

# CTN



# FORECAST

## Informe de Vigilancia Tecnológica

Investigación y optimización de técnicas de modelización, clasificación y predicción de series temporales, con aplicación al entorno marino



Este informe ha sido elaborado por la Asociación Empresarial de Investigación Centro Tecnológico Naval y del Mar gracias al Convenio suscrito con el Instituto de Fomento de la Región de Murcia con el apoyo del fondo FEDER.



**Autores:** Iván Felis, Rosa Martínez Álvarez, Eduardo Madrid, M<sup>a</sup> Ángeles García, Isabel Hernández

Más info: [www.ctnaval.com](http://www.ctnaval.com)



Unión Europea



*Fondo Europeo de  
Desarrollo Regional  
“Una manera de  
hacer Europa”*

© CTN, 2022

Todos los derechos están reservados. Se autoriza la reproducción total o parcial de este informe con fines educacionales, divulgativos y no comerciales citando la fuente. La reproducción para otros fines está expresamente prohibida sin el permiso de los propietarios del copyright.

# Índice

1. Introducción .....	<a href="#">4</a>
2. Metodología.....	<a href="#">5</a>
3. Sustainable Blue Economy .....	<a href="#">8</a>
4. Estado del arte .....	<a href="#">7</a>
4.1. Contextualización del problema: variabilidad de datos en el entorno marino .....	<a href="#">8</a>
4.2. Tipología de series temporales en función de la naturaleza de los datos .....	<a href="#">10</a>
4.3. Métricas y técnicas de discriminación / clasificación de series temporales .....	<a href="#">12</a>
4.4 Métodos de predicción de series temporales basados en la naturaleza de los datos .....	<a href="#">14</a>
4.5 Origen, naturaleza y estudios de series temporales con aplicación al medio marino ....	<a href="#">18</a>
5. Tendencias.....	<a href="#">21</a>
5.1. Literatura científica .....	<a href="#">21</a>
5.1.1. Análisis de tendencias en la literatura.....	<a href="#">37</a>
5.2. Proyectos .....	<a href="#">41</a>
5.2.1. Análisis gráfico de la financiación .....	<a href="#">45</a>
6. Bibliografía.....	<a href="#">46</a>

# 1. Introducción

Este informe, elaborado por el equipo del Centro Tecnológico Naval y del Mar, tiene como finalidad ofrecer al tejido empresarial una mejora en el conocimiento del entorno, que permita detectar tendencias y desarrollar estrategias adecuadas basadas en niveles superiores de certidumbre a través de la captación y divulgación de información y conocimiento de importancia estratégica en los ámbitos social, tecnológico y económico, que incidan en la detección de nuevas oportunidades de desarrollo regional.

Los contenidos de este informe están estrechamente relacionados con el desarrollo del proyecto *Investigación y optimización de técnicas de modelización, clasificación y predicción de series temporales, con aplicación al entorno marino*.

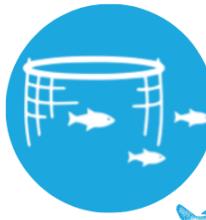
En este proyecto se aplican modelos descriptivos y predictivos basados en IA (Inteligencia Artificial) para encontrar una metodología óptima para el estudio de series temporales. Se busca desarrollar un modelo de análisis ágil y certero que permita optimizar las tareas de predicción a través de uso de series temporales y mediante la caracterización y modelización de datos del medio marino.

Los resultados obtenidos en el proyecto ForeCast podrán ser aplicables a numerosos sectores, como son la acuicultura, la industria energética o el ámbito portuario. Concretamente en acuicultura, el modelo de estudio de series temporales podría facilitar las tareas de predicción de escapes de peces.

Para la realización de este informe se han aplicado técnicas de Vigilancia Tecnológica, una herramienta al servicio de las empresas y organizaciones que permite detectar oportunidades y amenazas aportándoles

## PREDICCIÓN DE ESCAPES ACUICULTURA

La predicción de escapes de peces en instalaciones acuícolas supone un ejemplo de aplicación de la **metodología de estudio de modelos de series temporales**, en la que CTN está trabajando.



### ESCAPES DE PECES

En los sistemas de cultivo en mar abierto los escapes de peces son difíciles de anticipar. Estos escapes representan pérdidas económicas considerables y pueden generar un gran impacto ambiental.



### RECOPILACIÓN Y ANÁLISIS DE DATOS

Se recogen y analizan de forma previa datos sobre el oleaje, temperatura, velocidad del viento, capturas en lonjas... Esta tarea nos ayudará a extraer conclusiones en fases posteriores.



### CORRELACIÓN ENTRE ESCAPES Y TEMPORALES

A partir de los datos recopilados se extraen conclusiones sobre las posibles relaciones entre los inputs. En este caso, entre los escapes y fenómenos meteorológicos extremos.



### OBTENCIÓN DE MODELOS PREDICTIVOS

Conocidas las relaciones entre los parámetros ambientales y los escapes producidos, se genera el modelo predictivo que mejor se adapta a las condiciones y permite anticipar los posibles escapes.



### PREDICCIÓN DE ESCAPES

Finalmente, se dispone de un modelo predictivo que permite a los acuicultores gestionar sus instalaciones y poner medidas para prevenir las fugas.

ventajas competitivas y fundamentos para la toma de decisiones estratégicas mediante la selección y análisis de información de diversos tipos (científica, tecnológica, comercial, de mercado, social...).

Para ello se parte de una introducción metodológica sobre las técnicas y fases de la Vigilancia Tecnológica que se han aplicado para el desarrollo del informe. A continuación, se introduce la Economía Azul como

iniciativa europea con el fin de contextualizar los contenido temáticos del informe. Seguidamente se realiza un análisis del estado de la técnica, proyectos y literatura científica.

Por último, se incluyen las fuentes que se han manejado para la realización de este informe.

## 2. Metodología

**L**a vigilancia tecnológica se entiende como una “forma organizada, selectiva y permanente de captar información del exterior sobre tecnología, analizarla y convertirla en conocimiento para tomar decisiones con menor riesgo y poder anticiparse a los cambios” [1]. Su finalidad última es generar ventajas competitivas para la empresa ya que le proporciona datos para:

Para el desarrollo de la Vigilancia Tecnológica el primer paso es el plantear los aspectos básicos [2]: ¿Cuál es el objeto de la vigilancia? ¿Qué debemos vigilar? ¿Qué información buscar? ¿Dónde localizarla?

Cuando el objetivo de la VT está claramente delimitado, se procede a planificar la estrategia de búsqueda. Para el despliegue de esta fase conviene tener en cuenta que la información puede presentarse de dos formas: estructurada y no estructurada. La primera es propia de las bases de datos, conjuntos de datos homogéneos, ordenados de una forma determinada, que se presenta en forma legible por ordenador [3]. Su unidad es el registro –o ficha de un artículo

científico o una patente– que presenta la información ordenada en campos: autor, título, fecha de publicación, titular de la patente, inventores, etc. En cambio, la información no estructurada se presenta en textos sin un formato determinado (noticias de periódicos, sitios web, blogs, correos electrónicos) cuyo tratamiento requerirá de nuevas herramientas capaces de “leer” y analizar estos textos. Estas herramientas son útiles también para analizar la información de textos completos de artículos científicos o de patentes. Hoy se considera que el texto es la mayor fuente de información y conocimiento para las empresas [4].

Tras la selección de las palabras clave se automatiza la búsqueda en función de las diferentes tipologías de fuentes a utilizar, se lanza la misma y se

**La finalidad de la  
Vigilancia Tecnológica es  
generar ventajas  
competitivas para la  
empresa**

filtran los resultados en términos de pertinencia, fiabilidad, relevancia, calidad y capacidad de contraste [1].

Una vez comprobada la calidad de la información, los métodos de análisis han de garantizar su valor para la explotación de los mismos [5]. El

objetivo del análisis es transformar la información en bruto recogida en un producto con alto valor añadido. A partir de aquí, la aportación de los expertos es crítica para crear información avanzada, para generar

conocimiento. Pasamos de una masa ingente de información en distintos formatos y lugares a una etapa en la que se captura la información más relevante, se organiza, indexa, almacena, filtra y, finalmente, con la opinión del experto que aporta en este punto del pro-

ceso un máximo valor añadido [6]. A continuación, se incluye un esquema con las distintas fases de la metodología empleada durante la generación de este informe.



## 3. Sustainable Blue Economy

**L**a Economía Azul Sostenible es el nuevo enfoque que da la Unión Europea a la Economía Azul para incorporarla de pleno derecho a los esfuerzos que van a marcar el rumbo de la economía europea en los próximos años: el Pacto Verde Europeo y el Plan de Recuperación para Europa.

Es una manera de ver la economía que subraya la necesidad de invertir en investigación e innovación para conseguir que las actividades económicas en el sector marítimo reduzcan su impacto en el medio marino, contribuyendo así a la mitigación del cambio climático, con el fin de lograr el objetivo de convertir a Europa en el primer continente climáticamente neutro en el mundo en 2050.

El programa Horizonte Europa, junto a instrumentos de financiación como el Fondo Europeo Marítimo, garantizan una base sólida en ciencia e innovación enfocada en:

- Preservar y restaurar los mares y océanos y eliminar la contaminación.
- Controlar el uso de los recursos que se

obtienen de mares y océanos para utilizarlos de manera más sostenible y renovable.

- Adaptación a las consecuencias del cambio climático.
- Cómo utilizar los recursos oceánicos para mitigar el cambio climático.
- Impulsar la innovación y ayudar a empresas del sector marítimo para fomentar la economía circular y las soluciones sostenibles.

Puedes ampliar información sobre la economía azul en el story map de nuestro [observatorio tecnológico](#).



## 4. Estado del arte

**A** continuación, se contextualiza el problema de la amplia variabilidad de datos en el medio marino. Asimismo, se presenta el concepto de series temporales (origen, naturaleza y estudios), ahondando en las distintas métricas y técnicas de clasifica-

ción, así como distintos métodos de predicción basados en la naturaleza de los datos.

**El estado del arte recoge la situación de una determinada tecnología: lo más innovador o reciente con respecto a un arte específico**

## 4.1. Contextualización del problema: variabilidad de datos en el entorno marino

Debido a la creciente disponibilidad de grandes flujos de datos de gran dimensión, hay una necesidad urgente por desarrollar modelos que permitan, entre otros, extraer eficazmente aquellos patrones ocultos en los sistemas complejos que representan, reducir la dimensionalidad de los datos, determinar la causalidad dinámica y aprovechar un amplio conjunto de factores exógenos para una predicción adecuada.

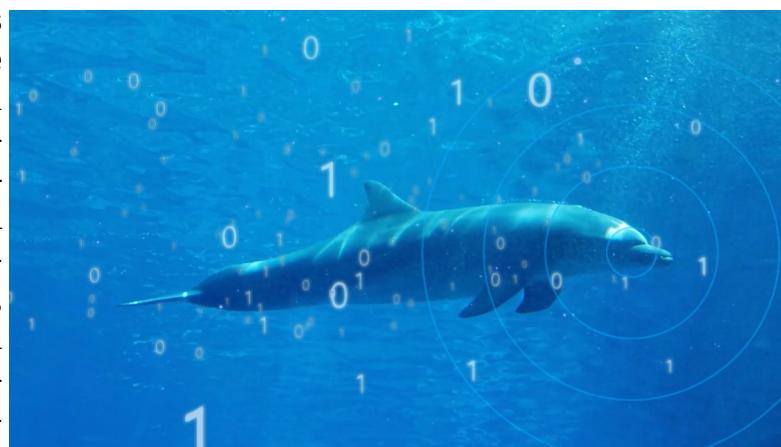
Estas técnicas avanzadas de predicción, en boga en diversos ámbitos, como puede ser el ámbito marítimo, portuario, industrial o el de la acuicultura<sup>1</sup>, son esenciales para introducir el paradigma P4<sup>2</sup> (Predicción, pronóstico y prevención) con el fin de mejorar la calidad y la integridad de los sistemas complejos no lineales y no estacionarios donde se llevan a cabo estas actividades.

Los datos provenientes del medio marino son un activo muy valioso. No solo el rápido acceso a información fiable y precisa es vital para obtener los conocimientos necesarios para hacer frente a las amenazas del

medio ambiente marino y costero, en el desarrollo de políticas y legislación para proteger zonas vulnerables o en la comprensión de las tendencias y en la previsión de los cambios futuros; sino que también, la disponibilidad de datos de mayor calidad son requisitos claves para la innovación y el desarrollo económico marítimo sostenible o crecimiento azul (Blue Growth)<sup>3</sup>.

En este sentido, es evidente que los datos marinos aumentan cada vez más gracias a la mejora de las técnicas de adquisición de datos marinos y a la evolución de los sensores marinos basados en diferentes tecnologías (acústica, óptica o electro-

magnética)<sup>4</sup>. Lo que permite, por un lado, observar variables oceánicas esenciales y datos biológicos que antes eran inviables de obtener, generando un gran volumen de datos; y, por otro lado, estos nuevos métodos permiten la recolección y obtención de datos e información cada vez más complejos<sup>5</sup>. Cabe notar que, aunque generalmente las mejoras tecnológicas derivan en la obtención de datos de mayor calidad, en oca-



1. Changqing Cheng and others, 'Time Series Forecasting for Nonlinear and Non-Stationary Processes: A Review and Comparative Study', IIE Transactions (Institute of Industrial Engineers), 47.10 (2015), 1053–71 <<https://doi.org/10.1080/0740817X.2014.999180>>.
2. Paradigma derivado del ámbito médico y que contempla: "predicción, preventiva, personalizada y participativa". Este paradigma es trasladado al ámbito de la ciencia de datos como "predicción, pronóstico y prevención".
3. European Commission. European Marine Observation and Data Network. Impact Assessment. Com. 461, sec. 999 (2010).
4. Dongmei Huang and others, 'Modeling and Analysis in Marine Big Data: Advances and Challenges', Mathematical Problems in Engineering, 2015 (2015) <<https://doi.org/10.1155/2015/384742>>.
5. Ketil Malde and others, 'Machine Intelligence and the Data-Driven Future of Marine Science', ICES Journal of Marine Science, 77.4 (2020), 1274–85 <<https://doi.org/10.1093/icesjms/fsz057>>

siones, este aumento del volumen de datos se obtiene sacrificando la calidad por la cantidad. Por ello, es importante encontrar un equilibrio entre calidad y cantidad, para que el posterior análisis de la serie temporal sea lo más preciso y satisfactorio posible<sup>6</sup>.

Estos datos pueden ser clasificados dependiendo de la dimensionalidad de los mismos. Así, podremos tener datos univariados, recogidos tanto por sensores marinos convencionales, nano sensores o, incluso, observatorios marinos que recogen datos de diferentes sensores y obtienen una amplia variedad de datos secuenciales marinos que, posteriormente, son de utilidad para aplicaciones de monitorización y vigilancia para proporcionar una percepción a largo plazo y a gran escala del entorno, así como también para hacer frente a los cambios ambientales no deseados<sup>7</sup>. Por otro lado, se pueden obtener datos bidimensionales a partir de aquellos sensores que recogen imágenes subacuáticas; o incluso, datos tridimensionales provenientes de sensores que capturan video, tanto en tiempo real como históricos. En este sentido, es importante destacar que la adquisición y procesado de datos en 3D se ve limitada por las comunicaciones submarinas<sup>8</sup>.

Asimismo, la gran variedad de tipos de datos, y de formatos en que estos se expresan, complica el procesado de la información recolectada en el medio marino. De hecho, algunos de los retos a los que se enfrenta la

estandarización de datos según los principios FAIR tocan esta problemática: la gran diversidad de datos, la multitud de estructuras de gestión de datos existente, y los nuevos formatos de datos que están siendo originados debido a la evolución de la tecnología de sensores<sup>9</sup>. Tomando EMODNET, la infraestructura de datos marinos más importante de Europa, como ejemplo, se pueden encontrar series temporales de datos biológicos (e.g., poblaciones de especies marinas), químicos (e.g., pH), físicos (e.g., temperatura, ruido submarino), topográficos (e.g., batimetría) o de actividades humanas (e.g., tráfico marítimo, dragados, zonas pesqueras), entre otras<sup>10</sup>.

Con todo, a pesar de que existen ámbitos de trabajo específicos que utilizan distintas fuentes de datos del medio marino, como ocurre en la Planificación Marítima Espacial (MSP), existe una carencia de estandarización de los mismos. Para intentar paliar este problema surgen las siguientes iniciativas:

- ◆ Directiva Europea 2007/2/EC INSPIRE (Maritime Spatial Planning Supported by Infraestructure for Spatial Information in Europe)<sup>11</sup>.
- ◆ Principios FAIR (Findability, Accessibility, Interoperability, and Reuse): disponibilidad, accesibilidad, operatividad y reutilización de los datos<sup>12</sup>.

En el presente proyecto, se pretende avanzar en el estudio de una estructura de datos

6. A. Teruzzi and others, 'Parallel Implementation of a Data Assimilation Scheme for Operational Oceanography: The Case of the MedBFM Model System', *Computers & Geosciences*, 124 (2019), 103–14 <<https://doi.org/10.1016/J.CAGEO.2019.01.003>>.
7. Judi E. Hewitt and Simon F. Thrush, 'Monitoring for Tipping Points in the Marine Environment', *Journal of Environmental Management*, 234 (2019), 131–37 <<https://doi.org/10.1016/J.JENVMAN.2018.12.092>>.
8. Mohammad Jahanbakhsh and others, 'Internet of Underwater Things and Big Marine Data Analytics - A Comprehensive Survey', *IEEE Communications Surveys and Tutorials*, 23.2 (2021), 904–56 <<https://doi.org/10.1109/COMST.2021.3053118>>.
9. Teruzzi and others.
10. Jan-Bart Calewaert and others, 'The European Marine Data and Observation Network (EMODnet): Your Gateway to European Marine and Coastal Data', 2016, 31–46 <[https://doi.org/10.1007/978-3-319-32107-3\\_4](https://doi.org/10.1007/978-3-319-32107-3_4)>.
11. Andrej Abramic and others, 'Maritime Spatial Planning Supported by Infrastructure for Spatial Information in Europe (INSPIRE)', *Ocean & Coastal Management*, 152 (2018), 23–36 <<https://doi.org/10.1016/J.OCECOAMAN.2017.11.007>>.
12. FAIR Data in Trustworthy Data Repositories Webinar 'Fair-Data-in-Trustworthy-Data-Repositories-Webinar-Dans-Eudat-Openaire-Webinar-Dec-2016' <<https://www.openaire.eu/fair-data-in-trustworthy-data-repositories-webinar-dans-eudat-openaire-webinar-dec-2016>>.

muy habitual, las series temporales, afianzando así la línea de I+D orientada hacia la ciencia de datos, partiendo con el análisis de la diversidad de datos de series tempora-

les que se pueden obtener del ámbito marino y cómo alcanzar su homogeneización y lograr un mayor grado de conocimiento de éstos.

## 4.2. Tipología de series temporales en función de la naturaleza de los datos

**L**as series temporales pueden clasificarse según diferentes criterios. Una primera distinción reside en el **número de variables** descritas en la serie temporal: si la serie se compone de más de una variable, se denomina multivariable, mientras que, si únicamente representa una variable, entonces será una serie temporal univariante (o escalar). En principio, no hay distinción entre una serie temporal multivariable y una colección de series temporales univariantes, siempre que estas estén referenciadas temporalmente de forma idéntica; sin embargo, el término se suele emplear para hacer hincapié y describir los casos en que hay ciertas interrelaciones entre las series temporales constitutivas<sup>13</sup>, hecho que habitualmente permite mejorar las predicciones.

Por otro lado, otro criterio de clasificación se fundamenta en la **dimensionalidad** (espacial) de las series temporales. En este sentido, existen tanto series temporales referenciadas espacialmente como no (e.g., el histórico de valores en bolsa es una serie

temporal multivariable no espacialmente referenciada per se). Dentro del grupo de series temporales referenciadas espacialmente, estas pueden ser unidimensionales (monitorización de un único punto del espacio), bidimensionales (un mallado superficial, ya sea ráster o vectorial) y tridimensionales (volumen espacial de datos). En la bibliografía, estas series son también llamadas simplemente series temporales espaciales<sup>14</sup> (habitualmente para el caso bidimensional); estas también incluyen aquellas series temporales georreferenciadas de forma irregular (e.g., algunos puntos de muestreo que no definen un mallado regular). Si bien la mayor parte de métodos que se encuentran en la bibliografía se han



- 13. Pablo Montero-Manso and Rob J. Hyndman, 'Principles and Algorithms for Forecasting Groups of Time Series: Locality and Globality', International Journal of Forecasting, 37.4 (2021), 1632–53 <<https://doi.org/10.1016/j.ijforecast.2021.03.004>>.
- 14. Pusheng Zhang and others, 'Correlation Analysis of Spatial Time Series Datasets: A Filter-and-Refine Approach', Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics), 2637 (2003), 519–31 <[https://doi.org/10.1007/3-540-36175-8\\_53](https://doi.org/10.1007/3-540-36175-8_53)>.

ideado para el caso unidimensional, en las ciencias de la Tierra es más frecuente encontrar estas series temporales espaciales<sup>15</sup>. En ciertos contextos, una serie temporal espacial puede entenderse equivalentemente como una serie temporal multivariable, con la salvedad de que ahora, más que diferentes variables o parámetros, lo que se tiene con múltiples series temporales del mismo parámetro, que además están espacialmente referenciadas.

Más popular aún es la distinción entre series temporales según su **linealidad**. De forma cualitativa, una serie se dice lineal cuando cada punto de la misma puede expresarse como una combinación lineal de valores pasados, futuros, o diferencias; esto implica un cierto grado de autocorrelación que a menudo se explota en los modelos que las describen. De manera similar, se define la familia de series temporales Gaussianas como un subconjunto de las series lineales, dado por la condición de que las componentes de la anterior combinación lineal estén independiente e idénticamente muestreadas desde la función de distribución normal<sup>16</sup>.

Otros criterios permiten seguir caracterizando y separando las series temporales, como la estacionariedad, que es asumida en multitud de modelos y que, aunque presenta varias formas, indica que sus prime-

ros momentos estadísticos (media y varianza) son constantes en el tiempo, o la jerarquía, que engloba aquellas series temporales que presentan alguna relación jerárquica entre sí (e.g., temperatura diaria y temperatura promedio semanal en una misma ubicación)<sup>17</sup>. Un caso típico de serie temporal no estacionaria es el de la temperatura diaria ambiente en una ciudad, por ejemplo, ya que la distribución de temperaturas difiere para cada mes. Por el contrario, un caso típico trivial de serie temporal estacionaria consistiría la distribución temporal de resultados de lanzamiento de un dado equilibrado.

Menos frecuentemente, a veces se desea estudiar la caoticidad de una serie temporal, aspecto que está íntimamente relacionado con las series temporales no lineales, particularmente en aquellos casos en que se conozca o intuya a priori que esta proviene de un sistema dinámico complejo. El artículo pionero fue el de Sugihara y May (1990)<sup>18</sup>, en el que propusieron utilizar métricas basadas en la precisión de predicción a corto plazo para así distinguir caos de ruido en series temporales. Este método se enmarca en la teoría de sistemas dinámicos no lineales y embebido en espacio de fases (más adelante se volverá a tocar este tema).

- 15. Federico Amato and others, 'A Novel Framework for Spatio-Temporal Prediction of Environmental Data Using Deep Learning', *Scientific Reports*, 10.1 (2020), 1–11 <<https://doi.org/10.1038/s41598-020-79148-7>>.
- 16. Arthur Berg, Timothy McMurry, and Dimitris N. Politis, 'Testing Time Series Linearity. Traditional and Bootstrap Methods', *Handbook of Statistics*, 30 (2012), 27–42 <<https://doi.org/10.1016/B978-0-444-53858-1.00002-8>>.
- 17. Rob J Hyndman and George Athanasopoulos, *Forecasting: Principles and Practice*, 3rd edn (OTexts, 2021).
- 18. George Sugihara and Robert M. May, 'Nonlinear Forecasting as a Way of Distinguishing Chaos from Measurement Error in Time Series', *Nature*, 344.6268 (1990), 734–41 <<https://doi.org/10.1038/344734A0>>.

## 4.3. Métricas y técnicas de discriminación/ clasificación de series temporales

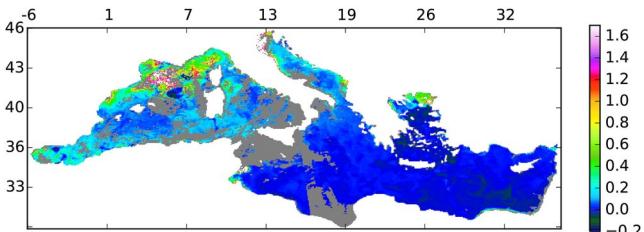
**C**omo se ha visto en el apartado anterior, hay varias formas de clasificar las series temporales. En esta sección, se profundizará en el estado del arte de las técnicas de discriminación de series temporales. No se debe confundir con las tareas de clasificación tal y como se entiende por *clustering*, que tratan de agrupar series temporales según otras características.

Empezando por la **linealidad**, el primer método reconocido descrito en la bibliografía data de 1980. Ideado por Rao y Gabr, consiste en un método no paramétrico basado en la densidad biespectral de la serie temporal<sup>19</sup>. Desde entonces, han aparecido diversas pruebas de linealidad, tanto basadas en esta métrica como otras, como el método de los datos subrogados<sup>20</sup>, el test de Wald, estimación kernel, o el test basado en la función de autocorrelación (ACF), entre otros<sup>21</sup>.

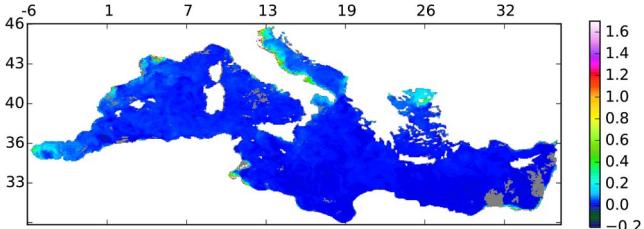
En cuanto a técnicas para discriminar **estacionariedad**, históricamente, se puede señalar el artículo de Priestley y Subba<sup>22</sup> como uno de los primeros en que un método se ideaba explícitamente para investigar la (no) estacionariedad de una serie temporal. Este se basaba en análisis espectral evoluti-

vo. Desde entonces, muchos otros métodos han proponiéndose, si bien hoy en día los más populares son la prueba de Dickey-Fuller aumentada (ADF) y la de Kwiatkowski-Phillips-Schmidt-Shin (KPSS)<sup>23</sup>, las cuales prueban la hipótesis nula de que una raíz unidad esté presente y de que la serie sea estacionaria en tendencia, respectivamente.

Cabe decir que cualquier proceso estacionario en segundo orden (estacionario en covarianza) es lineal, o puede transformarse a lineal por sustracción directa de una componente determinista; este resultado se enmarca en el teorema de descomposición de Wold<sup>24</sup>; por lo tanto, quizá se haya dado



(a) April dataset.



(b) July dataset.

- 19. T. Subba Rao and M. M. Gabr, 'A TEST FOR LINEARITY OF STATIONARY TIME SERIES', Journal of Time Series Analysis, 1.2 (1980), 145–58 <<https://doi.org/10.1111/J.1467-9892.1980.TB00308.X>>.
- 20. James Theiler and others, 'Testing for Nonlinearity in Time Series: The Method of Surrogate Data', Physica D: Nonlinear Phenomena, 58.1–4 (1992), 77–94 <[https://doi.org/10.1016/0167-2789\(92\)90102-S](https://doi.org/10.1016/0167-2789(92)90102-S)>.
- 21. Berg, McMurry, and Politis.
- 22. M. B. Priestley and T. Subba Rao, 'A Test for Non-Stationarity of Time-Series', Journal of the Royal Statistical Society: Series B (Methodological), 31.1 (1969), 140–49 <<https://doi.org/10.1111/J.2517-6161.1969.TB00775.X>>.
- 23. Denis Kwiatkowski and others, 'Testing the Null Hypothesis of Stationarity against the Alternative of a Unit Root. How Sure Are We That Economic Time Series Have a Unit Root?', Journal of Econometrics, 54.1–3 (1992), 159–78 <[https://doi.org/10.1016/0304-4076\(92\)90104-Y](https://doi.org/10.1016/0304-4076(92)90104-Y)>.
- 24. Maurice Kendall and Herman Wold, 'A Study in the Analysis of Stationary Time-Series.', Undefined, 117.4 (1954), 484 <<https://doi.org/10.2307/2342687>>.

más importancia a la estacionariedad frente a la linealidad, como métrica de clasificación de series temporales individuales que componen una serie multivariable. Las métricas habituales parten desde el mismo desempeño de la predicción según cada caso, o técnicas de inferencia causal, hasta aquellas propias de la teoría de la información.

En la **presente propuesta**, el CTN pretende introducir el análisis de estas características y métricas en su flujo de trabajo rutinario de estudio series temporales, con la esperanza de conseguir entender mejor por qué un modelo de serie temporal se comporta mejor que otro en función de la caustística.

## 4.4. Métodos de predicción de series temporales basados en la naturaleza de los datos

**D**ado que la linealidad es la característica que es más frecuentemente utilizada para distinguir modelos de series temporales y que, además, es más general que las otras (e.g., una serie multivariable puede estar compuesta de series temporales individuales tanto lineales como no lineales), se ha decidido realizar la distinción entre métodos para el análisis predictivo de series temporales lineales respecto a los métodos para series no lineales, como sigue.

### Métodos para series temporales lineales

Históricamente, los modelos lineales de series temporales han sido los más extensamente estudiados. Sus orígenes pueden trazarse hasta los trabajos pioneros de Kolmogorov y Wiener en la década de los 40. En particular, resulta destacable el acercamiento de Wiener, que fue el primero en formalizar el problema de “extracción de señal”; esto es, extraer la estimación óptima de la señal subyacente, dadas observaciones de una serie temporal que se considera contaminada por ruido (como se comprobará más tarde, esta idea guarda relación con

los modelos de espacio de estados). En cualquier caso, no fue hasta la década de los 70 que, con los desarrollos de Box y Jenkins<sup>25</sup>, se llegó a un marco de trabajo más completo. La idea básica de la metodología Box-Jenkins, que comprime los métodos de modelización lineal (hoy día) clásicos, tales como regresión lineal, auto-regresión (AR), media móvil (MA) auto-regresión de media móvil (ARMA) o ARMA integrado (ARIMA), y similares, es considerar que una serie temporal puede explicarse mediante dos grupos de términos: una combinación lineal de valores pasados de dicha serie (para una cierta ventana temporal), y una componente estocástica (e.g., ruido blanco). Estos métodos, aunque extensamente utilizados en la bibliografía, requieren de estacionariedad de la serie temporal para ser aplicados correctamente (salvo ARIMA en ciertos casos). Para solventar esta limitación, se desarrollaron los modelos GARCH (del inglés *generalized autoregressive conditional heteroscedacity*), aptos para aplicarse en series con un tipo de no estacionariedad, en particular, de varianza no constante<sup>26</sup>.

25. George E.P. Box and Gwilym M. Jenkins, *Time Series Analysis: Forecasting and Control*, 1st edn, 1970.

26. Satheesh V. Aradhyula and Matthew T. Holt, ‘GARCH Time-Series Models: An Application to Retail Livestock Prices’, *Western Journal of Agricultural Economics*, 1988, pp. 365–74. Aradhyula and Holt.

27. Ps Kalekar, ‘Time Series Forecasting Using Holt-Winters Exponential Smoothing’, *Kanwal Rekhi School of Information Technology*, 04329008, 2004, 1–13. Kalekar.

Otro método similar clásico y que todavía es usado hoy en día parte de la técnica de Suavizado Exponencial (ES). Inicialmente concebido por Holt y Winters en los 60<sup>27</sup>, el fundamento de este método para realizar predicciones es tomar valores pasados de la serie, con pesos exponencialmente decrecientes. Las dos clases principales de modelos de este conjunto son los modelos aditivos y los multiplicativos; estos modelos resultan interesantes cuando los datos exhiben tanto una tendencia como estacionalidad claras<sup>28</sup>.

Extensiones de estos métodos a series temporales multivariadas fueron desarrollándose paralelamente. Así, pronto surgieron métodos como la regresión automática vectorial, en todas sus formas (VAR, VARMA, GARCH multivariable, etc.), que son versiones vectoriales de los modelos clásicos que permiten aprovechar la correlación cruzada entre las variables de la serie temporal multivariable<sup>29</sup>. Asimismo, otros métodos fueron apareciendo para analizar series temporales espacialmente referenciadas, como el modelo STARIMA (Space-time ARIMA), el cual es en cierto sentido equivalente a un modelo VARMA, y la autoregresión vectorial bayesiana (BVAR).

Multitud de variantes y nuevos métodos fueron desarrollados durante las siguientes

décadas, hasta que, sobre los 90, el paradigma del Aprendizaje Profundo (Deep Learning) cobró fuerza y alcanzó el campo de las series temporales lineales. Consecuentemente, en dicha década, diversos diseños de redes neuronales (RN) se empezaron a aplicar rutinariamente para realizar predicciones de series temporales. Además, dada su versatilidad y carácter inherentemente no lineal y no paramétrico, sus defensores argumentan que pueden ser aplicadas tanto en series temporales lineales como no lineales de forma automática<sup>30</sup>.

Así pues, algunos modelos de redes neuronales también han sido aplicados en predicción multivariable/espacial, bien para predecir la magnitud del viento en superficie en toda una red de estaciones meteorológicas<sup>31</sup>, o para predecir la demanda de decenas de millones de productos<sup>32</sup>.



- 27. R. Winters, 'Forecasting Sales by Exponentially Weighted Moving Averages', [Http://dx.Doi.Org/10.1287/Mnsc.6.3.324](http://dx.doi.org/10.1287/Mnsc.6.3.324), 6.3 (1960), 324–42 <<https://doi.org/10.1287/MNSC.6.3.324>>.
- 28. Ps Kalekar, 'Time Series Forecasting Using Holt-Winters Exponential Smoothing', Kanwal Rekhi School of Information Technology, 04329008, 2004, 1–13. Kalekar.
- 29. William W.S. Wei, *Multivariate Time Series Analysis and Applications*, 1st edn (John Wiley & Sons Ltd, 2019).
- 30. Guoqiang Peter Zhang, 'An Investigation of Neural Networks for Linear Time-Series Forecasting', *Computers and Operations Research*, 28.12 (2001), 1183–1202 <[https://doi.org/10.1016/S0305-0548\(00\)00033-2](https://doi.org/10.1016/S0305-0548(00)00033-2)>.
- 31. Amir Ghaderi, Borhan M. Sanandaji, and Faezeh Ghaderi, 'Deep Forecast: Deep Learning-Based Spatio-Temporal Forecasting', ii, 2017. Ghaderi, Sanandaji, and Ghaderi.
- 32. Rajat Sen, Hsiang Fu Yu, and Inderjit Dhillon, 'Think Globally, Act Locally: A Deep Neural Network Approach to High-Dimensional Time Series Forecasting', *Advances in Neural Information Processing Systems*, 32.NeurIPS (2019), 1–10.

Adicionalmente, existe todo un paradigma alternativo de análisis de series temporales todavía no mencionado: los modelos de series temporales estructurales. Se denominan estructurales porque en ellos se modeliza cada componente constitutivo de la serie por separado; en este sentido, son similares a los modelos ARMA o ARIMA, en que se da cuenta de las componentes de tendencia, estacionalidad y estocásticas, con la diferencia de que estos últimos tratan de eliminar las dos primeras diferenciando. Cabe decir que también existen modelos estructurales de series temporales no lineales, que se mencionarán más adelante.

Más aún, como se mencionó previamente, otro paradigma de modelización de series temporales consiste en los modelos de espacio de estados. Bajo esta visión, la serie temporal se interpreta como el resultado de una observación contaminada (e.g., con ruido) de un proceso estocástico. Estos modelos se enmarcan en el reino de la inferencia Bayesiana. Este paradigma contiene tantos modelos lineales como no lineales y, de hecho, incluyen algunos de los modelos descritos anteriormente como casos especiales (e.g., ARIMA), además de otros populares, como los filtros Kalman<sup>33</sup>.

### Métodos para series no lineales

Como ha quedado claro, el campo de los modelos de series temporales (ya solo li-

neales) es muy vasto (como muestra, valga un reciente artículo enciclopédico con más de 280 páginas y 2100 referencias<sup>34</sup>). Por su parte, el estudio de las series temporales no lineales empezó relativamente más tarde que el de lineales, alrededor de los 80, justificado por el hecho de que los investigadores pronto se fueron percatando de que la mayor parte de problemas prácticos se correspondían con sistemas no lineales, para los que la aproximación lineal no era resultaba suficiente. Durante esta época, se comenzó a extender el uso de algunas modificaciones o extensiones no lineales de modelos lineales clásicos como los modelos bilineales, el modelo ARMA exponencial (ExpARMA), o los modelos generales de umbral (TAR, TARMA, SETAR, SETARMA, etc.)<sup>35</sup>.

Poco más tarde, las redes neuronales comenzaron a ser aplicadas en este tipo de problemas, puesto que gozan de la particularidad de ser aproximadores universales; esto es, pueden aproximar cualquier función no lineal con arbitraría precisión<sup>36</sup>. Hoy en día, destacan tres tipos populares de arquitecturas neuronales en predicción de series temporales: redes neuronales convoluciones (CNN), redes neuronales recurrentes (RNN) (y redes de larga memoria a corto plazo (LSTMs)), y los modelos basados en atención. A pesar del gran foco que hay puesto en las RN, la precisión de las RN ha

- 33. James Durbin and Siem Jan Koopman, 'Time Series Analysis by State Space Methods', Time Series Analysis by State Space Methods, 2013 <<https://doi.org/10.1093/acprof:oso/9780199641178.001.0001>>.
- 34. Fotios Petropoulos and others, 'Forecasting: Theory and Practice', 2020. Petropoulos and others.
- 35. J.G. De Gooijer, Elements of Nonlinear Time Series Analysis and Forecasting, 1st edn (Springer, 2017).
- 36. T.E Gomez, 'Acoustic Impedance Matching of Piezoelectric', IEEE Transactions on Ultrasonics, Ferroelectrics and Frequency Control, 51.5 (2004), 624–33.

sido históricamente cuestionada, y era un hecho probado que, a menudo, ensambles modelos tradicionales arrojaban mejores resultados que un modelo de aprendizaje profundo<sup>37</sup>. Por ende, una tendencia moderna consiste en utilizar modelos híbridos: una combinación de modelos tradicionales bien establecidos con redes neuronales, usando estas últimas para generar los parámetros óptimos en cada iteración temporal; estos modelos parecen presentar, en general, una mejoría respecto a modelos “puros”, como se evidencia tras la última competición de predicción de series temporales<sup>38</sup>.

De acuerdo con otros autores, los fundamentos del análisis de series temporales no lineales residen en la teoría de reconstrucción de espacios de fases, un paradigma fundamentado en el teorema de Takens, que permite reconstruir la dinámica de un sistema no lineal complejo a partir de una única serie temporal<sup>39</sup>. Esto guarda estrecha relación con los denominados modelos de espacio de estados, los cuales, como se ha explicado más arriba, consideran que la serie temporal se obtiene como una realización con ruido de un proceso esto-

cástico (sistema subyacente). Como apunte, este paradigma ya se estudió por el CTN en anteriores proyectos, como BitBlue o EnviroPorts.

Tal y como se desprende tras la lectura del estado del arte realizado, la inmensidad del campo de análisis y predicción de series temporales queda más que probada. Sin embargo, un problema detectado es la compartimentación de los diferentes métodos



por ciencias y objetos de estudio, lo que ocasiona que, cuando se pretende analizar y predecir una serie temporal arbitraria, el practicante se enfrenta a la difícil pregunta de qué

modelo elegir de entre la gran miríada de ellos disponibles. En este sentido, no hay muchos trabajos científicos que aborden este problema, por lo que la contribución por el trabajo propuesto en este proyecto por parte del CTN ya sería interesante por esta razón. Adicionalmente, de estos trabajos que sí han tratado este dilema, gran parte de ellos (en parte los más antiguos) se basan en el grado de predicción de los modelos, de forma que deben ser testeados en la serie temporal actual y, consecuentemente,

37. Bryan Lim and Stefan Zohren, ‘Time-Series Forecasting with Deep Learning: A Survey’, *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 379.2194 (2021) <<https://doi.org/10.1098/rsta.2020.0209>>.

38. Spyros Makridakis, Evangelos Spiliotis, and Vassilios Assimakopoulos, ‘The M4 Competition: 100,000 Time Series and 61 Forecasting Methods’, *International Journal of Forecasting*, 36.1 (2020), 54–74 <<https://doi.org/10.1016/j.ijforecast.2019.04.014>>.

39. Elizabeth Bradley and Holger Kantz, ‘Nonlinear Time-Series Analysis Revisited’, *Chaos*, 25.9 (2015) <<https://doi.org/10.1063/1.4917289>>.

mente, son computacionalmente costosos. En contraste, el trabajo propuesto por el CTN se enmarca en aquellos acercamientos más modernos en que se trata de reducir la carga computacional mediante inferencias más inteligentes.

Con todo, como ya se discute en Parmezan<sup>40</sup>, la identificación de los modelos óptimos en función de la tipología de las series temporales no es algo que se haya estudiado rigurosa ni extensivamente. Este problema resulta complejo porque, tal y como expresa el teorema no-free-lunch, no existe un algoritmo único que sea capaz de alcanzar el mejor desempeño cuando se considera cualquier tipo de serie temporal<sup>41</sup>. De hecho, otros artículos abordando este problema también han identificado esta carencia<sup>42</sup>, por lo que el presente proyecto ayudaría a consolidar la correcta implementación de modelos de predicción de series temporales, en particular en algunos de los tipos de series temporales más comunes del entorno marino.

## Metaanálisis de resultados

Los algoritmos de aprendizaje automático resultan muy efectivos a la hora de clasificar muestras y se utilizan cada vez más para tratar de predecir lo que puede ocurrir en un campo concreto dados datos previos. En esta línea, en relación con el objetivo específico 3 de la presente propuesta (OE3), existen investigaciones que emplean el aprendizaje automático para realizar los metaanálisis sobre resultados de experimentos previos, que consisten en recopilar las bases de datos disponibles de cada artículo científico, y, a su vez, conseguir concentrar la mayor cantidad de datos de calidad para después poder aplicar la algoritmia.

En los últimos años, se ha implementado el metaanálisis, de tal forma que probando los diferentes algoritmos que existen (Naive Bayes, máquinas de soporte vectorial, redes neuronales, vecinos más cercanos y árboles de decisión), los que mejor predicen en este campo son las máquinas de soporte vectorial como ocurre en trastornos de la voz<sup>43</sup>, en el cáncer de pecho<sup>44</sup>, en la septicemia<sup>45</sup> y

- 40. Antonio Rafael Sabino Parmezan, Vinicius M.A. Souza, and Gustavo E.A.P.A. Batista, ‘Evaluation of Statistical and Machine Learning Models for Time Series Prediction: Identifying the State-of-the-Art and the Best Conditions for the Use of Each Model’, *Information Sciences*, 484 (2019), 302–37 <<https://doi.org/10.1016/j.ins.2019.01.076>>.
- 41. Sasan Barak, Mahdi Nasiri, and Mehrdad Rostamzadeh, ‘Time Series Model Selection with a Meta-Learning Approach; Evidence from a Pool of Forecasting Algorithms’, *CoRR*, abs/1908.0 (2019), 1–30.
- 42. Christiane Lemke and Bogdan Gabrys, ‘Meta-Learning for Time Series Forecasting and Forecast Combination’, *Neurocomputing*, 73.10–12 (2010), 2006–16 <<https://doi.org/10.1016/j.neucom.2009.09.020>>.
- 43. Syed, S. A., Rashid, M., & Hussain, S. (2020). Meta-analysis of voice disorders databases and applied machine learning techniques. *Mathematical Biosciences and Engineering*, 17(6), 7958–7979.
- 44. Nindrea, R. D., Aryandono, T., Lazuardi, L., & Dwiprahasto, I. (2018). Diagnostic accuracy of different machine learning algorithms for breast cancer risk calculation: a meta-analysis. *Asian Pacific journal of cancer prevention: APJCP*, 19(7), 1747.
- 45. Islam, M. M., Nasrin, T., Walther, B. A., Wu, C. C., Yang, H. C., & Li, Y. C. (2019). Prediction of sepsis patients using machine learning approach: a meta-analysis. *Computer methods and programs in biomedicine*, 170, 1–9.

en enfermedades cardiovasculares<sup>46</sup>. En este sentido, el campo de la medicina le está dando cada vez más importancia al aprendizaje automático con el fin de predecir qué pacientes pueden padecer una enfermedad u otra. Estas técnicas también se han utilizado para mejorar el bienestar personal mediante el entrenamiento cognitivo, en el cual se incorporaron datos diver-

sos, de diferentes métodos de entrenamiento, así como tiempo de entrenamiento, edad o sexo de las personas implicadas<sup>47</sup>.

En el ámbito del aprendizaje profundo, también hay estudios utilizando un metaanálisis como forma de extracción de datos en el diagnóstico de desórdenes neurológicos<sup>48</sup> y, por otro lado, en la teledetección para el mapeo mediante imágenes<sup>49</sup>.

## 4.5. Origen, naturaleza y estudios de series temporales con aplicación al medio marino

**C**on este proyecto, el CTN pretende acumular una gran diversidad datos de series temporales provenientes de distintos sectores relacionados con el medio marino, incluidos el sector portuario, acuícola, energético y oceanográfico u observación. En este sentido, cabe esperar elevada variedad, tanto en procedencia, dimensionalidad y cantidad de cada uno de ellos.

A continuación, se contextualiza, para cada ámbito, la tipología de datos que se pueden disponer, así como estudios y proyectos previos que impulsan el estudio de series temporales:

### Sector Portuario

Debido al auge tecnológico y al surgimiento del concepto “Green Ports” o “Puertos verdes” para abordar las preocupaciones de sostenibilidad ambiental y social relacionados con los puertos, cada vez son más las iniciativas, estrategias y estudios desde diferentes organismos llevadas a cabo para la regulación de la sostenibilidad y reducción de los impactos ambientales y actividades marítimas<sup>50</sup>. Esto supone que se lleven a cabo diferentes acciones de monitorización de las actividades adversas, que dan lugar a la generación de multitud de datos de diferente índole. En este sentido, el CTN ha par-

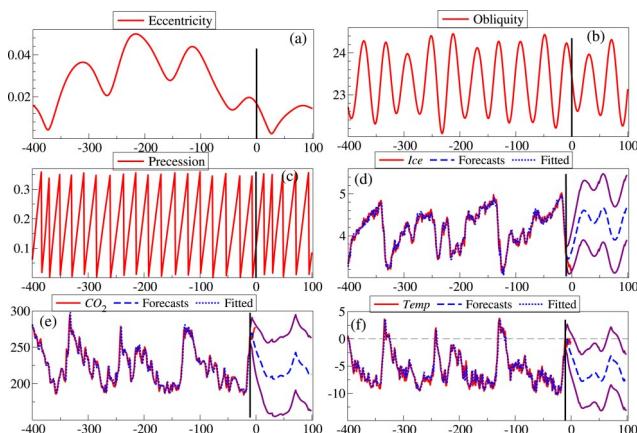
- 46. Krittawong, C., Virk, H. U. H., Bangalore, S., Wang, Z., Johnson, K. W., Pinotti, R., ... & Tang, W. W. (2020). Machine learning prediction in cardiovascular diseases: a meta-analysis. *Scientific reports*, 10(1), 1-11.
- 47. Shani, R., Tal, S., Derakshan, N., Cohen, N., Enock, P. M., McNally, R. J., ... & Okon-Singer, H. (2021). Personalized cognitive training: Protocol for individual-level meta-analysis implementing machine learning methods. *Journal of psychiatric research*, 138, 342-348.
- 48. Gautam, R., & Sharma, M. (2020). Prevalence and diagnosis of neurological disorders using different deep learning techniques: a meta-analysis. *Journal of medical systems*, 44(2), 1-24.
- 49. Ma, L., Liu, Y., Zhang, X., Ye, Y., Yin, G., & Johnson, B. A. (2019). Deep learning in remote sensing applications: A meta-analysis and review. *ISPRS journal of photogrammetry and remote sensing*, 152, 166-177.
- 50. Ching Chih Chang and Chih Min Wang, 'Evaluating the Effects of Green Port Policy: Case Study of Kaohsiung Harbor in Taiwan', *Transportation Research Part D: Transport and Environment*, 17.3 (2012), 185–89 <<https://doi.org/10.1016/j.trd.2011.11.006>>.

ticipado en proyectos como Enviroports, BitBlue o LIFE PortSounds, que se enmarcan bajo el paradigma de puertos sostenibles. En este ámbito, la procedencia y tipología series temporales que típicamente se emplean son:

- **Tráfico marítimo:** este tipo de serie temporal proporciona información detallada sobre movimientos de embarcaciones, rutas marítimas o puertos, a una escala global. Generalmente, los datos de tráfico marítimo proporcionan información geoespacial, tratándose de datos bidimensionales que suelen representarse en forma de ráster.

## Sector Acuícola

Siendo consciente de la necesidad de automatizar sus procesos y operaciones remotas, así como de tener un mayor control de toda su producción que permita una mejora en la sostenibilidad y en la competitividad global (EATIP), el sector acuícola está dando, poco a poco, un paso hacia la transformación digital. No solo esto, sino que, mediante la implementación de nuevas tecnologías y técnicas de automatización desean minimizar algunos de los principales problemas que han de hacer frente co-



mo el desperdicio de pienso suministrado, con sus impactos tanto económicos como medioambientales, como las pérdidas de jaulas y escapes de cardumen derivados de la falta de integridad de sus infraestructuras y compatibilidad con fenómenos meteorológicos adversos. Proyectos como DEMO-Blue Smart Feed, GLORIA-2, DigiSafeCage o SmartBite, en los que CTN realizará acciones de investigación e integración y tecnologías digitales, intentan avanzar en esta línea y pretenden aportar ese valor añadido al sector e intentar paliar los problemas a los que hace frente. En este ámbito, la procedencia y tipología series temporales que típicamente se emplean son:

- **Metodología de alimentación:** Este conjunto de datos se corresponde con datos históricos que son actualizados diariamente. Engloban tanto las tablas de alimentación, los parámetros SFR (Specific Feeding Rate) y SGR (Specific Growth Rate), la talla y el número de peces de la jaula en o el tamaño de los pellets y tomas diarias, entre otros. Este tipo de parámetros suelen ser series temporales unidimensionales.
- **Parámetros medioambientales:** en este caso, los parámetros medioambientales se corresponden con información sobre temporales meteorológicos, pH, corriente, oleaje, temperatura u oxígeno entre otros.
- **Parámetros físicos:** correspondientes al estado de la instalación, infraestructura de la jaula, la calidad de los materiales e información sobre las revisiones periódicas. Obtenidos mediante sensores de flotabilidad y deforma-

ción, sensores de esfuerzos y cámaras de inspección. Por lo tanto, estas series temporales serán tanto unidimensionales como tridimensionales.

## Sector Energético

Una de las principales necesidades para alentar el impulso y desarrollo tanto de la economía azul en general, como de la propia transición energética en el medio marino en particular, es mejorar el conocimiento sobre las presiones e impactos derivados de actividades antropogénicas sobre la biodiversidad. Para hacer compatible esta transición energética con la biodiversidad marina, se están proponiendo enfoques cada vez más disruptivos donde los datos y, por extensión, las series temporales registradas son la base para la evaluación de estas relaciones e impactos. Proyectos europeos como WESE y SafeWAVE hacen frente a esta problemática, en los que CTN lidera el desarrollo y validación de modelos de impacto acústico, electromagnético e hidrodinámico de los sistemas de energía undimotriz. En este ámbito, la procedencia y tipología series temporales que típicamente se emplean son:

- **Parámetros medioambientales:** por un lado, series multivariadas no espacialmente extendidas (1D), correspondientes a datos de oleaje (altura de ola y periodo), así como precipitación. Por otro lado, series tridimensionales (rasters en profundidad) de datos de temperatura y salinidad del agua en columna de agua.
- **Parámetros de maquinaria:** la actividad de los generadores de energía se

monitoriza en series temporales multivariable (1D) correspondientes a variables tales como: potencia eléctrica generada, revoluciones por minuto del rotor, entre otros.

- **Acústicos:** el grueso del análisis se realiza sobre los datos acústicos recogidos por los hidrófonos instalados alrededor de los convertidores de energía, que se tratan de series temporales multivariable (3 hidrófonos) unidimensionales (espacialmente).
- **AIS:** posiciones temporalmente referenciadas de embarcaciones cercanas. Se pueden interpretar como series temporales multivariable (latitud/longitud, barcos).

Más allá de esta casuística de procedencia de series temporales, se encuentran plataformas colaborativas como Kaggle, Github o EMODnet en la que se disponen de grandes conjuntos de datos de series temporales gratuitamente (*open-source*). Asimismo, también es posible disponer de un amplio conjunto de datos cuyas características se asemejen a las características que podrían presentar los datos anteriormente descritos. Este conjunto de datos estaría conformado por datos sintéticos, que no son más que un conjunto de datos elaborados a conciencia a partir de una serie de reglas predefinidas como puede ser que los datos tengan un valor promedio establecido, que no presenten ninguna correlación entre ellos o que aparezcan huecos en el conjunto de datos formado.

# 5. Tendencias

## 5.1. Literatura científica

### 01 Machine intelligence and data-driven future of marine science

**Autor:** Ketil Malde, Nils Olav Handegard, Line Eikvil, Arnt-Børre Salberg,

**Publicado en:** ICES Journal of Marine Science 77(4):1274-1285. DOI: 10.1093/icesjms/fsz057

**Abstract:** Oceans constitute over 70% of the earth's surface, and the marine environment and ecosystems are central to many global challenges. Not only are the oceans an important source of food and other resources, but they also play a important roles in the earth's climate and provide crucial ecosystem services. To monitor the environment and ensure sustainable exploitation of marine resources, extensive data collection and analysis efforts form the backbone of management programmes on global, regional, or national levels. Technological advances in sensor technology, autonomous platforms, and information and communications technology...

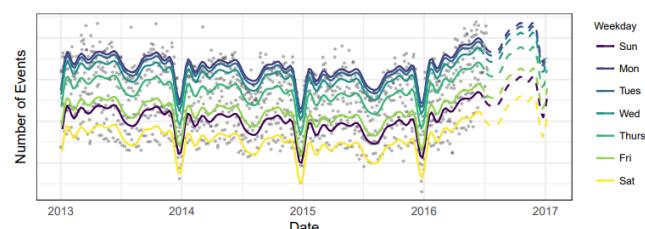


### 02 Forecasting at scale

**Autor:** Sean J. Tylor, Benjamin Letham,

**Publicado en:** The American Statistician 72 (1):37-45.

DOI: 10.7287/peerj.preprints.3190v2



**Abstract:** Forecasting is a common data science task that helps organizations with capacity planning, goal setting, and anomaly detection. Despite its importance, there are serious challenges associated with producing reliable and high quality forecasts – especially when there are a variety of time series and analysts with expertise in time series modeling are relatively rare. To address these challenges, we describe a practical approach to forecasting “at scale” that combines configurable models with analyst-in-the-loop performance analysis...

### 03 Forecasting big time series: old and new

**Autor:** Christos Faloutsos, Jan Gasthaus, Tim Januschowski, Yuyang Wang,

**Publicado en:** Proceedings of the VLDB Endowment 11(12):2102-2105.

**Abstract:** Time series forecasting is a key

ingredient in the automation and optimization of business processes: in retail, deciding which products to order and where to store them depends on the forecasts of future demand in different regions; in cloud computing, the estimated future usage of services and infrastructure components guides capacity planning; and workforce scheduling in warehouses, call centers, factories requires forecasts of the future workload. Recent years have witnessed a paradigm shift in forecasting techniques and applications, from computer-assisted model - and assumption-based to data-driven and fully-automated...

## 04

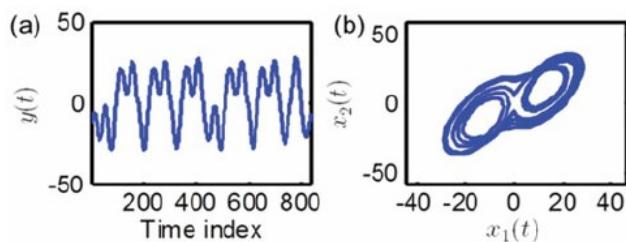
### Time series forecasting for nonlinear and nonstationary processes: a review and comparative study

**Autor:** Changqing Cheng, Akkarapol Sa-Ngasoongsong, Omer Faruk Beyca, Trung Le, et al.,

**Publicado en:** IIE Transactions.  
DOI: 10.1080/0740817X.2014.999180

**Abstract:** Forecasting the evolution of complex systems is noted as one of the ten grand challenges of modern science. Time series data from complex systems capture the dynamic behaviors and causalities of the underlying processes and provide a tractable means to predict and monitor system state evolution. However, the nonlinear and nonstationary dynamics of the underlying processes pose a major challenge for accurate forecasting. For most real-world systems, the vector field of state dynamics is a nonlinear function of the state

variables, i.e., the relationship connecting intrinsic state variables with their autoregressive terms and exogenous variables is nonlinear.



## 05

### Modelling and analysis in marine big data: advances and challenges

**Autor:** Dongmei Huang, Danfeng Zhao, Lifei Wei, Zhenhua Wang, Yanling Du,

**Publicado en:** Computational Methods for Engineering Science.

DOI: 10.1155/2015/384742

**Abstract:** It is aware that big data has gathered tremendous attentions from academic research institutes, governments, and enterprises in all aspects of information sciences. With the development of diversity of



marine data acquisition techniques, marine data grow exponentially in last decade, which forms marine big data. As an innovation, marine big data is a double-edged sword. On the one hand, there are many potential and highly useful values hidden in the huge volume of marine data, which is widely used in marine-related fields, such as tsunami and red-tide warning, prevention, and forecasting, disaster inversion, and visualization modelling...

## 06

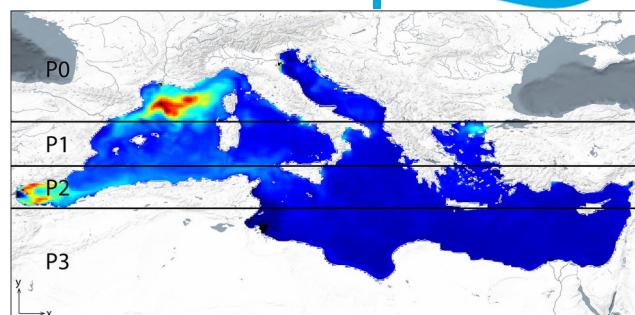
### Parallel implementation of data assimilation scheme for operational oceanography: the case of the MedBFM model system

**Autor:** A.Teruzzi, P. Di Cerbo, G. Cossarini, E. Pascolo, S. Salon,

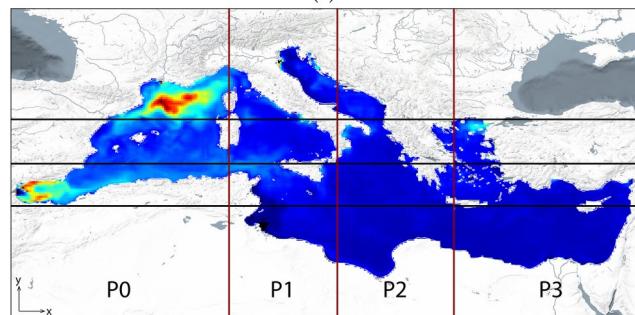
**Publicado en:** Computers & Geosciences 124:103-114.

DOI: 10.1016/j.cageo.2019.01.003

**Abstract:** The MedBFM model system provides forecasts and reanalysis of the Mediterranean Sea biogeochemistry for the European Copernicus Services. The system integrates model and observations through a 3D variational assimilation scheme, whose performance capitalizes on present HPC systems and ensures compliance with the service requirements. Domain decomposition with message passing paradigm was implemented to parallelize the assimilation code and maximize performance and scalability. In particular, the parallelization of the horizontal recursive filtering algorithm was implemented using a dynamic sliced domain decomposition...



(a)



(b)

## 07

### Monitoring for tipping points in the marine environment

**Autor:** Judie E. Hewitt, Simon F. Thrush,

**Publicado en:** Journal of Environmental Management 234:131-137.

**Abstract:** Increasingly studies are reporting sudden and dramatic changes in the structure and function of communities or ecosystems. The prevalence of these reports demonstrates the importance for management of being able to detect whether these have happened and, preferably, whether they are likely to occur. Ecological theory provides the rationale for why such changes occur and a variety of statistical indicators of approach that have generic properties have been developed. However, whether the theory has successfully translated into monitoring programmes is unknown...

08

## Internet of underwater thing and big marine data analytics— A comprehensive survey

**Autor:** Mohammad Jahanbakht, Wei Xiang, Lajos Hanzo, Mostafa Rahimi Azghadi,

**Publicado en:** IEEE Communications surveys & Tutorials 23(2).

DOI: 10.1109/COMST.2021.3053118

**Abstract:** The Internet of Underwater Things (IoUT) is an emerging communication ecosystem developed for connecting underwater objects in maritime and underwater environments. The IoUT technology is intricately linked with intelligent boats and ships, smart shores and oceans, automatic marine transportations, positioning and navigation, underwater exploration, disaster prediction and prevention, as well as with intelligent monitoring and security. The IoUT has an influence at various scales ranging from a small scientific observatory, to a mid-sized harbor, and to covering global oceanic trade. The network architecture of IoUT is intrinsically heterogeneous and should be sufficiently resilient to operate in harsh environments...

09

## Maritime spatial planning sup- ported by infrastructure for spatial information in Europe (INSPIRE)

**Autor:** Andrej Abramic, Emanuele Bigagli, Vittorio Barale, Michael Assouline, Alberto Lorenzo-Alonso, Conor Norton,

**Publicado en:** Ocean & Coastal Management 152:23-36.

DOI: 10.1016/j.ocecoaman.2017.11.007

**Abstract:** The implementation of Directive 2007/2/EC - INSPIRE can improve and actually strengthen the information management and data infrastructures needed for setting up Maritime Spatial Planning (MSP) processes. Evidence for this comes from three parallel analyses: links between the MSP Framework Directive and INSPIRE components and implementation; the availability of marine and maritime data through the INSPIRE Geo-Portal; and the adequacy of using an INSPIRE data model for mapping maritime spatial plans...

10

## Principles and algorithms for forecasting groups of time se- ries: locality and globality

**Autor:** Pablo Montero-Manso, Rob J. Hyndman,

**Publicado en:** International Journal of Forecasting 37(4):1632-1653.

DOI: 10.1016/j.ijforecast.2021.03.004

**Abstract:** Global methods that fit a single forecasting method to all time series in a set have recently shown surprising accuracy, even when forecasting large groups of heterogeneous time series. We provide the following contributions that help understand the potential and applicability of global methods and how they relate to traditional local methods that fit a separate forecasting method to each series...

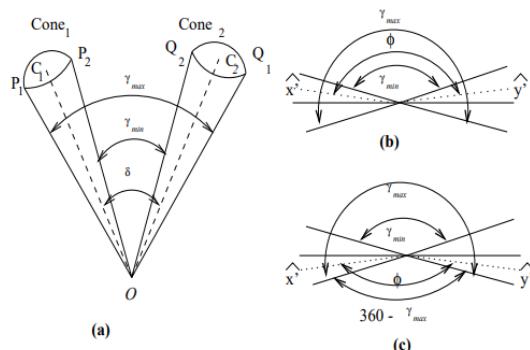
11

## Correlation analysis of spatial tie series datasets: a filter-and- refine approach

**Autor:** Pusheng Zhang, Yan Huang, Sashi

**Publicado en:** Proceedings of the 7th Pacific-Asia conference on Advances in knowledge discovery and data mining (Conference).

DOI: 10.1007/3-540-36175-8\_53



**Abstract:** A spatial time series dataset is a collection of time series, each referencing a location in a common spatial framework. Correlation analysis is often used to identify pairs of potentially interacting elements from the cross product of two spatial time series datasets. However, the computational cost of correlation analysis is very high when the dimension of the time series and the number of locations in the spatial frameworks are large. The key contribution of this paper is the use of spatial autocorrelation among spatial neighboring time series to reduce computational cost.

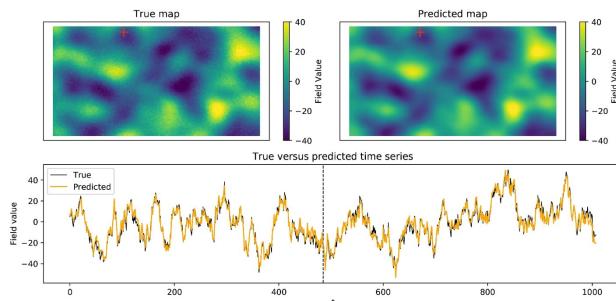
## 12 A novel framework for spatio-temporal prediction of environmental data using deep learning

**Autor:** Federico Amato, Fabian Guignard, Sylvain Robert, Mikhail Kanevski,

**Publicado en:** Scientific Reports 10.  
DOI: 10.1038/s41598-020-79148-7

**Abstract:** As the role played by statistical

and computational sciences in climate and environmental modelling and prediction becomes more important, Machine Learning researchers are becoming more aware of the relevance of their work to help tackle the climate crisis. Indeed, being universal nonlinear function approximation tools, Machine Learning algorithms are efficient in analysing and modelling spatially and temporally variable environmental data. While Deep Learning models have proved to be able to capture spatial, temporal, and spatio-temporal dependencies through their automatic feature representation learning, the problem of the interpolation of continuous spatio-temporal fields measured on a set of irregular points in space is still under-investigated....



## 13 Testing time series linearity: traditional and bootstrap methods

**Autor:** Arthur Berg, Timothy McMurry, Dimitris N. Politis,

**Publicado en:** Handbook of statistics 30:27-42.

DOI: 10.1016/B978-0-444-53858-1.00002-8

**Abstract:** We review the notion of time series linearity and describe recent advances in linearity and Gaussianity testing via data resampling methodologies. Many advances have been made since the first published

tests of linearity and Gaussianity by Subba Rao and Gabr in 1980, including several resampling-based proposals. This chapter is intended to be instructive in explaining and motivating linearity testing. Recent results on the validity of the AR-sieve bootstrap for linearity testing are reviewed. In addition, a subsampling-based linearity and Gaussianity test is proposed where asymptotic consistency of the testing procedure is justified...

14

### Nonlinear forecasting as a way of distinguishing chaos from measurement error in time series

**Autor:** G Sugihara, R M May,

**Publicado en:** Nature 344(6268):743-41.  
DOI: 10.1038/344734a0

**Abstract:** An approach is presented for making short-term predictions about the trajectories of chaotic dynamical systems. The method is applied to data on measles, chickenpox, and marine phytoplankton populations, to show how apparent noise associated with deterministic chaos can be distinguished from sampling error and other sources of externally induced environmental noise.

15

### A test for linearity of stationary time series

**Autor:** T. Subba Rao, M. M. Gabr,

**Publicado en:** Journal of Time Series Analysis 1(2):145-158.  
DOI: 10.1111/j.1467-9892.1980.tb00308.x

**Abstract:** A standard assumption that is often made in time series analysis is that the series conforms to a linear model. The object of this paper is to describe statistical tests for testing this assumption. The tests are constructed from the bispectral density function, and depend on the application of Hotelling T<sub>2</sub>. These tests are illustrated with two real time series and four simulated time series. Some guidelines about the choice of the parameters are also included.

16

### Testing the null hypothesis of stationarity against the alternative of a unit root: How sure are we that economic time series have unit root?

**Autor:** Denis Kwiatkowski, Peter C. B. Phillips, Peter Schmidt, Yongcheol Shin,

**Publicado en:** Journal of Econometrics 54(1-3):159-178.  
DOI: 10.1016/0304-4076(92)90104-Y

**Abstract:** We propose a test of the null hypothesis that an observable series is stationary around a deterministic trend. The series is expressed as the sum of deterministic trend, random walk, and stationary error, and the test is the LM test of the hypothesis that the random walk has zero variance. The asymptotic distribution of the statistic is derived under the null and under the alternative that the series is difference-stationary. Finite sample size and power are considered in a Monte Carlo experiment. The test is applied to the Nelson-Plosser data, and for many of these series the hypothesis of trend stationarity cannot be rejected...

## 17 A study in analysis of stationary time-series

**Autor:** Maurice Kendall, Herman Wold,

**Publicado en:** Journal of the royal statistical society 102(2):295-298.  
DOI: 10.2307/2980009

**Abstract:** This paper discusses comparison of two time series decomposition methods: The Least Squares Estimation (LSE) and Buys-Ballot Estimation (BBE) methods. As noted by Iwueze and Nwogu (2014), there exists a research gap for the choice of appropriate model for decomposition and detection of presence of seasonal effect in a series model. Estimates of trend parameters and seasonal indices are all that are needed to fill the research gap. However, these estimates are obtainable through the Least Squares Estimation (LSE) and Buys-Ballot Estimation (BBE) methods. Hence, there is need to compare estimates of the two methods and recommend...

## 18 GARCH time series models: an application to retail livestock prices

**Autor:** Satheesh V. Aradhyula, Matthew T. Holt,

**Publicado en:** Western Journal od Agricultural Economics 13:88-29.

**Abstract:** Traditional time series models assume a constant conditional variance. Realizing the implausibility of this assumption, Bollerslev proposed Generalized Auto-regressive Conditional Heteroscedasticity (GARSH) processes, which are character-

ized by nonconstant conditional variances. In this paper, GARCH (1,1) processes were applied to model livestock prices. Results indicate that GARCH processes adequately describe retail meat price behavior...

## 19 Forecasting sales by exponentially weighted moving averages

**Autor:** Peter R. Winters,

**Publicado en:** Management Science 6(3).  
DOI: 10.1287/mnsc.6.3.324

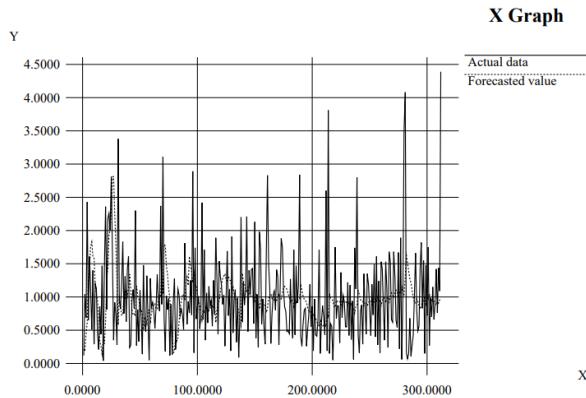
**Abstract:** The growing use of computers for mechanized inventory control and production planning has brought with it the need for explicit forecasts of sales and usage for individual products and materials. These forecasts must be made on a routine basis for thousands of products, so that they must be made quickly, and, both in terms of computing time and information storage, cheaply; they should be responsive to changing conditions. The paper presents a method of forecasting sales which has these desirable characteristics, and which in terms of ability to forecast compares favorably with other, more traditional methods. Several models of the exponential forecasting system are presented, along with several examples of application...

## 20 Time series forecasting using holt-winters exponential smoothing

**Autor:** Prajakta S Kalekar,

**Abstract:** Many industrial time series exhibit seasonal behavior, such as demand

for apparel or toys. Consequently, seasonal forecasting problems are of considerable importance. This report concentrates on the analysis of seasonal time series data using Holt-Winters exponential smoothing methods. Two models discussed here are the Multiplicative Seasonal Model and the Additive Seasonal Model.



21

### An investigation of neural networks for linear time-series forecasting

**Autor:** Guoqiang Peter Zhang,

**Publicado en:** Computers & Operations Research 28(12):1183-1202. DOI: 10.1016/S0305-0548(00)00033-2

**Abstract:** This study examines the capability of neural networks for linear time-series forecasting. Using both simulated and real data, the effects of neural network factors such as the number of input nodes and the number of hidden nodes as well as the training sample size are investigated. Results show that neural networks are quite competent in modeling and forecasting linear time series in a variety of situations and simple neural network structures are often effective in modeling and forecasting linear time series...

22

### Think globally, act locally: a deep neural network approach to high-dimensional time series forecasting

**Autor:** Rajat Sen, Hsiang-Fu Yu, Inderjit Dhillon,

**Publicado en:** NIPS'19: Proceedings of the 33rd International Conference on Neural Information Processing Systems 4837-4846.

**Abstract:** Forecasting high-dimensional time series plays a crucial role in many applications such as demand forecasting and financial predictions. Modern datasets can have millions of correlated time-series that evolve together, i.e they are extremely high dimensional (one dimension for each individual time-series). There is a need for exploiting global patterns and coupling them with local calibration for better prediction. However, most recent deep learning approaches in the literature are one-dimensional, i.e, even though they are trained on the whole dataset, during prediction, the future forecast for a single dimension mainly depends on past values from the same dimension...

23

### Deep forecast: deep learning-based spatio-temporal forecasting

**Autor:** Amir Ghaderi, B. M. Sanandaji, Faezeh Ghaderi,

**Publicado en:** ArXiv

**Abstract:** The paper presents a spatio-temporal wind speed forecasting algorithm

using Deep Learning (DL) and in particular, Recurrent Neural Networks (RNNs). Motivated by recent advances in renewable energy integration and smart grids, we apply our proposed algorithm for wind speed forecasting. Renewable energy resources (wind and solar) are random in nature and, thus, their integration is facilitated with accurate short-term forecasts...

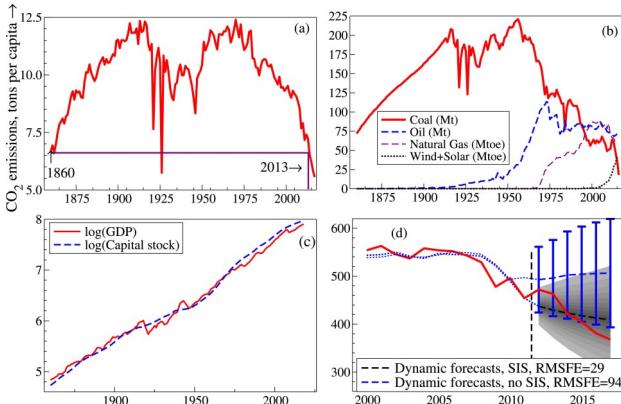
## 24 Forecasting: theory and practice

**Autor:** Fotios Petropoulos, Daniele Apietti, et al.,

**Publicado en:** International Journal of Forecasting 38(3):705-87.

DOI: 10.1016/j.ijforecast.2021.11.001

**Abstract:** Forecasting has always been at the forefront of decision making and planning. The uncertainty that surrounds the future is both exciting and challenging, with individuals and organisations seeking to minimise risks and maximise utilities. The large number of forecasting applications calls for a diverse set of forecasting meth-



ods to tackle real-life challenges. This article provides a non-systematic review of the theory and the practice of forecasting. We provide an overview of a wide range of theoretical, state-of-the-art models, methods, prin-

ciples, and approaches to prepare, produce, organise, and evaluate forecasts. We then demonstrate how such theoretical concepts are applied in a variety of real-life contexts...

## 25 Acoustic impedance matching of piezoelectric transducers

**Autor:** T.E. Gómez Álvarez-Arenas,

**Publicado en:** IEEE transactions on ultrasonic, ferroelectrics, and frequency control 51 (5):624-633. DOI: 10.1109/TUFFC.2004.1302770

**Abstract:** The purpose of this work is three-fold: to investigate material requirements to produce impedance matching layers for air-coupled piezoelectric transducers, to identify materials that meet these requirements, and to propose the best solution to produce air-coupled piezoelectric transducers for the low megahertz frequency range. Toward this end, design criteria for the matching layers and possible configurations are reviewed. Among the several factors that affect the efficiency of the matching layer, the importance of attenuation is pointed out...

## 26 Time-series forecasting with deep learning: a survey

**Autor:** Bryan Lim, Stefan Sohren,

**Publicado en:** Machine learning for weather and climate modelling 379(2194). DOI: 10.1098/rsta.2020.0209

**Abstract:** Numerous deep learning architectures have been developed to accommo-

date the diversity of time-series datasets across different domains. In this article, we survey common encoder and decoder designs used in both one-step-ahead and multi-horizon time-series forecasting—describing how temporal information is incorporated into predictions by each model. Next, we highlight recent developments in hybrid deep learning models, which combine well-studied statistical models with neural network components to improve pure methods in either category. Lastly, we outline some ways in which deep learning can also facilitate decision support with time-series data...

27

## Nonlinear time-series analysis revised

**Autor:** Elizabeth Bradley, Holger Kantz,

**Publicado en:** arXiv 25(9). DOI: 10.1063/1.4917289

**Abstract:** In 1980 and 1981, two pioneering papers laid the foundation for what became known as nonlinear time-series analysis: the analysis of observed data—typically univariate—via dynamical systems theory. Based on the concept of state-space reconstruction, this set of methods allows us to compute characteristic quantities such as...

28

## Evaluation of statistical and machine learning models for time series prediction: identifying the state-of-the-art and the best conditions for the use of each model

**Autor:** Antonio Rafael Sabino Parmezan, Vinicius M. A. Souza, Gustavo E. A. P. A. Batista,

**Publicado en:** Information Sciences 484:302-337.

DOI: 10.1016/j.ins.2019.01.076

**Abstract:** The choice of the most promising algorithm to model and predict a particular phenomenon is one of the most prominent activities of the temporal data forecasting. Forecasting (or prediction), similarly to other data mining tasks, uses empirical evidence to select the most suitable model for a problem at hand since no modeling method can be considered as the best. However, according to our systematic literature review of the last decade, few scientific publications rigorously expose the benefits and limitations of the most popular algorithms for time series prediction...

29

## Time series model selection with a meta-learning approach; evidence from a pool of forecasting algorithms

**Autor:** Sasan Barak, Mahdi Nasiri, Mehrdad Rostamzadeh,

**Publicado en:** arXiv

**Abstract:** One of the challenging questions in time series forecasting is how to find the best algorithm. In recent years, a recommender system scheme has been developed for time series analysis using a meta-learning approach. This system selects the best forecasting method with consideration of the time series characteristics. In this paper, we propose a novel approach to focusing on some of the unanswered questions resulting from the use of meta-learning in time series forecasting...

30

## Meta-learning for time series forecasting and forecast combination

**Autor:** Christiane Lemke, Bogdan Gabrys,

**Publicado en:** Neurocomputing 73(10-12):2006-2016.

DOI: 10.1016/j.neucom.2009.09.020

**Abstract:** In research of time series forecasting, a lot of uncertainty is still related to the task of selecting an appropriate forecasting method for a problem. It is not only the individual algorithms that are available in great quantities; combination approaches have been equally popular in the last decades. Alone the question of whether to choose the most promising individual method or a combination is not straightforward to answer. Usually, expert knowledge is needed to make an informed decision, however, in many cases this is not feasible due to lack of resources like time, money and manpower...

31

## Meta-analysis of voice disorders databases and applied machine learning techniques

**Autor:** Engr. Dr. Sidra Abid Syed, Sheikh Muhammad Munaf Rashid, Samreen Hussain,

**Publicado en:** Mathematical biosciences and engineering: MBE 17(6). DOI: 10.3934/mbe.2020404

**Abstract:** Voice disorders are pathological conditions that directly affect voice production. Computer based diagnosis may play a major role in the early detection and in

tracking and even development of efficient pathological speech diagnosis, based on a computerized acoustic evaluation. The health of the Voice is assessed by several acoustic parameters. The exactness of these parameters is often linked to algorithms used to estimate them for speech noise identification...

32

## Diagnostic accuracy of different machine learning algorithms for breast cancer risk calculation: a meta-analysis

**Autor:** Ricvan Dana Nindrea, Teguh Aryan-dono, Lutfan Lazuardi, Iwan Dwiprahasto,

**Publicado en:** Asian Pacific Journal of Cancer Prevention 19(7):1747-1752. DOI: 10.22034/APJCP.2018.19.7.1747

**Abstract:** The aim of this study was to determine the diagnostic accuracy of different machine learning algorithms for breast cancer risk calculation. Methods: A meta-analysis was conducted of published research articles on diagnostic test accuracy of different machine learning algorithms for breast cancer risk calculation published between January 2000 and May 2018 in the online article databases of PubMed, ProQuest and EBSCO. Paired forest plots were employed for the analysis. Numerical values for sensitivity and specificity were obtained from false negative (FN), false positive (FP), true negative (TN) and true positive (TP) rates, presented alongside graphical representations with boxes marking the values and horizontal lines showing the confidence intervals (CIs)...

33

## Prediction of sepsis patients using machine learning approach: a meta-analysis

**Autor:** Md. Mohaimenul Islam, Tahmina Nasrin, Bruno Andreas Walther, Chieh-Chen Wu, Hsuan-Chia Yang, Yu-Chuan Li (Jack),

**Publicado en:** Computer Methods and Programs in Biomedicine 170:1-9. DOI: 10.1016/j.cmpb.2018.12.027

**Abstract:** Sepsis is a common and major health crisis in hospitals globally. An innovative and feasible tool for predicting sepsis remains elusive. However, early and accurate prediction of sepsis could help physicians with proper treatments and minimize the diagnostic uncertainty. Machine learning models could help to identify potential clinical variables and provide higher performance than existing traditional low-performance models. We therefore performed a meta-analysis of observational studies to quantify the performance of a machine learning model to predict sepsis...

34

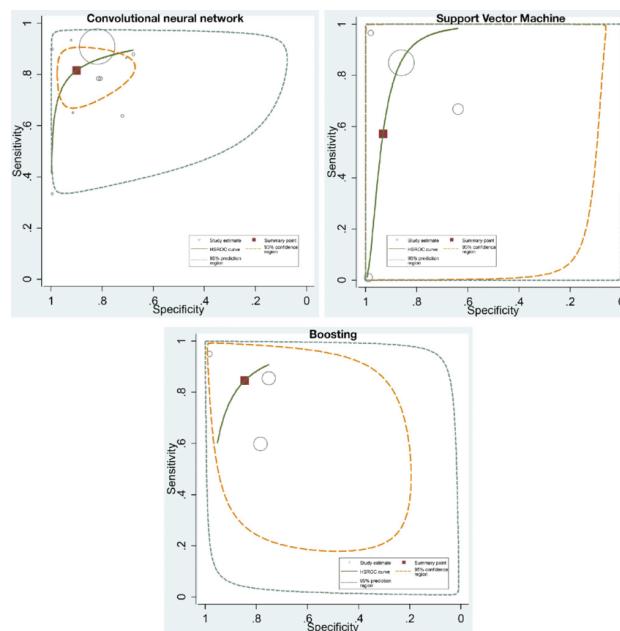
## Machine learning prediction in cardiovascular diseases: a meta-analysis

**Autor:** Chayakrit Krittawong, Hafeez Ul Hassan Virk, Sripal Bangalore, Zhen Wang,

**Publicado en:** Scientifics Reports 10(16057). DOI: 10.1038/s41598-020-72685-1

**Abstract:** Abstract Several machine learning (ML) algorithms have been increasingly utilized for cardiovascular disease prediction. We aim to assess and summarize the overall predictive ability of ML algorithms in cardiovascular diseases. A comprehen-

sive search strategy was designed and executed within the MEDLINE, Embase, and Scopus databases from database inception through March 15, 2019. The primary outcome was a composite of the predictive ability of ML algorithms of coronary artery disease, heart failure, stroke, and cardiac arrhythmias.



## Personalized cognitive training: protocol for individual-level meta-analysis implementing machine learning methods

**Autor:** Reut Shani, Shachaf Tal, Nazanin Derakshan, et al.,

**Publicado en:** Jorunal of Psychiatric Research 138:342-348. DOI: 10.1016/j.jpsychires.2021.03.043

**Abstract:** Accumulating evidence suggests that cognitive training may enhance well-being. Yet, mixed findings imply that individual differences and training characteristics may interact to moderate training efficacy. To investigate this possibility, the cur-

rent paper describes a protocol for a data-driven individual-level meta-analysis study aimed at developing personalized cognitive training.

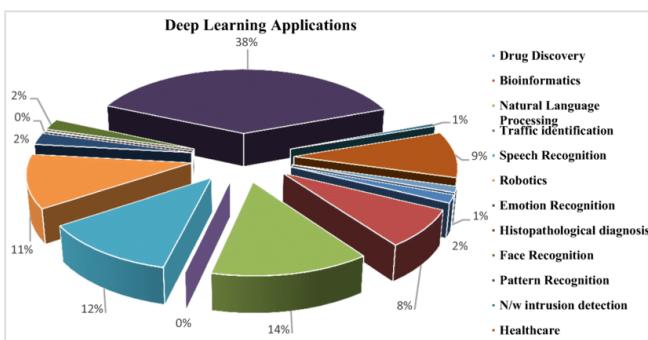
36

### Prevalence and Diagnosis of Neurological Disorders Using Different Deep Learning Techniques: a meta-analysis

**Autor:** Ritu Gautam, Manik, Sharma,

**Publicado en:** Journal of Medical Systems 44(2). DOI: 10.1007/s10916-019-1519-7

**Abstract:** This paper dispenses an exhaustive review on deep learning techniques used in the prognosis of eight different neuropsychiatric and neurological disorders such as stroke, alzheimer, parkinson's, epilepsy, autism, migraine, cerebral palsy, and multiple sclerosis. These diseases are critical, life-threatening and in most of the cases may lead to other precarious human disorders...



37

### Deep learning in remote sensing applications: a meta-analysis and review

**Autor:** Lei Ma, Yu Liu, Xueliang Zhang, Yuanxin Ye, Gaofei Yin, Brian Alan Johnson,

**Publicado en:** Journal of Medical Systems 44(2). DOI: 10.1007/s10916-019-1519-7

**Abstract:** Deep learning (DL) algorithms have seen a massive rise in popularity for remote-sensing image analysis over the past few years. In this study, the major DL concepts pertinent to remote-sensing are introduced, and more than 200 publications in this field, most of which were published during the last two years, are reviewed and analyzed. Initially, a meta-analysis was conducted to analyze the status of remote sensing DL studies in terms of the study targets, DL model(s) used, image spatial resolution(s), type of study area, and level of classification accuracy achieved...

38

### Evaluating the effects off green port policy: case study of Kaohsiung harbor in Taiwan

**Autor:** Ching-Chih Chang, Chih-Min Wang,

**Publicado en:** Transportation Research Part D: Transport and Environment 17 (3):185-189. DOI: 10.1016/j.trd.2011.11.006

**Abstract:** The paper evaluates the effectiveness of strategies designed to reduce these pollutants in port areas, based on a newly developed assessment model to calculate emissions. The case study found that the strategy of reducing the ship's speed to 12 knots is most effective in cutting fuel consumption and costs, as well as emissions. Adopting an onshore power supply system could reduce CO<sub>2</sub> emission by 57.16% and PM by 39.4%. By adopting the strategies of both reduced speed and cold ironing emissions control, a reduction in emissions of 71% to 91% can be achieved

with a 20 nautical mile reduced speed zone...

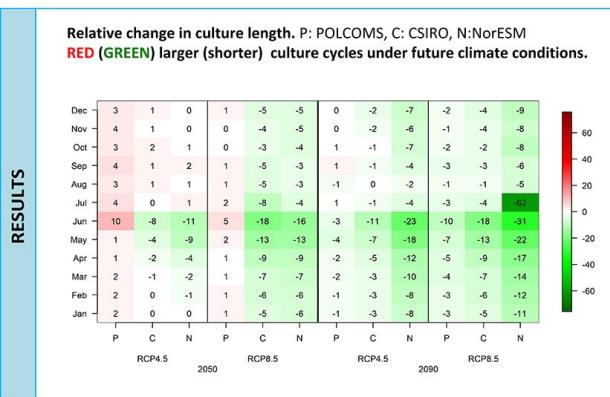
39

## Modelling the impact of climate change on mussel aquaculture in a coastal upwelling system: a critical assessment

**Autor:** Isabel Fuentes-Santos, Uxío Labarta, et al.,

**Publicado en:** Science of The Total Environment 775:145020. DOI: 10.1016/j.scitotenv.2021.145020

**Abstract:** Forecasting of climate change impacts on marine aquaculture production has become a major research task, which requires taking into account the biases and uncertainties arising from ocean climate models in coastal areas, as well as considering culture management strategies. Focusing on the suspended mussel culture in the NW Iberian coastal upwelling system, we simulated current and future mussel growth by means of a multistructural net production Dynamic Energy Budget (DEB) model...



40

## Forecasting for intended consequences

**Autor:** Tina Mozelewski, Robert M. Scheller,

**Publicado en:** Conservation Science and Practice 3(4). DOI: 10.1111/csp2.370

**Abstract:** Restoration and conservation innovations face numerous challenges that often limit widespread adoption, including uncertainty of outcomes, risk averse or status quo biased management, and unknown tradeoffs. These barriers often result in cautious conservation that does not consider the true cost of impeding innovation, and overemphasizes the risks of unintended consequences versus the opportunities presented by proactive and innovative conservation, the intended consequences...

41

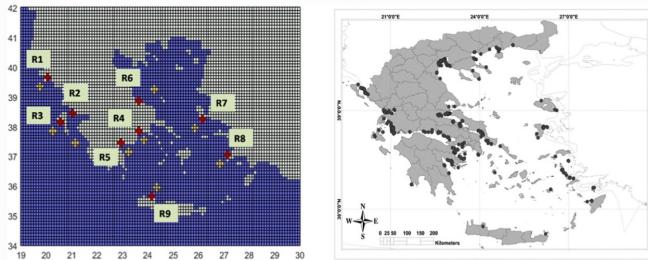
## Projecting climate change impacts on Mediterranean finfish production: a case study in Greece

**Autor:** Orestis Stavrakidis-Zachou, Konstantia Lika, Panagiotis Anastasiadis, Nikos Papandroulakis,

**Publicado en:** Climatic Change 165(3-4). DOI: 10.1007/s10584-021-03096-y

**Abstract:** Finfish aquaculture in the Mediterranean Sea faces increasing challenges due to climate change, while potential adaptation requires a robust assessment of the arising threats and opportunities. This paper presents an approach developed to investigate effects of climate drivers on Greek aquaculture, a representative Mediterranean country with a leading role in the sector. Using a farm level approach, dynamic energy budget models for European seabass and meagre were developed, and environmen-

tal forcing was used to simulate changes in production and farm profitability under IPCC scenarios RCP45 and RCP85...



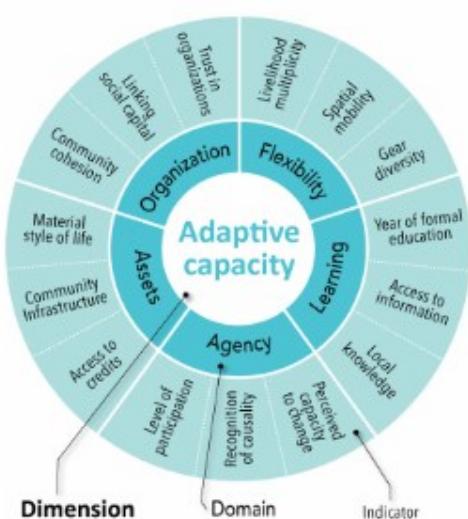
## 42 Herability assessments for man-aging social-ecological systems

**Autor:** Lauric Thiault, Stacy Jupiter, Johanna E. Johnson, et al.

**Publicado en:** Ecology and Society 26(2).

DOI: 10.5751/ES-12167-260201

**Abstract:** The concept of vulnerability has broadened from initial applications in the fields of risk and hazards, human ecology and resilience to include the management of social-ecological systems (SES). We review how this concept has been operationalized in various contexts and identify opportunities and challenges to apply vulnerability assessments to SES management in the face of social, environmental, and cli-



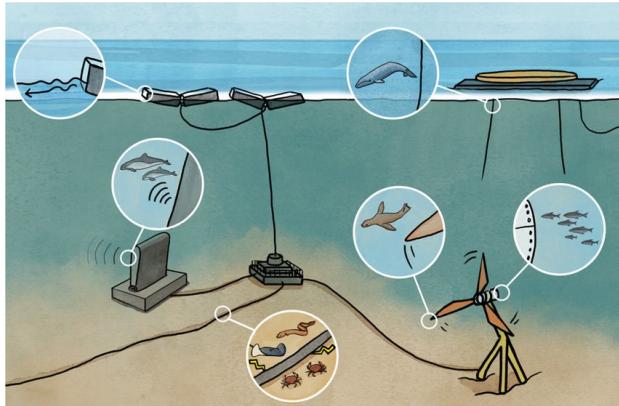
matic changes. We synthesize these lessons into a 12-step framework to help practitioners scope, design, operationalize, and implement vulnerability assessments that can effectively minimize exposure, reduce sensitivity, and enhance adaptive capacity...

# Potential environmental effects of marine renewable energy de- velopment – the estate of the science

**Autor:** Andrea E. Copping, Lenaig G He-mery, Dorian Overhus, et al.,

**Publicado en:** Journal of Marine Science and Engineering 8(11). DOI: 10.3390/jmse8110879

**Abstract:** Marine renewable energy (MRE) harnesses energy from the ocean and pro-



vides a low-carbon sustainable energy source for national grids and remote uses. The international MRE industry is in the early stages of development, focused largely on tidal and riverine turbines, and wave energy converters (WECs), to harness energy from tides, rivers, and waves, respectively. Although MRE supports climate change mitigation, there are concerns that MRE devices and systems could affect portions of the marine and river environments...

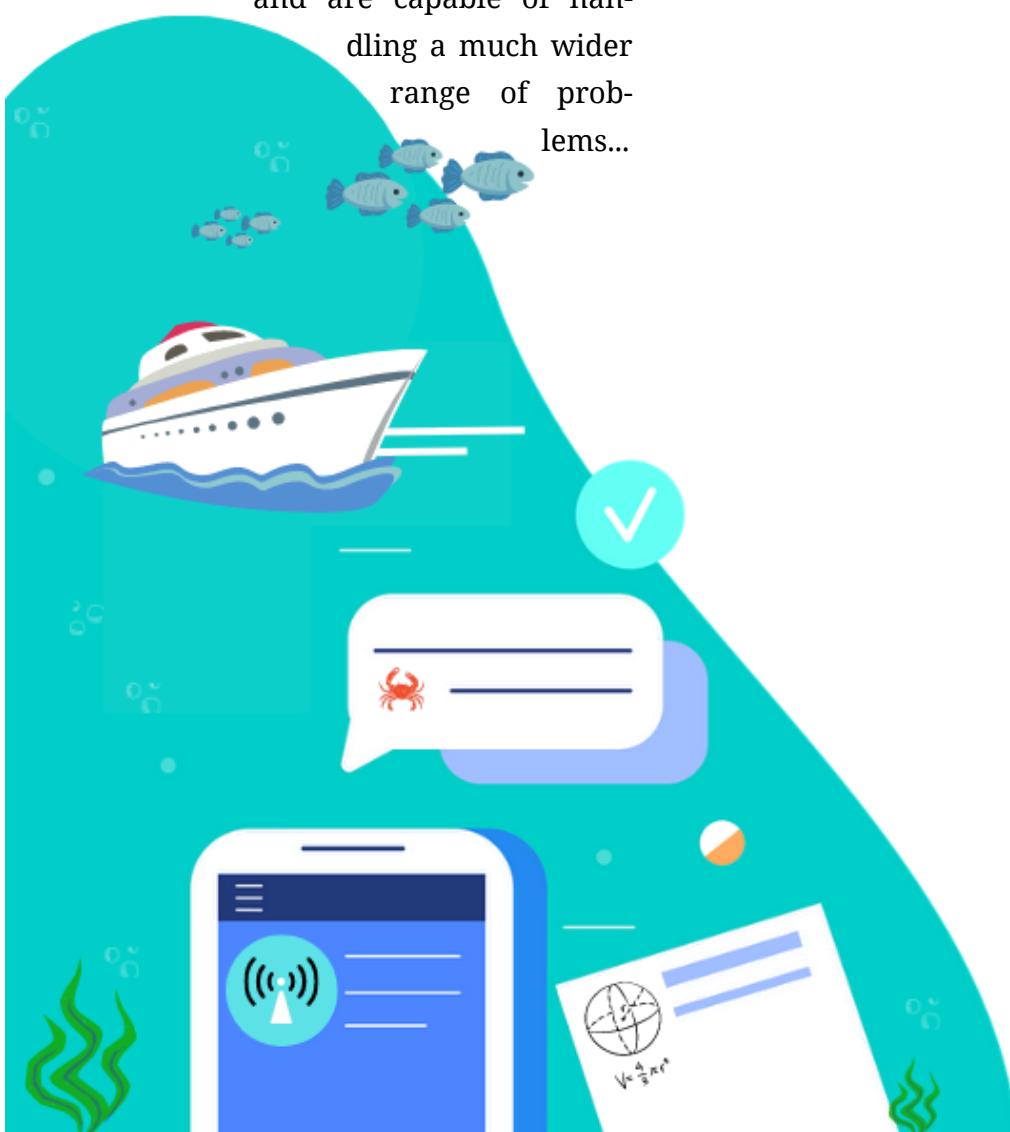
## 44 Time series analysis by state space methods

**Autor:** James Durbin, Siem Jan Koopman,

**Publicado en:** DOI: 10.1093/  
acprof:oso/9780199641178.001.0001

**Abstract:** This new edition updates Durbin & Koopman's important text on the state space approach to time series analysis. The distinguishing feature of state space time series models is that observations are regarded as made up of distinct components such as trend, seasonal, regression elements and disturbance terms, each of which is modelled separately. The techniques that emerge from this approach are very flexible

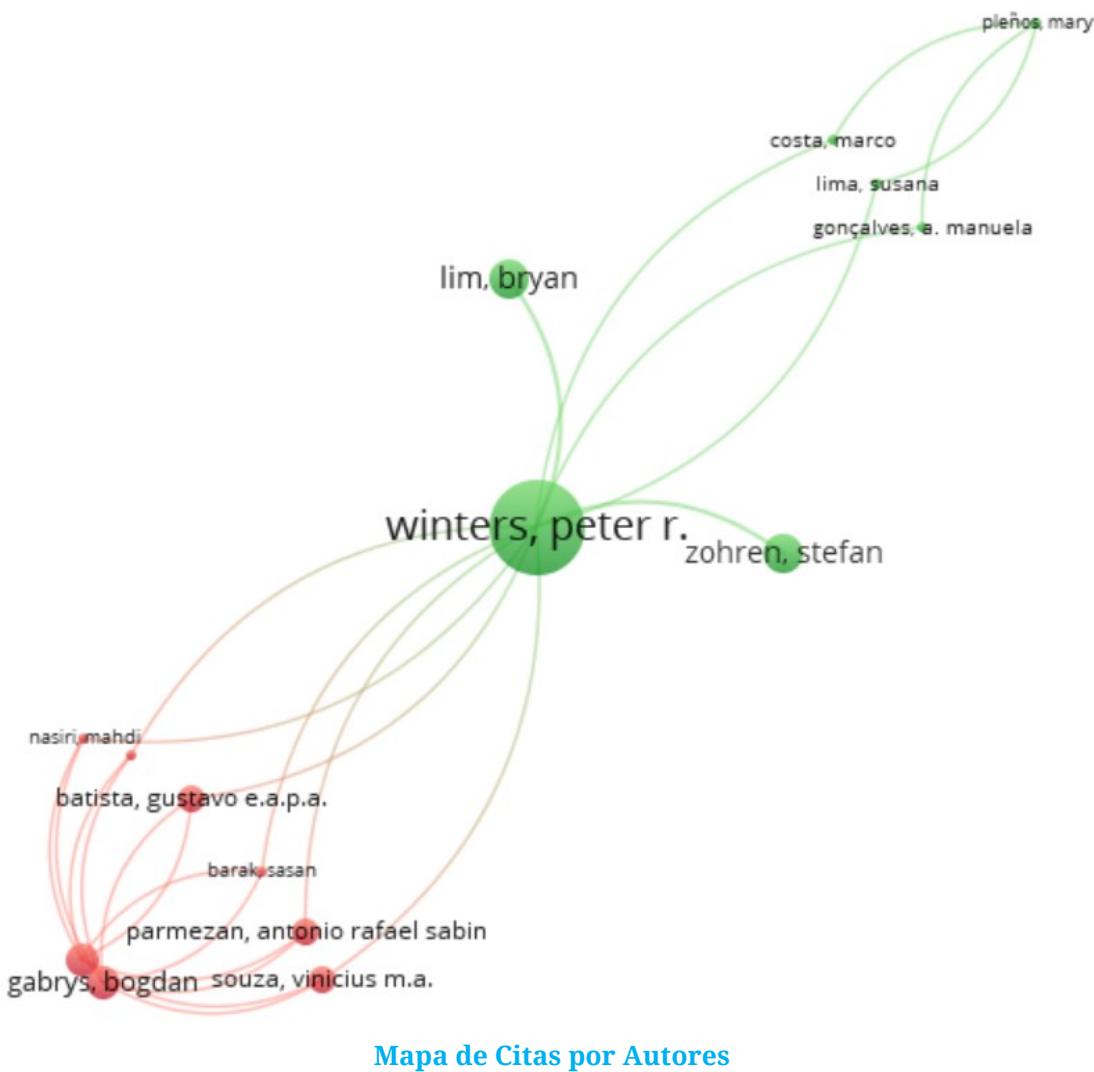
and are capable of handling a much wider range of problems...



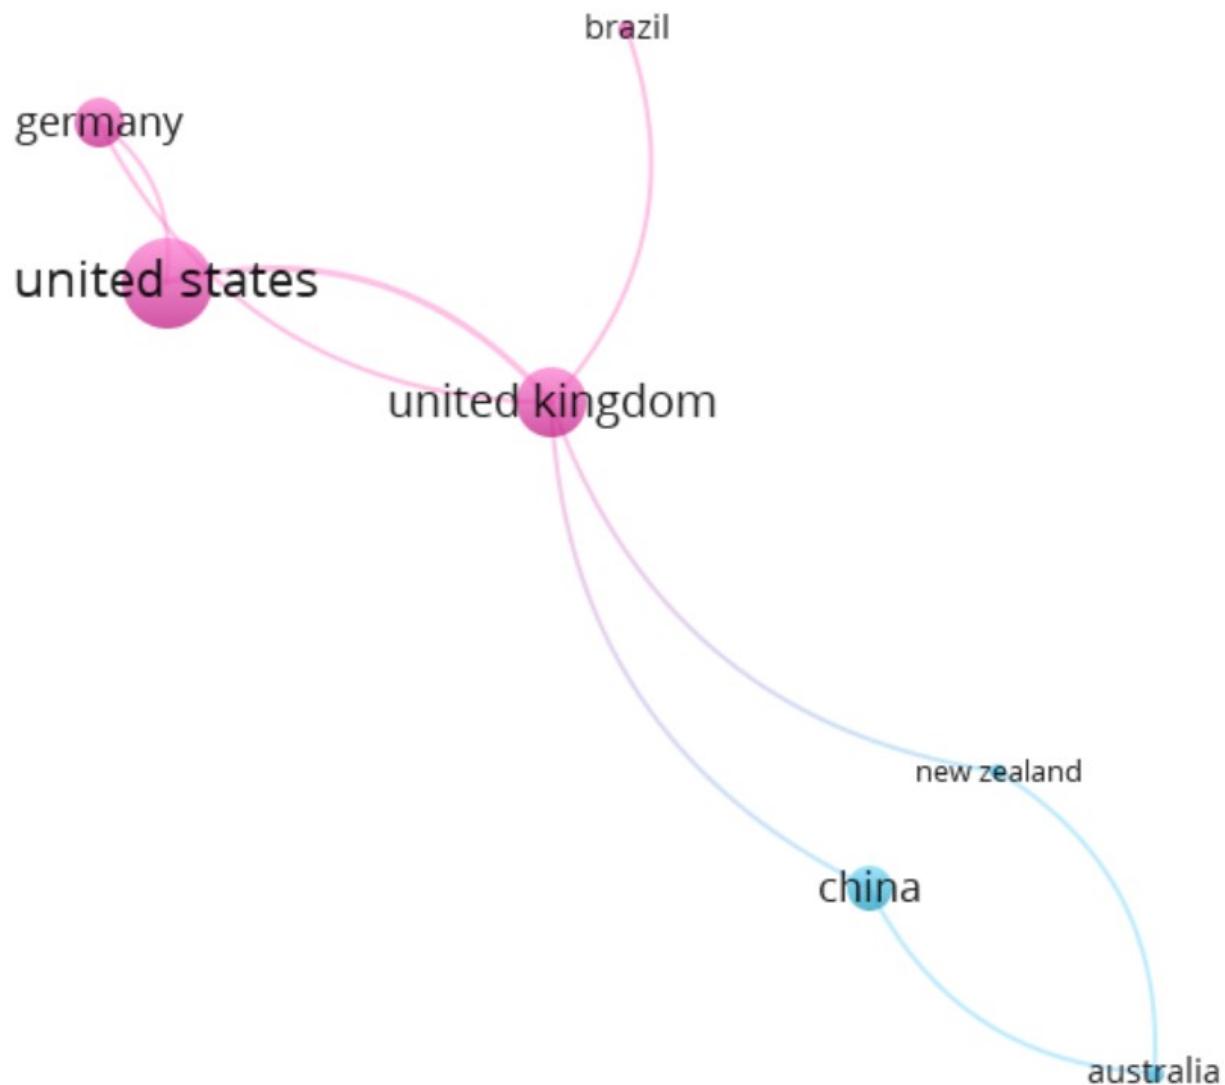
## 5.1.1. Análisis de tendencias en la literatura

Para el análisis de tendencias de la literatura relacionada con el estudio de series temporales en el medio marino, se han analizado los 44 artículos propuestos en el apartado anterior, para conocer las relaciones entre ellos según las relaciones entre sus autores, país o la entidad a la que pertenecen. En el siguiente mapa, cada nodo representa a un autor y los enlaces indican las relaciones entre unos y otros. El color de cada uno de los autores determina el clúster al que pertenece. Por otro lado, la distancia entre dos autores marca su relación en función de las citas. En general, cuanto más

cerca están, mayor es su relación. A continuación, haremos un análisis de los principales clústeres. El **primer clúster** (color verde) está formado por los autores (ordenados por el número de citas): Winters, Peter R.; Lim, Bryan; Zohren, Stefan; Costa, Marco; Gonçalves, A. Manuela; Lima, Susana; Pleños, Mary. El **segundo clúster** (color rojo) está formado por los autores (ordenados por el número de citas): Gabrys, Bogdan; Lemke, Christiane; Batista, Gustavo E.A.P.A.; Parmezan, Antonio Rafael Sabino; Souza, Vinicius M.A.; Barak, Sasan; Nasiri, Mahdi; Rostamzadeh, Mehrdad.

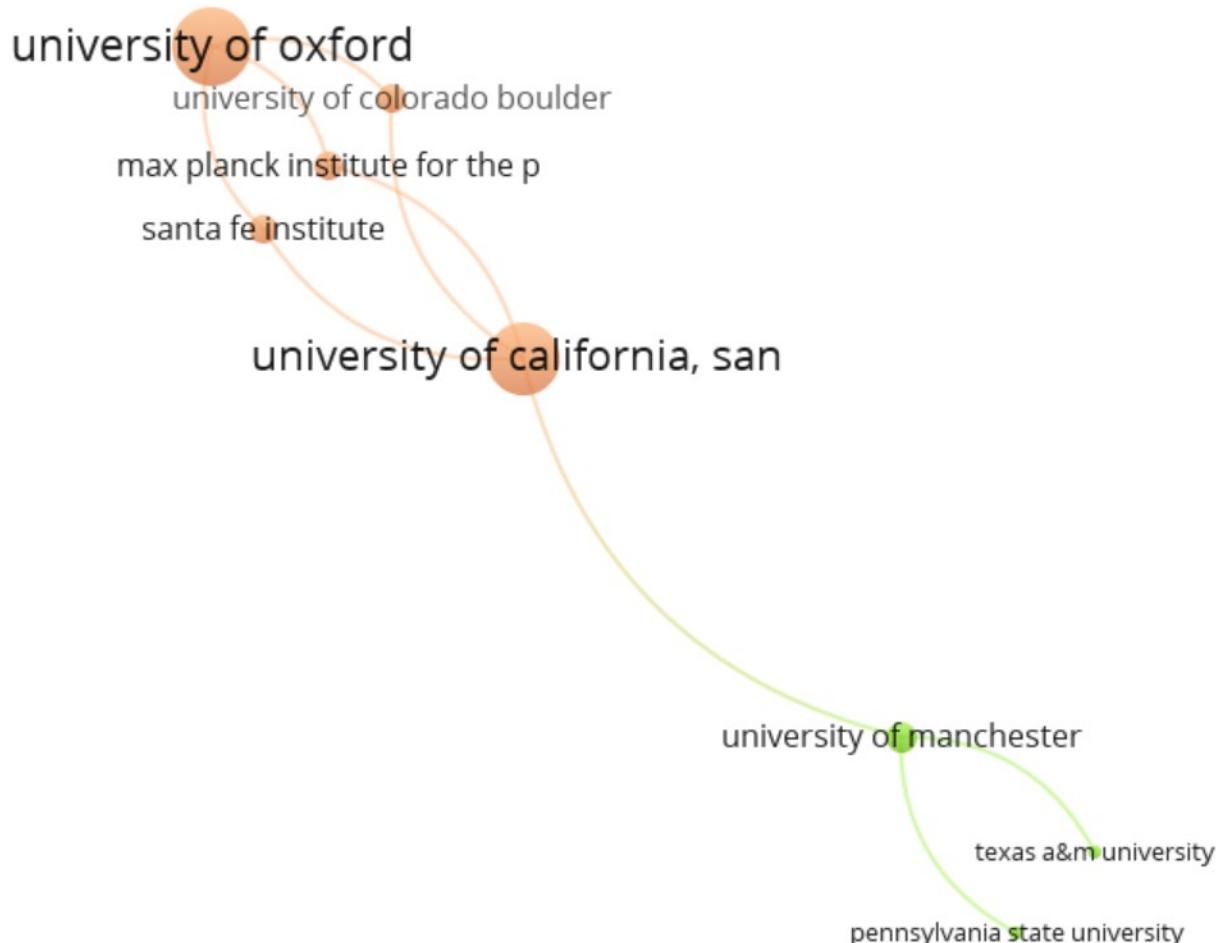


En los siguientes gráficos se muestra la relación por entidades y países de los documentos analizados en el apartado 5.1 Literatura científica.



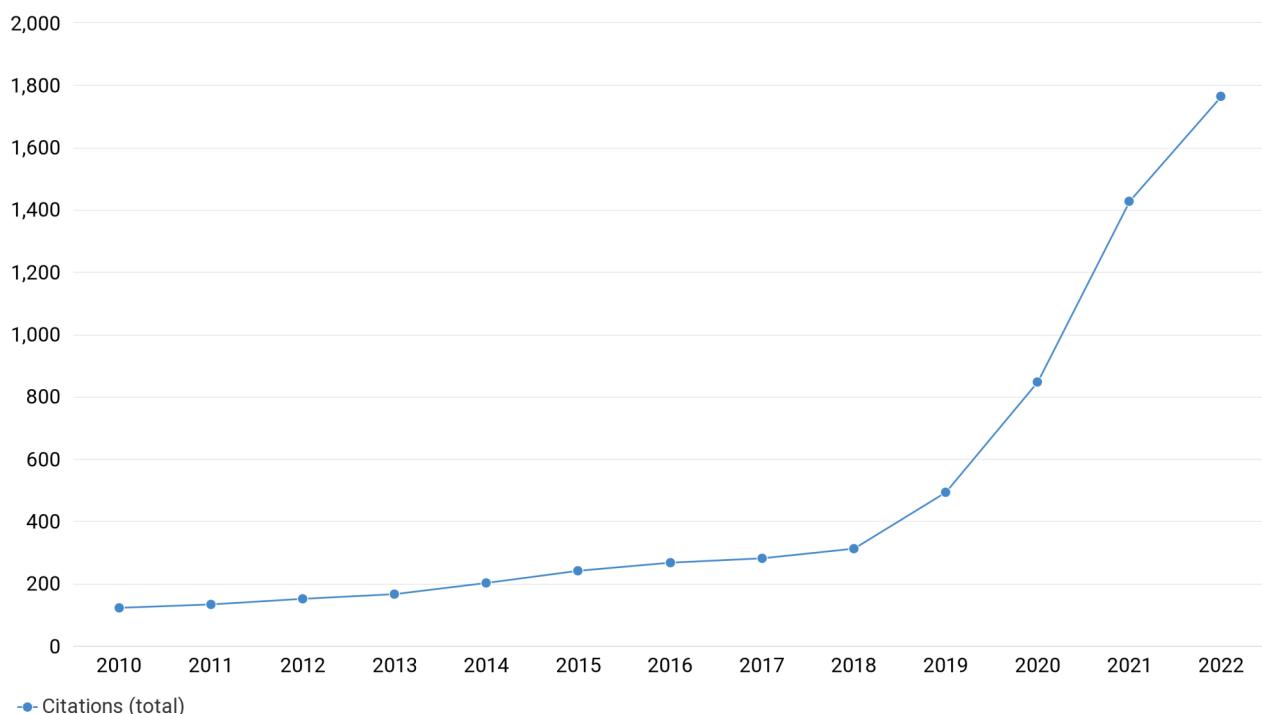
Mapa de citas por países



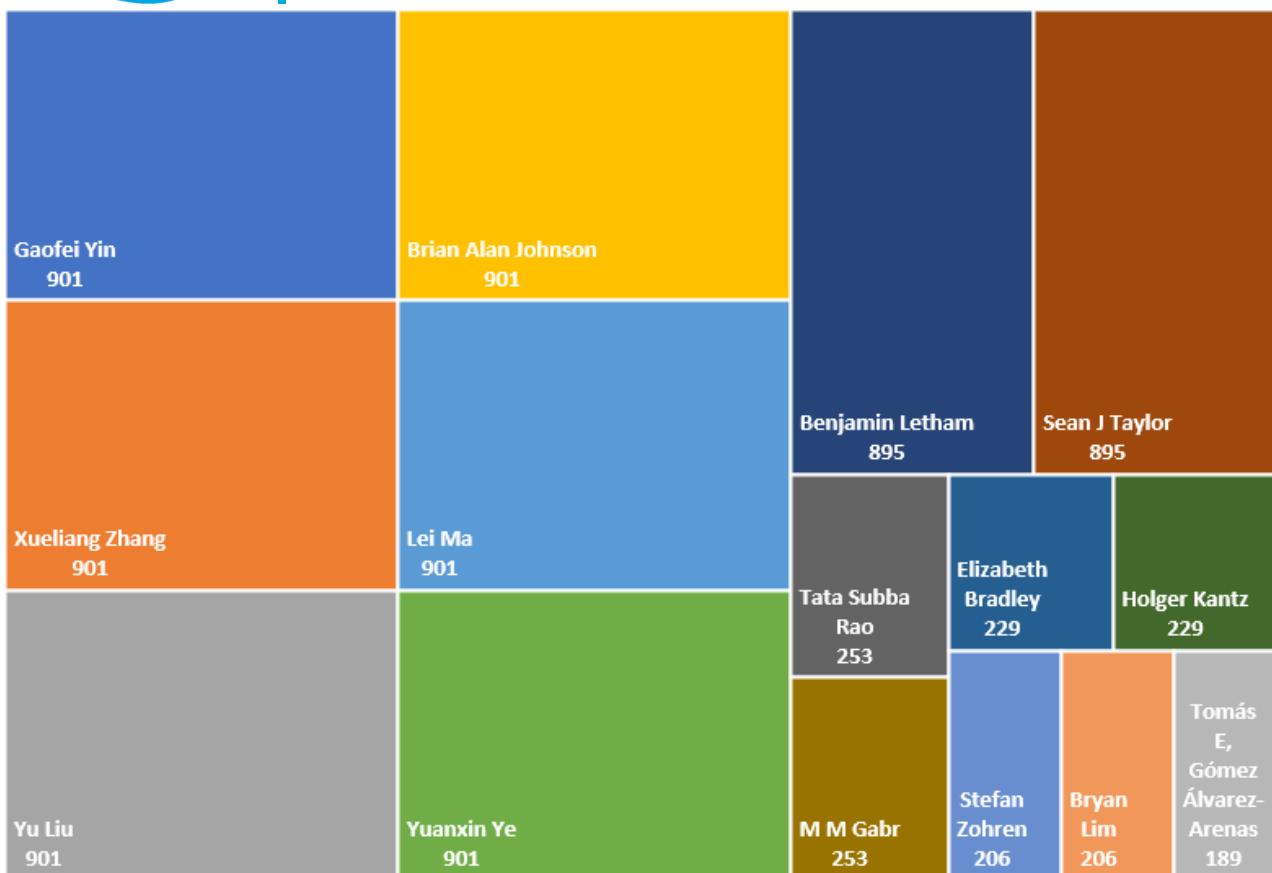


**Mapa de citas por entidades**

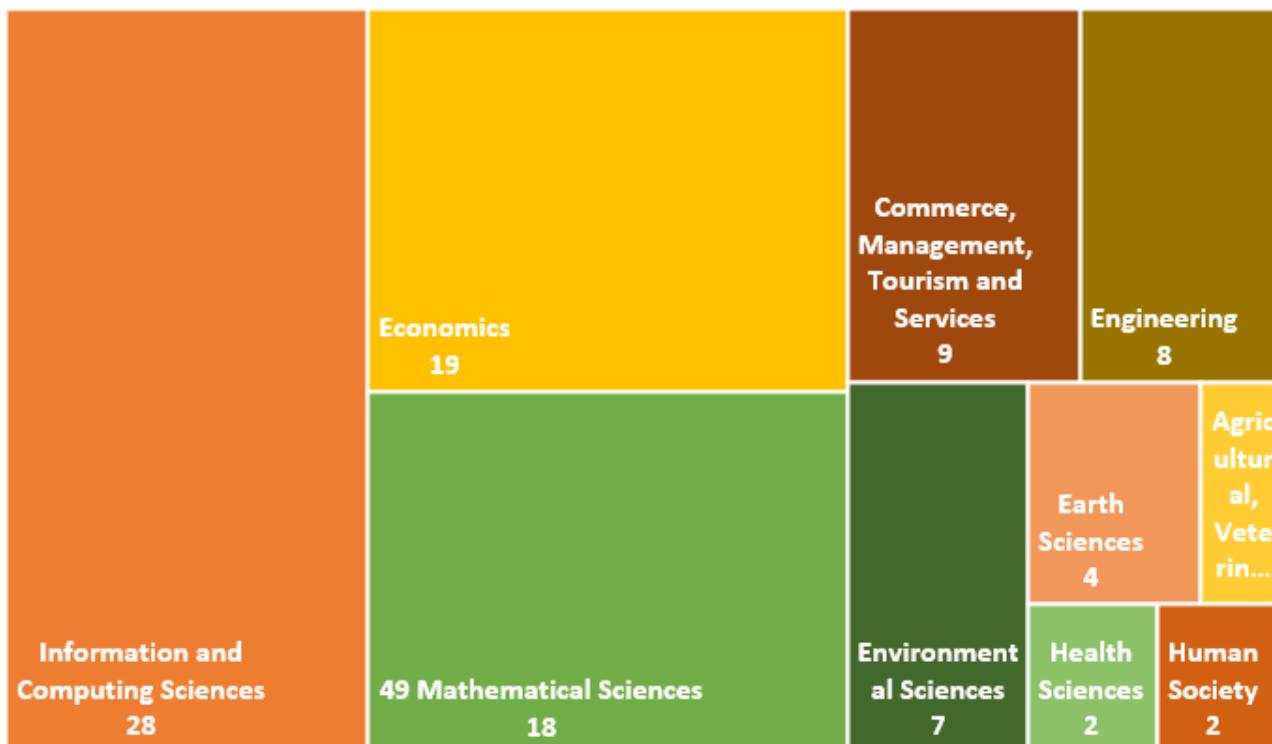
El siguiente gráfico muestra la evolución de citas en los últimos años del corpus documental analizado.



**Evolución cronológica de las citas**



Autores más citados



Publicaciones por temática

## 5.2. Proyectos

01

### Tropical and south Atlantic climate-based marine ecosystem predictions for sustainable management

**Acrónimo:** TRIATLAS

**Financiado por:** H2020-EU 3.2

**Periodo de financiación:** 2019-2023

[+ INFO](#)

**Resumen:** Human activities such as intense fishing and coastal development are altering the Atlantic marine ecosystems around the South and Tropical Atlantic. The EU-funded TRIATLAS project aims to study the current situation of the Atlantic Ocean's marine ecosystem and predict future changes. A range of African, European, and South American institutions specialised in climate change, oceanography and social sciences, as well as local stakeholders will be engaged in the project. TRIATLAS will also work closely with relevant European Commission services...

02

### Climate and marine-ecosystem predictions in the Angola-Benguela upwelling system

**Acrónimo:** BENGUP

**Financiado por:** H2020-EU 1.3

**Periodo de financiación:** 2021-2023

[+ INFO](#)

**Resumen:** Benguela Niño is an extreme

event consisting of muddy warm, nutrient-poor water that occasionally enters the Angola-Benguela Upwelling System off the south-west African coast affecting the rich marine ecosystem and the local economy. There is an urgent need for a reliable predictability system. Recent studies revealed the potential of prediction of these events. The EU-funded BENGUP project will develop the first climate-based marine ecosystem predictions in the region...

03

### Improving models for marine environment services

**Acrónimo:** IMERSE

**Financiado por:** H2020-EU 2.1.6

**Periodo de financiación:** 2018-2023

[+ INFO](#)

**Resumen:** The Copernicus Marine Environment Monitoring Service (CMEMS) provides oceanographic services addressing the increasing and evolving demands for marine monitoring and prediction. The EU-funded IMMERSE project will ensure CMEMS' continuing access to world-class marine modelling tools for its next-generation systems. The project will develop new capabilities in producing ocean forecasts and analyses. It will also exploit high-resolution satellite datasets and deliver ocean analyses and forecasts with a higher spatial resolution...

04

### Shaping ecosystem based fisheries management

Acrónimo: SEAwise

Financiado por: H2020-EU 3.2

Periodo de financiación: 2021-2025

[+ INFO](#)

**Resumen:** The EU-funded SEAwise project will address the need to increase benefits to fisheries while reducing ecosystem impacts under environmental change and increasing competition for space. The network of stakeholders, advisory bodies and scientists will improve stock productivity predictions using environmental metrics, density dependence, predation, stock health indicators and habitat extent. In addition, multispecies-multifleet models will provide ecosystem forecasts of the effect of fisheries management measures...

## 05 Guide data-driven safety at sea

Acrónimo: SEFEWAVE

Financiado por: H2020-EU 2.3

Periodo de financiación: 2019-2019

[+ INFO](#)

**Resumen:** EU-funded SAFEWAVE helps to ensure that boats are operated in a safe and efficient operational envelope. The solution uses intelligent proprietary methods to generate real-time speed guidance optimised for safety, impact reduction, comfort, fuel efficiency and reduction of carbon emissions. The system automatically varies its guidance to reflect prevailing conditions, actual speed and vessel motions. The solution helps ensure duty of care, reduce human errors...

## 06 Aquaculture smart and open data analytics as a service

Acrónimo: AquaSmart

Financiado por: H2020-EU.2.1.1

Periodo de financiación: 2015-2017

[+ INFO](#)

**Resumen:** AQUASMART's objective is to enhance innovation capacity to the aquaculture sector, by addressing the problem of global knowledge access and data exchanges between aquaculture companies and its related stakeholders. Offering aquaculture production companies the tools to access and share global open data and strong data analytics in a multi-lingual, multi-sector and cross-border setting strengthens their competitiveness and growth potential...

## 07 Aquaculture infrastructures for excellence in European fish research towards 2020

Acrónimo: AQUAEXCEL2020

Financiado por: H2020-EU.2.4.

Periodo de financiación: 2015–2020.

[+ INFO](#)

**Resumen:** AQUAEXCEL2020 aims to integrate top class European aquaculture research facilities of very diverse nature, covering all relevant scientific fields for research and innovation in aquaculture, from genetics to technology through pathology, physiology and nutrition. It will put in place a user-friendly one-stop access to high-quality services and resources from

39 installations covering both established and new aquaculture species, all types of experimental systems as well as sequencing facilities.

**08**

**Connecting the dots to unleash the innovation potential for digital transformation of the European agri-food sector**

**Acrónimo:** SmartAgriHubs

**Financiado por:** H2020-EU.3.2.

**Periodo de financiación:** 2018–2022

[+ INFO](#)

**Resumen:** The digital transformation of the European agri-food sector will guarantee maximum return on investment and deliver sufficient and safe food. The EU funded SmartAgriHubs project will create a network of digital innovation hubs (DIHs) to boost the adoption of digital solutions by the sector by consolidating, activating and extending the existing ecosystem...

**09**

**Developing innovative market orientated prediction toolbox to strengthen the economic sustainability and competitiveness of European seafood on local and global markets**

**Acrónimo:** PrimeFish

**Financiado por:** H2020-EU.3.2.

**Periodo de financiación:** 2015–2019

[+ INFO](#)

**Resumen:** The overall aim of PrimeFish is to improve the economic sustainability of

European fisheries and aquaculture sectors. PrimeFish will gather data from individual production companies, industry and sales organisations, consumers and public sources. The data will be related to the competitiveness and economic performance of companies in the sector; this includes data on price development, supply chain relations, markets, consumer behaviour and successful product innovation...

**10**

**Co-creating a decision support framework to ensure sustainable fish production in Europe under climate change**

**Acrónimo:** ClimeFish

**Financiado por:** H2020-EU.3.2.

**Periodo de financiación:** 2016–2020

[+ INFO](#)

**Resumen:** The overall goal of ClimeFish is to help ensure that the increase in seafood production comes in areas and for species where there is a potential for sustainable growth, given the expected developments in climate, thus contributing to robust employment and sustainable development of rural and coastal communities. The underlying biological models are based on single species distribution and production, as well as multispecies interactions...

**11**

**Comercial service platform for user-relevant coastal water monitoring services based on Earth observation**

**Acrónimo:** CoastObs

Financiado por: H2020-EU 2.1.6

Periodo de financiación: 2017–2021

+ INFO

**Resumen:** Coastal zones are very productive areas, offering many valuable habitats and ecosystems services and attracting human settlements and activities. The intensive concentration of population and excessive exploitation of natural resources puts high pressure on coastal ecosystems leading to biodiversity loss, habitat destruction, pollution as well as conflicts between potential uses and space competition...

12

### Sub-seasonal to seasonal climate forecasting for energy

Acrónimo: S2S4E

Financiado por: H2020-EU.3.5

Periodo de financiación: 2017–2020

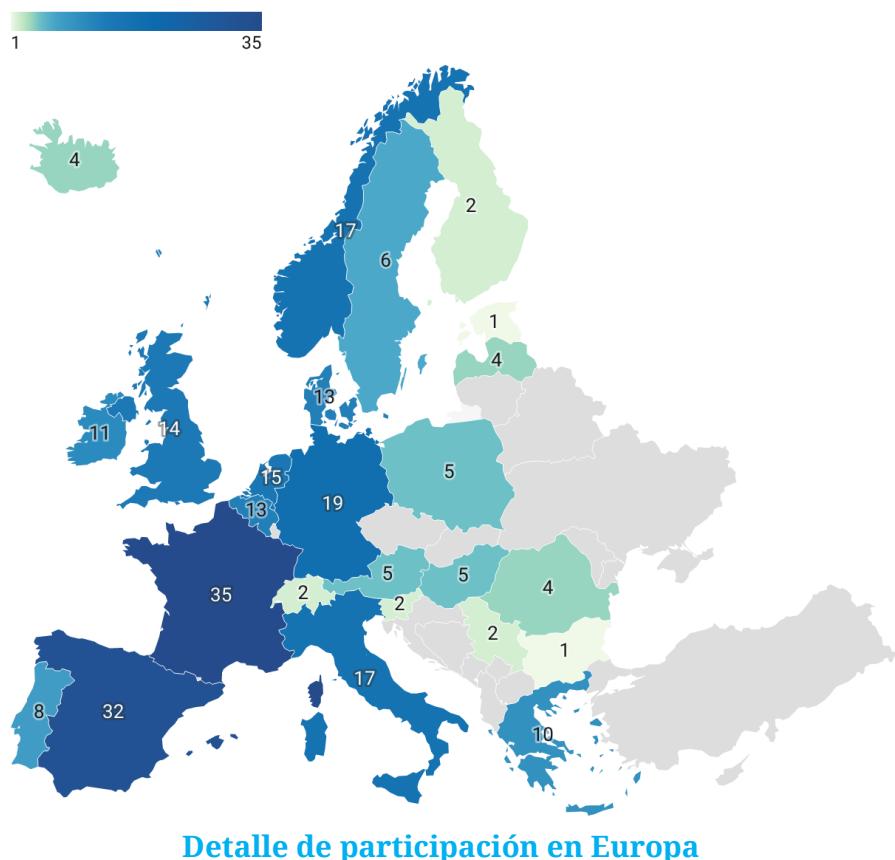
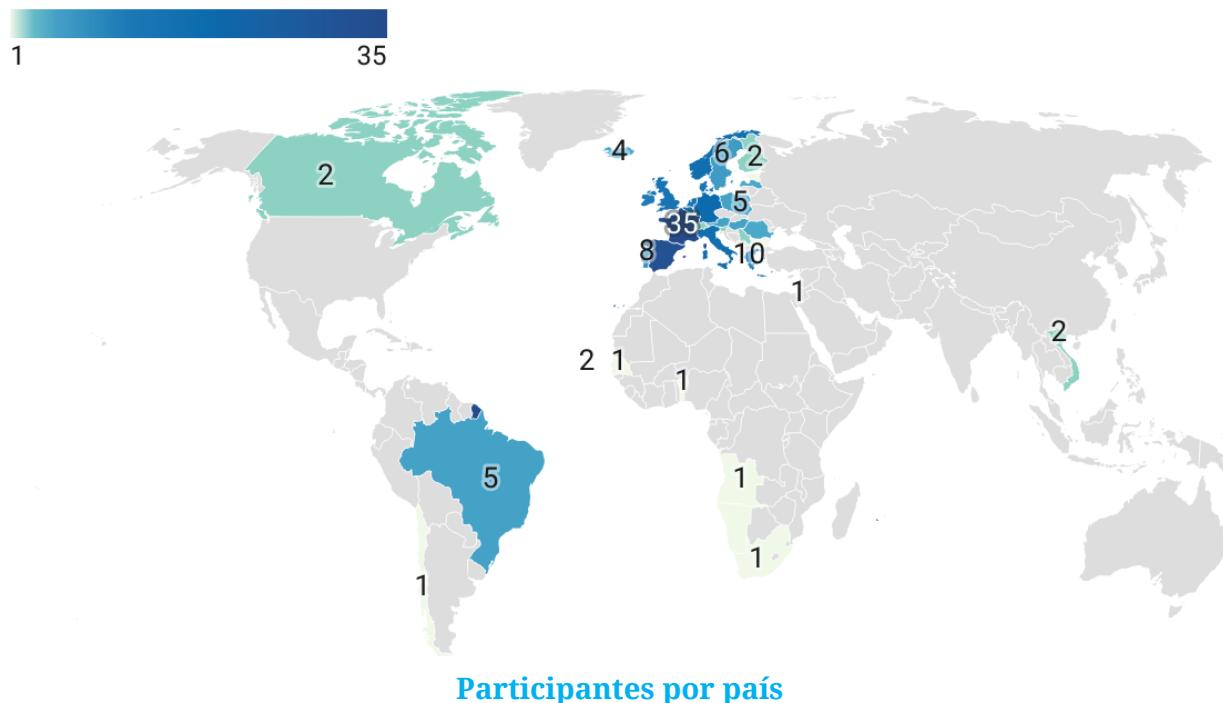
+ INFO

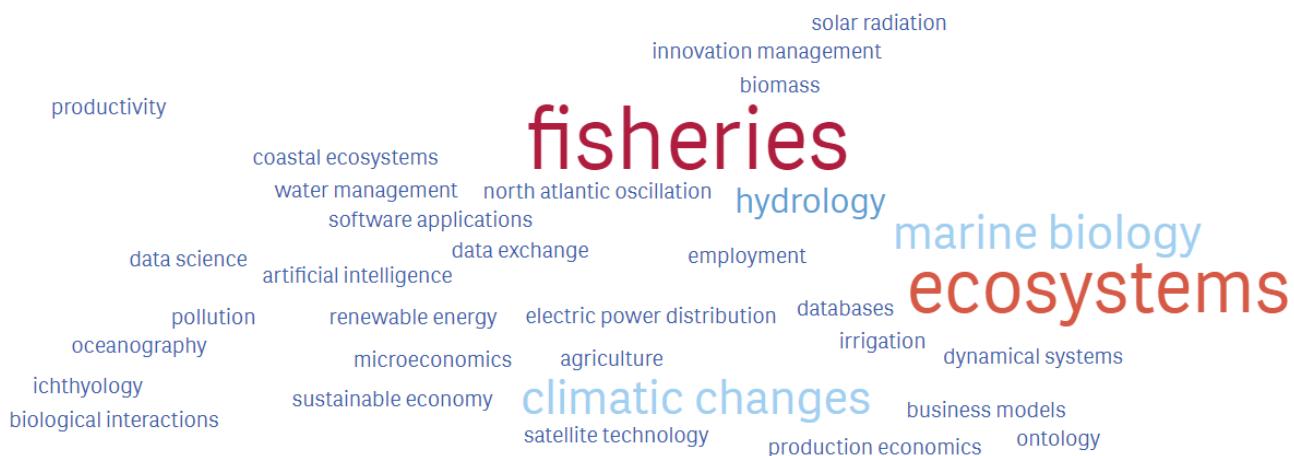
**Resumen:** Large scale deployment of renewable energy (RE) is key to comply with the GHG emissions reduction set by the COP21 agreement. Despite cost competitive in many settings, RE diffusion remains limited largely due to its variability. This works as a major barrier to RE's integration in electricity networks as knowledge of power output and demand forecasting beyond a few days remains poor. To help solve this problem, S2S4E will offer an innovative service to improve RE variability management by developing...

### 5.2.1. Análisis de la financiación europea

Los proyectos descritos están financiados por Horizonte 2020. El presupuesto total de este programa es de 67,93B€, para estos proyectos concretamente se destinan

68.459M€. En estos proyectos participan 273 organismos de los 175.986 intervenidos en total.





### Nube de temas de los proyectos

## 6. Bibliografía

- [1] Amir Ghaderi, Borhan M. Sanandaji, and Faezeh Ghaderi, 'Deep Forecast: Deep Learning-Based Spatio-Temporal Forecasting', ii, 2017.
- [2] Andrea E. Copping and others, 'Potential Environmental Effects of Marine Renewable Energy Development—The State of the Science', Journal of Marine Science and Engineering 2020, Vol. 8, Page 879, 8.11 (2020), 879 <<https://doi.org/10.3390/JMSE8110879>>
- [3] Andrej Abramic and others, 'Maritime Spatial Planning Supported by Infrastructure for Spatial Information in Europe (INSPIRE)', Ocean & Coastal Management, 152 (2018), 23–36 <<https://doi.org/10.1016/J.OCECOAMAN.2017.11.007>>
- [4] Antonio Rafael Sabino Parmezan, Vinicius M.A. Souza, and Gustavo E.A.P.A. Batista, 'Evaluation of Statistical and Machine Learning Models for Time Series Prediction: Identifying the State-of-the-Art and the Best Conditions for the Use of Each Model', Information Sciences, 484 (2019), 302–37 <<https://doi.org/10.1016/j.ins.2019.01.076>>
- [5] Arthur Berg, Timothy McMurry, and Dimitris N. Politis, 'Testing Time Series Linearity. Traditional and Bootstrap Methods', Handbook of Statistics, 30 (2012), 27–42 <<https://doi.org/10.1016/B978-0-444-53858-1.00002-8>>
- [6] A. Teruzzi and others, 'Parallel Implementation of a Data Assimilation Scheme for Operational Oceanography: The Case of the MedBFM Model System', Computers & Geosciences, 124 (2019), 103–14 <<https://doi.org/10.1016/J.CAGEO.2019.01.003>>

- [7] Changqing Cheng and others, 'Time Series Forecasting for Nonlinear and Non-Stationary Processes: A Review and Comparative Study', *IIE Transactions* (Institute of Industrial Engineers), 47.10 (2015), 1053–71 <<https://doi.org/10.1080/0740817X.2014.999180>>
- [8] Ching Chih Chang and Chih Min Wang, 'Evaluating the Effects of Green Port Policy: Case Study of Kaohsiung Harbor in Taiwan', *Transportation Research Part D: Transport and Environment*, 17.3 (2012), 185–89 <<https://doi.org/10.1016/j.trd.2011.11.006>>
- [9] Christiane Lemke and Bogdan Gabrys, 'Meta-Learning for Time Series Forecasting and Forecast Combination', *Neurocomputing*, 73.10–12 (2010), 2006–16 <<https://doi.org/10.1016/j.neucom.2009.09.020>>
- [10] Christos Faloutsos and others, 'Forecasting Big Time Series: Old and New', *Proceedings of the VLDB Endowment*, 11.12 (2018), 2102–5 <<https://doi.org/10.14778/3229863.3229878>>
- [11] David Reinsel, John Gantz, and John Rydning, 'The Digitization of the World - From Edge to Core', Framingham: International Data Corporation, November, 2018, US44413318
- [12] Denis Kwiatkowski and others, 'Testing the Null Hypothesis of Stationarity against the Alternative of a Unit Root. How Sure Are We That Economic Time Series Have a Unit Root?', *Journal of Econometrics*, 54.1–3 (1992), 159–78 <[https://doi.org/10.1016/0304-4076\(92\)90104-Y](https://doi.org/10.1016/0304-4076(92)90104-Y)>
- [13] Dongmei Huang and others, 'Modeling and Analysis in Marine Big Data: Advances and Challenges', *Mathematical Problems in Engineering*, 2015 (2015) <<https://doi.org/10.1155/2015/384742>>
- [14] Elizabeth Bradley and Holger Kantz, 'Nonlinear Time-Series Analysis Revisited', *Chaos*, 25.9 (2015) <<https://doi.org/10.1063/1.4917289>>
- [15] Federico Amato and others, 'A Novel Framework for Spatio-Temporal Prediction of Environmental Data Using Deep Learning', *Scientific Reports*, 10.1 (2020), 1–11 <<https://doi.org/10.1038/s41598-020-79148-7>>
- [16] Gautam, R., & Sharma, M. (2020). Prevalence and diagnosis of neurological disorders using different deep learning techniques: a meta-analysis. *Journal of medical systems*, 44(2), 1-24
- [17] George E.P. Box and Gwylim M. Jenkins, *Time Series Analysis: Forecasting and Control*, 1st edn, 1970
- [18] George Sugihara and Robert M. May, 'Nonlinear Forecasting as a Way of Distinguishing Chaos from Measurement Error in Time Series', *Nature*, 344.6268

- [19] Guoqiang Peter Zhang, 'An Investigation of Neural Networks for Linear Time-Series Forecasting', *Computers and Operations Research*, 28.12 (2001), 1183–1202 <[https://doi.org/10.1016/S0305-0548\(00\)00033-2](https://doi.org/10.1016/S0305-0548(00)00033-2)>
- [20] Isabel Fuentes-Santos and others, 'Modeling the Impact of Climate Change on Mussel Aquaculture in a Coastal Upwelling System: A Critical Assessment', *Science of The Total Environment*, 775 (2021), 145020 <<https://doi.org/10.1016/J.SCITOTENV.2021.145020>>
- [21] Islam, M. M., Nasrin, T., Walther, B. A., Wu, C. C., Yang, H. C., & Li, Y. C. (2019). Prediction of sepsis patients using machine learning approach: a meta-analysis. *Computer methods and programs in biomedicine*, 170, 1-9
- [22] James Durbin and Siem Jan Koopman, 'Time Series Analysis by State Space Methods', *Time Series Analysis by State Space Methods*, 2013 <<https://doi.org/10.1093/acprof:oso/9780199641178.001.0001>>
- [23] Jan-Bart Calewaert and others, 'The European Marine Data and Observation Network (EMODnet): Your Gateway to European Marine and Coastal Data', 2016, 31–46 <[https://doi.org/10.1007/978-3-319-32107-3\\_4](https://doi.org/10.1007/978-3-319-32107-3_4)>
- [24] J.G. De Gooijer, Elements of Nonlinear Time Series Analysis and Forecasting, 1st edn (Springer, 2017)
- [25] Judi E. Hewitt and Simon F. Thrush, 'Monitoring for Tipping Points in the Marine Environment', *Journal of Environmental Management*, 234 (2019), 131–37 <<https://doi.org/10.1016/J.JENVMAN.2018.12.092>>
- [26] Ketil Malde and others, 'Machine Intelligence and the Data-Driven Future of Marine Science', *ICES Journal of Marine Science*, 77.4 (2020), 1274–85 <<https://doi.org/10.1093/icesjms/fsz057>>
- [27] Krittawong, C., Virk, H. U. H., Bangalore, S., Wang, Z., Johnson, K. W., Pinotti, R., ... & Tang, W. W. (2020). Machine learning prediction in cardiovascular diseases: a meta-analysis. *Scientific reports*, 10(1), 1-11
- [28] L.Thiault and others, 'Harnessing the Potential of Vulnerability Assessments for Managing Social-Ecological Systems', *Ecology and Society*, Published Online: Apr 14, 2021 | Doi:10.5751/ES-12167-260201, 26.2 (2021) <<https://doi.org/10.5751/ES-12167-260201>>
- [29] Ma, L., Liu, Y., Zhang, X., Ye, Y., Yin, G., & Johnson, B. A. (2019). Deep learning in remote sensing applications: A meta-analysis and review. *ISPRS journal of photogrammetry and remote sensing*, 152, 166-177
- [30] Maurice Kendall and Herman Wold, 'A Study in the Analysis of Stationary

Time-Series.', Undefined, 117.4 (1954), 484 <<https://doi.org/10.2307/2342687>>

- [31] M. B. Priestley and T. Subba Rao, 'A Test for Non-Stationarity of Time-Series', Journal of the Royal Statistical Society: Series B (Methodological), 31.1 (1969), 140–49 <<https://doi.org/10.1111/J.2517-6161.1969.TB00775.X>>
- [32] Mohammad Jahanbakht and others, 'Internet of Underwater Things and Big Marine Data Analytics - A Comprehensive Survey', IEEE Communications Surveys and Tutorials, 23.2 (2021), 904–56 <<https://doi.org/10.1109/COMST.2021.3053118>>
- [33] Nindrea, R. D., Aryandono, T., Lazuardi, L., & Dwiprahasto, I. (2018). Diagnostic accuracy of different machine learning algorithms for breast cancer risk calculation: a meta-analysis. Asian Pacific journal of cancer prevention: APJCP, 19(7), 1747
- [34] Orestis Stavrakidis-Zachou and others, 'Projecting Climate Change Impacts on Mediterranean Finfish Production: A Case Study in Greece', Climatic Change, 165.3–4 (2021), 1–18 <<https://doi.org/10.1007/S10584-021-03096-Y/FIGURES/5>>
- [35] Pablo Montero-Manso and Rob J. Hyndman, 'Principles and Algorithms for Forecasting Groups of Time Series: Locality and Globality', International Journal of Forecasting, 37.4 (2021), 1632–53 <<https://doi.org/10.1016/j.ijforecast.2021.03.004>>
- [36] Ps Kalekar, 'Time Series Forecasting Using Holt-Winters Exponential Smoothing', Kanwal Rekhi School of Information Technology, 04329008, 2004, 1–13. Kalekar
- [37] Pusheng Zhang and others, 'Correlation Analysis of Spatial Time Series Datasets: A Filter-and-Refine Approach', Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics), 2637 (2003), 519–31 <[https://doi.org/10.1007/3-540-36175-8\\_53](https://doi.org/10.1007/3-540-36175-8_53)>
- [38] Rajat Sen, Hsiang Fu Yu, and Inderjit Dhillon, 'Think Globally, Act Locally: A Deep Neural Network Approach to High-Dimensional Time Series Forecasting', Advances in Neural Information Processing Systems, 32.NeurIPS (2019), 1 –10
- [39] R. Winters, 'Forecasting Sales by Exponentially Weighted Moving Averages', <Http://Dx.Doi.Org/10.1287/Mnsc.6.3.324>, 6.3 (1960), 324–42 <<https://doi.org/10.1287/MNSC.6.3.324>>
- [40] Rob J Hyndman and George Athanasopoulos, Forecasting: Principles and Practice, 3rd edn (OTexts, 2021)

- [41] Sasan Barak, Mahdi Nasiri, and Mehrdad Rostamzadeh, ‘Time Series Model Selection with a Meta-Learning Approach; Evidence from a Pool of Forecasting Algorithms’, CoRR, abs/1908.0 (2019), 1–30
- [42] Satheesh V. Aradhyula and Matthew T. Holt, ‘GARCH Time-Series Models: An Application to Retail Livestock Prices’, Western Journal of Agricultural Economics, 1988, pp. 365–74. Aradhyula and Holt
- [43] Sean J. Taylor and Benjamin Letham, ‘Forecasting at Scale’, American Statistician, 72.1 (2018), 37–45 <<https://doi.org/10.1080/00031305.2017.1380080>>
- [44] Shani, R., Tal, S., Derakshan, N., Cohen, N., Enock, P. M., McNally, R. J., ... & Okon-Singer, H. (2021). Personalized cognitive training: Protocol for individual-level meta-analysis implementing machine learning methods. Journal of psychiatric research, 138, 342-348
- [45] Spyros Makridakis, Evangelos Spiliotis, and Vassilios Assimakopoulos, ‘The M4 Competition: 100,000 Time Series and 61 Forecasting Methods’, International Journal of Forecasting, 36.1 (2020), 54–74 <<https://doi.org/10.1016/j.ijforecast.2019.04.014>>
- [46] Syed, S. A., Rashid, M., & Hussain, S. (2020). Meta-analysis of voice disorders databases and applied machine learning techniques. Mathematical Biosciences and Engineering, 17(6), 7958-7979
- [47] T.E Gomez, ‘Acoustic Impedance Matching of Piezoelectric’, IEEE Transactions on Ultrasonics, Ferroelectrics and Frequency Control, 51.5 (2004), 624–33
- [48] Thomas F Stocker and others, ‘Cambio Climático 2013 Bases Físicas Resumen Para Responsables de Políticas Edición a Cargo De’, 2013 <[www.ipcc.ch](http://www.ipcc.ch)> [accedido por última vez el 17/1/2022]
- [49] Tina G. Mozelewski and Robert M. Scheller, ‘Forecasting for Intended Consequences’, Conservation Science and Practice, 3.4 (2021), e370 <<https://doi.org/10.1111/CSP2.370>>
- [50] T. Subba Rao and M. M. Gabr, ‘A TEST FOR LINEARITY OF STATIONARY TIME SERIES’, Journal of Time Series Analysis, 1.2 (1980), 145–58 <<https://doi.org/10.1111/J.1467-9892.1980.TB00308.X>>
- [51] Werner Kitzinger and others, ‘Digital Twin in Manufacturing: A Categorical Literature Review and Classification’, IFAC-PapersOnLine, 51.11 (2018), 1016–22 <<https://doi.org/10.1016/j.ifacol.2018.08.474>>
- [52] William W.S. Wei, Multivariate Time Series Analysis and Applications, 1st edn (John Wiley & Sons Ltd, 2019)