_r, xy = TRUE)
step1<-df[df$x== -72.5,]
rain_nov_CP<-step1[step1$y==40,]

#Dic
rain_dic<-stack(folder_name, varname=months[12])
rain_dic_r<-rotate(rain_dic)
df <- as.data.frame(rain_dic_r, xy = TRUE)
step1<-df[df$x== -72.5,]
rain_dic_CP<-step1[step1$y==40,]

#Combinamos row

dato_mensual<-rbind(rain_jan_CP,rain_feb_CP,rain_mar_CP,rain_apr_CP,
                    rain_may_CP,rain_jun_CP,rain_jul_CP,rain_aug_CP,
                    rain_sep_CP,rain_oct_CP,rain_nov_CP,rain_dic_CP)

#Quitamos 2023
#Quitamos variables de latitud y longitud

dato_mensual_1=as.matrix.data.frame(dato_mensual)
dato_mensual_1=dato_mensual_1[,c(-1,-2,-75)]
dimnames(dato_mensual_1) <- list(month.abb[1:12], c(1951:2022))
dato_mensual<-as.data.frame(dato_mensual_1)

#Formato para gráfico

```

```

dato_formateado<-matrix(0,(72*12),1)
w=1
for (j in 1:72){
  for(i in 1:12){
    dato_formateado[w,1]=dato_mensual[i,j]
    w=w+1
  }
}

dimnames(dato_formateado)<-list(seq(from=as.Date("1951-01-01"),
to=as.Date("2022-12-01"), by="months"))

#pillo solo desde 1960
x<-seq(from=as.Date("1960-01-01"), to=as.Date("2022-12-01"), by="months")

dato_formateado=dato_formateado[-c(1:108)]

df<-data.frame(x,dato_formateado)

attributes(df)

media_per_ref<-mean(df$dato_formateado[c(13:372)])
media_per_proy<-mean(df$dato_formateado[c(373:756)])

media_movil_rain<-roll_avrg(df$dato_formateado,k =12,date_origin = "1960-
01-01" )

ggplot(data=df, aes(x=media_movil_rain$x..c.1.k..,y =
media_movil_rain$datuki..c.1.k..))+
  geom_point()+
  geom_line(aes(x=media_movil_rain$x..c.1.k..,y=media_movil_rain$dumm))

#
media_movil_rain$x..c.1.k..=format(as.Date(media_movil_rain$x..c.1.k..),"
%Y")

x<-seq(from=as.Date("1960-01-01"), to=as.Date("2022-12-01"), by=1825)
x=format(as.Date(x),"%Y")

ggplot(data=media_movil_rain, aes(x=media_movil_rain$x..c.1.k..)) +
  geom_point(aes(y=media_movil_rain$datuki..c.1.k..)) +
  geom_line(aes(y=media_movil_rain$dumm,color="blue"),size=1.2)+
  labs(x="years",y="Maximum Precipitation")+
  scale_y_continuous(limits = c(0, 250), breaks = seq(0, 250, 15))+
  scale_fill_continuous(guide = guide_legend()+
  theme(rect=element_blank(),

```

```

    legend.position="bottom",
    legend.key = element_rect(fill = "white", colour = "black"))

# ggplot() +
#   geom_line(data = ruz, aes(date, val1, color = "a"), size = 1.5) +
#   geom_line(data = dfr, aes(date, val2 * 100, color = "b"), size = 1.5)
+
#   scale_color_manual(name = "Colors",
#                       values = c("a" = "blue", "b" = "red"))

#Media y Sd Periodo de referencia y periodo de observación

dato_mensual

dato_mensual=as.matrix(dato_mensual)

dato_mensual=dato_mensual[,-c(1:10)]

#Periodo de ref
mat_momentos<-matrix(0,8,12)

for(i in 1:12){
  mat_momentos[1,i]<-as.integer(mean(dato_mensual[i,-c(31:62)]))
  mat_momentos[2,i]<-as.integer(sd(dato_mensual[i,-c(31:62)]))
  mat_momentos[3,i]<-as.integer((mean(dato_mensual[i,-c(1:30)])))
  mat_momentos[4,i]<-as.integer((sd(dato_mensual[i,-c(1:30)])))
  mat_momentos[5,i]<-as.integer(mean(dato_mensual[i,-
c(31:62)])+sd(dato_mensual[i,-c(31:62)]))
  mat_momentos[6,i]<-as.integer(mean(dato_mensual[i,-
c(1:30)])+sd(dato_mensual[i,-c(1:30)]))
  mat_momentos[7,i]<-as.integer(mean(dato_mensual[i,-c(31:62)])-
sd(dato_mensual[i,-c(31:62)]))
  mat_momentos[8,i]<-as.integer(mean(dato_mensual[i,-c(1:30)])-
sd(dato_mensual[i,-c(1:30)]))
}

mat_momentos=round(mat_momentos,2)

dimnames(mat_momentos) <- list(c("Media Periodo 1961-1900", "sd Periodo
1961-1900", "Media Periodo 1991-2022", "sd Periodo 1991-2022", "Rango_Ref
Max", "Rango_Proj Max",
                                "Rango_Ref Min", "Rango_Proj Min"),
month.abb[1:12])

x<-
cbind(months,mat_momentos[1,],mat_momentos[3,],mat_momentos[2,],mat_momen
tos[4,])

```

```

x<-
rbind(months,mat_momentos[1,],mat_momentos[3,],mat_momentos[2,],mat_momentos[4,],mat_momentos[5,],mat_momentos[6,],mat_momentos[7,],mat_momentos[8,])
x<-rbind(months,mat_momentos[1,],mat_momentos[3,])

dimnames(x) <-
list(c("Meses", "Mean_ref", "Mean_proy", "Sd_ref", "sd_proy", "Rango_Ref_Max", "Rango_Proj_Max", "Rango_Ref_Min", "Rango_Proj_Min"))

months
mean_ref=as.integer(mat_momentos[1,])
mean_proy=as.integer(mat_momentos[3,])
# sd_ref=as.integer(mat_momentos[2,])
# sd_proy=as.integer(mat_momentos[4,])

x<-rbind(months,mean_ref,mean_proy)
df=as.data.frame(x)
df=as.data.frame(t(df))

#prueba
df2<-melt(df,id.vars = 'months')
ggplot(df2, aes(x=months, y=value, fill=variable)) +
  geom_bar(stat='identity', position='dodge')+
  scale_x_discrete(limits = month.abb)+
  scale_y_discrete(breaks = seq(from=45, to=68, by=5))

x<-
cbind(months,mat_momentos[1,],mat_momentos[3,],mat_momentos[2,],mat_momentos[4,])
x<-
rbind(months,mat_momentos[1,],mat_momentos[3,],mat_momentos[2,],mat_momentos[4,],mat_momentos[5,],mat_momentos[6,],mat_momentos[7,],mat_momentos[8,])
dimnames(x) <-
list(c("Meses", "Mean_ref", "Mean_proy", "Sd_ref", "sd_proy", "Rango_Ref_Max", "Rango_Proj_Max", "Rango_Ref_Min", "Rango_Proj_Min"))
df=as.data.frame(x)
df=as.data.frame(t(df))

# mat_momentos=as.data.frame(t(mat_momentos))

#formato
mformato<-matrix(0,24,6)

for(j in 1:2){
for(i in 1:12){

```

```

mformato[i,j]=x[j,i]
}
}
mformato[c(1:12),3]="Mean_ref"
mformato[c(1:12),4]=df$Rango_Ref_Max
mformato[c(1:12),5]=df$Rango_Ref_Min
mformato[c(1:12),6]=media_per_ref

for(i in 1:12){

  mformato[i+12,1]=x[1,i]
  mformato[i+12,2]=x[3,i]

}

mformato[c(13:24),3]="Mean_proy"
mformato[c(13:24),4]=df$Rango_Proj_Max
mformato[c(13:24),5]=df$Rango_Proj_Min
mformato[c(13:24),6]=media_per_proy
mformato[22,4]=95.64

mformato=as.data.frame(mformato)

names(mformato)

head(mformato)
#barras
ggplot(mformato, aes(x=V1, y=V2,fill=V3)) +
  geom_bar(stat="identity", position="dodge") +
  # geom_hline(yintercept = 20)+
  # geom_abline(media_movil_rain)+
  # geom_line(aes(x=mformato$V1, y=mformato$V6),stat="identity",color =
'red', size = 2)+
  geom_errorbar(aes(ymin=V5, ymax=V4),
width=.2,position=position_dodge(.9))+
  # geom_line(aes(y=media_per_proy, color="red"))+
  # scale_y_continuous(limits = c(20, 110))+
  scale_x_discrete(limits = month.abb)+
  scale_y_discrete(breaks = seq(from=0, to=100, by=5))+
  labs(x="Year",y="Number of Courses Sold")+
  theme(rect=element_blank(),
        legend.position="bottom",
        legend.key = element_rect(fill = "white", colour = "black"))

# Variaciones intermensuales de la precipitación máxima acumulada en los
ultimos 5 días

```



```

dato_mensual<-rbind(rain_jan_CP,rain_feb_CP,rain_mar_CP,rain_apr_CP,
                    rain_may_CP,rain_jun_CP,rain_jul_CP,rain_aug_CP,
                    rain_sep_CP,rain_oct_CP,rain_nov_CP,rain_dic_CP)

dato_formateado<-matrix(0,(72*12),1)
w=1
for (j in 1:72){
  for(i in 1:12){
    dato_formateado[w,1]=dato_mensual[i,j]
    w=w+1
  }
}

#pillo solo desde 1960
# x<-seq(from=as.Date("1960-01-01"), to=as.Date("2022-12-01"),
by="months")
# dato_formateado=dato_formateado[-c(1:108)]
# df<-data.frame(x,dato_formateado)
# mat_dif_rain<-matrix(0,755,1)

dato_mensual
mat_dif_rain<-c()
mat_momentos

w=1
for(j in 1:72){
  for(i in 1:12){

    mat_dif_rain[w]=(dato_mensual[i,j]-mat_momentos[1,i])

    w=w+1

  }
}

x<-seq(from=as.Date("1951-01-01"), to=as.Date("2022-12-01"), by="months")
# mat_dif_rain=mat_dif_rain[-c(1:108)]
df_diff<-data.frame(x[-c(1:120)],mat_dif_rain[-c(1:128)])

# Opcion1
# ggplot(df_diff, aes(x = df_diff$x..c.1.120.., y =
df_diff$mat_dif_rain..c.1.128..)) +
#   geom_bar(stat = "identity",width = 100,color="blue",fill="blue")+
#   labs(x="Year",y="Number of Courses Sold")+
#   scale_y_continuous(breaks = seq(-50, 200, by = 25))+
#   scale_x_date(breaks = date_breaks("5 year"),labels =
date_format("%Y"))+
#   theme(rect=element_blank()),

```

```

#       legend.position="bottom",
#       legend.key = element_rect(fill = "white", colour = "black"))+
# theme(panel.grid.major.y = element_line(color = "grey",size =
0.5,linetype = 1))

# Opcion 2
names(df_diff)
ggp2 <- ggplot(df_diff) +
  geom_bar(aes(x=x..c.1.120..,
y=mat_dif_rain..c.1.128..),stat="identity", fill="blue",colour="blue")+
  labs(x="Year",y="Number of Courses Sold")+
  scale_y_continuous(breaks = seq(-50, 200, by = 25))+
  scale_x_date(breaks = date_breaks("5 year"),labels =
date_format("%Y"))+
  theme(rect=element_blank(),
        legend.position="bottom",
        legend.key = element_rect(fill = "white", colour = "black"))+
  theme(panel.grid.major.y = element_line(color = "grey",size =
0.5,linetype = 1))
ggp2

# scale_x_date(breaks = seq(as.Date("1990-06-30"), as.Date("2015-06-30"),
by="1 year"),
              # labels = date_format("%Y"))

str_desv_rain<-c()

w=1
for(j in 1:72){
  for(i in 1:12){

    str_desv_rain[w]=(dato_mensual[i,j]-
mat_momentos[1,i])/mat_momentos[2,i]

    w=w+1

  }
}

x<-seq(from=as.Date("1951-01-01"), to=as.Date("2022-12-01"), by="months")
# mat_dif_rain=mat_dif_rain[-c(1:108)]
df_str_desv_rain<-data.frame(x[-c(1:120)],str_desv_rain[-c(1:120)])

media_movil_str_rain<-roll_avrg(str_desv_rain,60,date_origin = "1951-01-
01")

```

```

media_movil_str_rain=media_movil_str_rain[-c(1:60),]

ggp <- ggplot(media_movil_str_rain) +
  geom_bar(aes(x=x..c.1.k.., y=datuki..c.1.k..),stat="identity",
fill="blue",colour="blue")+
  geom_line(aes(x=x..c.1.k..,
y=dumm),stat="identity",color="red",size=2)+
  labs(x="Year",y="Number of Courses Sold")+
  scale_y_continuous(breaks = seq(-5, 10, by = 0.5))+
  scale_x_date(breaks = date_breaks("5 year"),labels =
date_format("%Y"))+
  theme(rect=element_blank(),
        legend.position="bottom",
        legend.key = element_rect(fill = "white", colour = "black"))+
  theme(panel.grid.major.y = element_line(color = "grey",size =
0.5,linetype = 1))
ggp

#####
#####
#####
#####
#           sea level           #
#####           #####
#####           #####
#####           #####
#####           #####
#####           #####
sea_data<-read.xlsx(xlsxFile =file.choose(),sheet = "sea_level")
sea_data

x<-seq(from=as.Date("1955-01-01"), to=as.Date("2022-12-01"), by="months")

sea_data$Date=x

media_movil_sea<-roll_avrg(sea_data$Milliliters,k = 12 ,date_origin =
"1955-01-01")

media_movil_sea=media_movil_sea[-c(1:60),]

names(media_movil_sea)

#opcion1
ggplot(data=media_movil_sea, aes(x=x..c.1.k..)) +
  geom_point(aes(y=datuki..c.1.k..)) +
  geom_line(aes(y=dumm,color="blue"),size=1.2)+
  labs(x="years",y="Maximum Precipitation")+

```

```

scale_y_continuous(limits = c(6800, 7700), breaks = seq(6800, 7700,
150))+
scale_fill_continuous(guide = guide_legend()+
theme(rect=element_blank(),
legend.position="bottom",
legend.key = element_rect(fill = "white", colour = "black")))+
theme(panel.grid.major.y = element_line(color = "grey",size =
0.5,linetype = 1))

```

#opcion2

```

ggp3 <- ggplot(media_movil_sea) +
geom_point(aes(x=x..c.1.k.,y=datuki..c.1.k..)) +
geom_line(aes(x=x..c.1.k., y=dumm),color="red",size=2)+
labs(x="Year",y="Millimeters + 7,000")+
scale_y_continuous(breaks = seq(6800, 7700, by = 150))+
scale_x_date(breaks = date_breaks("5 year"),labels =
date_format("%Y"))+
theme(rect=element_blank(),
legend.position="bottom",
legend.key = element_rect(fill = "white", colour = "black"))+
theme(panel.grid.major.y = element_line(color = "grey",size =
0.5,linetype = 1))

```

ggp3

```

sea_level_mensual<-matrix(0,12,62)

```

```

w=1
for(i in 1:62){
for(j in 1:12){
sea_level_mensual[j,i]=media_movil_sea[w,2]
w=w+1
}
}

```

```

dimnames(sea_level_mensual) <- list(month.abb[1:12], c(1961:2022))

```

#Periodo de ref

```

mat_momentos<-matrix(0,8,12)

```

```

for(i in 1:12){
mat_momentos[1,i]<-as.integer(mean(sea_level_mensual[i,-c(31:62)]))
mat_momentos[2,i]<-as.integer(sd(sea_level_mensual[i,-c(31:62)]))
mat_momentos[3,i]<-as.integer((mean(sea_level_mensual[i,-c(1:30)])))
mat_momentos[4,i]<-as.integer((sd(sea_level_mensual[i,-c(1:30)])))
}

```

```

    mat_momentos[5,i]<-as.integer(mean(sea_level_mensual[i,-
c(31:62)]))+sd(sea_level_mensual[i,-c(31:62)]))
    mat_momentos[6,i]<-as.integer(mean(sea_level_mensual[i,-
c(1:30)]))+sd(sea_level_mensual[i,-c(1:30)]))
    mat_momentos[7,i]<-as.integer(mean(sea_level_mensual[i,-c(31:62)])-
sd(sea_level_mensual[i,-c(31:62)]))
    mat_momentos[8,i]<-as.integer(mean(sea_level_mensual[i,-c(1:30)])-
sd(sea_level_mensual[i,-c(1:30)]))
}

x<-rbind(months,mat_momentos[1,],mat_momentos[3,])

dimnames(x) <- list(c("Meses","Mean_ref","Mean_proy"))

# months
mean_ref=as.integer(mat_momentos[1,])
mean_proy=as.integer(mat_momentos[3,])
# sd_ref=as.integer(mat_momentos[2,])
# sd_proy=as.integer(mat_momentos[4,])

x<-rbind(months,mean_ref,mean_proy)
df=as.data.frame(x)
df=as.data.frame(t(df))

#prueba
df3<-melt(df,id.vars = 'months')
ggplot(df3, aes(x=months, y=value, fill=variable)) +
  geom_bar(stat='identity', position='dodge')+
  scale_x_discrete(limits = month.abb)
  # coord_cartesian(ylim=c(0,7500))
  # scale_y_discrete(breaks = seq(from=6900, to=7500, by=100))

mat_dif_sea<-c()
w=1
for(j in 1:62){
  for(i in 1:12){

    mat_dif_sea[w]=(sea_level_mensual[i,j]-mat_momentos[1,i])

    w=w+1

  }
}

x<-seq(from=as.Date("1961-01-01"), to=as.Date("2022-12-01"), by="months")
# mat_dif_rain=mat_dif_rain[-c(1:108)]
df_diff_sea<-data.frame(x,mat_dif_sea)

```

```

names(df_diff_sea)

# Opcion 2 DIFERENCIAS
names(df_diff_sea)
ggp2_sea <- ggplot(df_diff_sea) +
  geom_bar(aes(x=x, y=mat_dif_sea),stat="identity",
fill="blue",colour="blue")+
  labs(x="Year",y="Number of Courses Sold")+
  scale_y_continuous(breaks = seq(-200, 350, by = 50))+
  scale_x_date(breaks = date_breaks("5 year"),labels =
date_format("%Y"))+
  theme(rect=element_blank(),
        legend.position="bottom",
        legend.key = element_rect(fill = "white", colour = "black"))+
  theme(panel.grid.major.y = element_line(color = "grey",size =
0.5,linetype = 1))
ggp2_sea

#ANOMALÍAS STD

media_movil_sea<-roll_avrg(sea_data$Milliliters,k = 12 ,date_origin =
"1955-01-01")
sea_level_mensual<-matrix(0,12,67)

w=1
for(i in 1:67){
  for(j in 1:12){
    sea_level_mensual[j,i]=media_movil_sea[w,2]
    w=w+1
  }
}

str_desv_sea<-c()

w=1
for(j in 1:67){
  for(i in 1:12){

    str_desv_sea[w]=(sea_level_mensual[i,j]-
mat_momentos[1,i])/mat_momentos[2,i]

    w=w+1

  }
}

x<-seq(from=as.Date("1956-01-01"), to=as.Date("2022-12-01"), by="months")

```

```

# mat_dif_rain=mat_dif_rain[-c(1:108)]
df_str_desv_sea<-data.frame(x,str_desv_sea)

media_movil_str_rain<-
roll_avrg(df_str_desv_sea$str_desv_sea,60,date_origin = "1956-01-01")

names(media_movil_str_rain)
ggp_sea <- ggplot(media_movil_str_rain) +
  geom_bar(aes(x=x..c.1.k., y=datuki..c.1.k.),stat="identity",
fill="blue",colour="blue")+
  geom_line(aes(x=x..c.1.k.,
y=dumm),stat="identity",color="red",size=2)+
  labs(x="Year",y="Number of Courses Sold")+
  scale_y_continuous(breaks = seq(-3, 6, by = 0.5))+
  scale_x_date(breaks = date_breaks("5 year"),labels =
date_format("%Y"))+
  theme(rect=element_blank(),
        legend.position="bottom",
        legend.key = element_rect(fill = "white", colour = "black"))+
  theme(panel.grid.major.y = element_line(color = "grey",size =
0.5,linetype = 1))

ggp_sea

#####
#####
#####
#####
#          sequía          #
#####          #####
#####          #####
#####          #####
#####          #####
#####          #####

months=c("Jan", "Feb", "Mar", "Apr", "May", "Jun", "Jul", "Aug", "Sep", "Oct", "Nov", "Dec")
folder_name<-"GHCND_CDD_1951-2023_RegularGrid_global_2.5x2.5deg_m4.nc"

wind_data<-stack(folder_name,varname="Ann")

ccd_data<-raster(folder_name,varname="Ann")

print(ccd_data)

cdd_data_r<-rotate(wind_data)

```

```

plot(cdd_data_r)

cdd_data_r@data@min

#formato df

df <- as.data.frame(cdd_data_r@data@min, xy = TRUE)

#Paleta
# define jet colormap
jet.colors <- colorRampPalette(c("#00007F", "blue", "#007FFF", "cyan",
"#7FFF7F", "yellow", "#FF7F00", "red", "#7F0000"))

#graf 1
ggplot() +
  geom_raster(data = df, aes(x=df$x, y=df$y, fill=df$Ann)) +
  scale_fill_gradientn(colors = jet.colors(7), limits = c(0,100),
na.value = "white") +
  coord_quickmap()+
  borders()+
  theme(axis.text.x=element_blank(),
        axis.text.y=element_blank(),
        axis.ticks =element_blank(),
        axis.title.y =element_blank(),
        axis.title.x=element_blank(),
        rect=element_blank())

data_rain<-raster("GHCND_Rx5day_1951-
2023_RegularGrid_global_2.5x2.5deg_m4.nc")
print(data_rain)
plot(data_rain)
data_rain_r<-rotate(data_rain)
plot(data_rain_r)

#####
#####
#####
#Visualización tipo de estacion (precipitación/temperatura)
#####
#####
#####

library(writexl)
library(tidyverse)
library(lubridate)
library(fs)

```



```

library(janitor)
library(openxlsx)
library(ggrepel)
setwd("C:/Users/ROYORUI/OneDrive - MAPFRE/Escritorio/TFM")
data<-read.xlsx(xlsxFile =file.choose())
data$FECHA=as.Date(data$FECHA, origin = "1899-12-30")
if.e
meteo_yr<-function(dates, start_month=NULL)
  dates.posix<- as.POSIXlt(dates)
  offset<-ifelse(dates.posix$mon >= start_month - 1,1,0)
  adj.year=dates.posix$year+1900+offset
  return(adj.year)

data<-mutate(data,
  winter_yt=meteo_yr(FECHA,12),
  month=month(FECHA),
  season=case_when(month %in% c(12,1:2) ~ "Winter",
    month %in% 3:5 ~ "Spring",
    month %in% 6:8 ~ "Summer",
    month %in% 9:11 ~ "Autum")

data_inv<-filter(data,
  season == "Winter") %>%
  group_by(winter_yt) %>%
  summarise(pr = sum(PRECP, na.rm = TRUE),
    ta = mean(TMEDIA, na.rm = TRUE))
data_inv <- mutate(data_inv, pr_mean = mean(pr[winter_yt <= 1991]),
  ta_mean = mean(ta[winter_yt <= 1991]),
  pr_anom = (pr*100/pr_mean)-100,
  ta_anom = ta-ta_mean,

  labyr = case_when(pr_anom < -10 & ta_anom < -.5 ~
winter_yt,
  pr_anom < -10 & ta_anom > .5 ~
winter_yt,
  pr_anom > 10 & ta_anom < -.5 ~
winter_yt,
  pr_anom > 10 & ta_anom > .5 ~
winter_yt),
  symb_point = ifelse(!is.na(labyr), "yes", "no"),
  lab_font = ifelse(labyr == 2022, "bold", "plain")
)
data_inv_p <- mutate(data_inv, pr_anom = pr_anom * -1)

bglab <- data.frame(x = c(-Inf, Inf, -Inf, Inf),
  y = c(Inf, Inf, -Inf, -Inf),
  hjust = c(1, 1, 0, 0),
  vjust = c(1, 0, 1, 0),
  lab = c("Húmeda-Cálida", "Seca-Cálida",
    "Húmeda-Fría", "Seca-Fría"))

```

```

bglab
g1 <- ggplot(data_inv_p,
             aes(pr_anom, ta_anom)) +
  annotate("rect", xmin = -Inf, xmax = 0, ymin = 0, ymax = Inf, fill =
"#fc9272", alpha = .6) + #Húmeda-Cálida
  annotate("rect", xmin = 0, xmax = Inf, ymin = 0, ymax = Inf, fill =
"#cb181d", alpha = .6) + #Seca-Cálida
  annotate("rect", xmin = -Inf, xmax = 0, ymin = -Inf, ymax = 0, fill =
"#2171b5", alpha = .6) + #Humeda-Fría
  annotate("rect", xmin = 0, xmax = Inf, ymin = -Inf, ymax = 0, fill =
"#c6dbef", alpha = .6) + #Seca-Fría
  geom_hline(yintercept = 0,
             linetype = "dashed") +
  geom_vline(xintercept = 0,
             linetype = "dashed") +
  geom_text(data = bglab,
            aes(x, y, label = lab, hjust = hjust, vjust = vjust),
            fontface = "italic", size = 5,
            angle = 90, colour = "Black")

g
g2 <- g1 + geom_point(aes(fill = symb_point, colour = symb_point),
                    size = 2.8, shape = 21, show.legend = FALSE) +
  geom_text_repel(aes(label = labyr, fontface = lab_font), max.iter = 5000,
size = 3.5)
g2
g3 <- g2 + scale_x_continuous("Anomalía precipitación en %",
                             breaks = seq(-100, 250, 10) * -1,
                             labels = seq(-100, 250, 10),
                             limits = c(min(data_inv_p$pr_anom), 100)) +
  scale_y_continuous("Anomalía temperatura media °C",
                    breaks = seq(-2, 4, 0.5)) +
  scale_fill_manual(values = c("black", "white")) +
  scale_colour_manual(values = rev(c("black", "white"))) +
  labs(title = "Anomalía para la estación Invierno en Soria",
       caption = "Dato: AEMET\n Periodo de referencia 1961-1991") +
  theme_bw()

g3 #visualización final.

```

```
#####
#####
#####
#Codigo para realizar la visualización de la iniciativa de la universidad
de Reading
#####
#####
#####

rm(list=ls())

library(writexl)
library(tidyverse)
library(lubridate)
library(fs)
library(janitor)
library(openxlsx)
library(ggrepel)
#packages
library(tidyverse)
library(lubridate)
library(RColorBrewer)

setwd("C:/Users/ROYORUI/OneDrive - MAPFRE/Escritorio/corregidas")
#data graf gama
data<-read.xlsx(xlsxFile =file.choose())

str(data)

#select only the annual temperature and year column
temp_SORIA_yr <- select(data, year, metANN)

#rename the temperature column
temp_SORIA_yr <- rename(temp_SORIA_yr, ta = metANN)

#missing values 999.9
summary(temp_SORIA_yr)

temp_SORIA_yr <- mutate(temp_SORIA_yr, ta = ifelse(ta == 999.9, NA, ta))

temp_SORIA_yr <- mutate(temp_SORIA_yr, date = str_c(year, "01-01", sep =
"-") %>% ymd())

theme_strip <- theme_minimal()+
```

```

theme(axis.text.y = element_blank(),
      axis.line.y = element_blank(),
      axis.title = element_blank(),
      panel.grid.major = element_blank(),
      legend.title = element_blank(),
      axis.text.x = element_text(vjust = 3),
      panel.grid.minor = element_blank(),
      plot.title = element_text(size = 14, face = "bold")
)

```

```
col_strip <- brewer.pal(11, "RdBu")
```

```
brewer.pal.info
```

```
#Con titulo
```

```

ggplot(temp_SORIA_yr,
      aes(x = date, y = 1, fill = ta))+
  geom_tile()+
  scale_x_date(date_breaks = "5 years",
              date_labels = "%Y",
              expand = c(0, 0))+
  scale_y_continuous(expand = c(0, 0))+
  scale_fill_gradientn(colors = rev(col_strip))+
  guides(fill = guide_colorbar(barwidth = 1))+
  labs(title = "Soria 1961-2022",
       caption = "Datos: AEMET Opendata")+
  theme_strip

```

```
Sub ininterpol()
```

```

Dim y() As Single
Dim x() As Single
Dim i, j, w, ronda As Integer

Hoja4.Activate
j = 0
Do
    j = j + 1
Loop Until ActiveSheet.Cells(j, 1).Value = ""
w = 0

Do
    w = w + 1
Loop Until ActiveSheet.Cells(j + w, 1).Value <> ""

ReDim y(1 To w + 2)
ReDim x(1 To w + 2)

x(1) = 0
x(w + 2) = w + 1
y(1) = ActiveSheet.Cells(j - 1, 1).Value
y(w + 2) = ActiveSheet.Cells(j + w, 1).Value

For i = 2 To UBound(x)
    x(i) = i - 1
Next i

For i = 2 To UBound(y)
    y(i) = (y(1) * (x(w + 2) - x(i)) + y(w + 2) * (x(i) - x(1))) / (x(w + 2) - x(1))
Next i

For i = 1 To w
    ActiveSheet.Cells(j + i - 1, 1).Value = y(i + 1)
Next i
i = 1

End Sub

```

```

Sub mov_avg()

```

```

Dim i, k, j, n As Integer
Dim result() As Double
Dim val() As Double

i = 1
n = ActiveSheet.Cells(1, 4).Value
k = ActiveSheet.Cells(1, 6).Value
j = 0
sum = 0
ReDim result(1 To n)

For j = 1 To n - k + 1

sum = 0
  For i = 1 To k

      sum = sum + ActiveSheet.Cells(j + i - 1, 2)

  Next i

  result(j) = sum / k

Next j

For i = 1 To n - k + 1

  ActiveSheet.Cells(k + i, 3).Value = result(i)

Next i
End Sub

```