



**Universidad de Concepción
Dirección de Postgrado
Facultad de Ciencias Naturales y Oceanográficas
Programa de Doctorado en Oceanografía**

**EVALUACIÓN DE CAMBIOS ESPACIALES Y TEMPORALES DE LA
SURGENCIA COSTERA EN LOS PRINCIPALES SISTEMAS DE BORDE
ORIENTAL UTILIZANDO TÉCNICAS DE INTELIGENCIA ARTIFICIAL**

**(Assessment of spatial and temporal changes in coastal upwelling in
major eastern boundary systems using artificial intelligence techniques)**

Tesis presentada en la Facultad de Ciencias Naturales y Oceanográficas de la
Universidad de Concepción para optar al grado de Doctor en Oceanografía

**POR: DAVID FRANCISCO BUSTOS USTA
CONCEPCIÓN-CHILE
2025**

Profesor Guía: Diego Alonso Narváez Rodríguez
Dpto. de Oceanografía, Facultad de Ciencias Naturales y Oceanográficas
Universidad de Concepción

Universidad de Concepción
Dirección de Postgrado

La Tesis de “*Doctorado en Oceanografía*” titulada “*Evaluación de cambios espaciales y temporales de la surgencia costera en los principales sistemas de borde oriental utilizando técnicas de Inteligencia Artificial*”, del Sr. David Bustos Usta y realizada bajo la Facultad de Ciencias Naturales y Oceanográficas, Universidad de Concepción, ha sido aprobada por la siguiente Comisión de Evaluación:

Dr. Diego A Narváez Rodríguez
Profesor Guía
Universidad de Concepción.

Dr. Fabian Tapia
Miembro Comité de Tesis
Universidad de Concepción

Dr. Mabel Vidal
Miembro Comité de Tesis
Universidad de Concepción

Dr. Vera Oerder
Miembro Comité de Tesis
Universidad de Concepción

Dr. Boris Dewitte
Miembro Comité de Tesis
CEAZA

Dr. Luis Bravo
Evaluador Externo
Universidad Católica del Norte

Dra. Pamela Hidalgo
Directora
Programa de Doctorado en Oceanografía
Universidad de Concepción

AGRADECIMIENTOS

Quiero agradecer a mi familia, por brindarme fuerza y motivación incondicional, incluso en la distancia.

A mi profesor guía, Dr. Diego Narváez, por su guía constante. Al Dr. Boris Dewitte, al Dr. Fabian Tapia, Dra. Vera Oerder y la Dra. Mabel Vidal, por su apoyo comprometido durante el desarrollo de esta tesis, siempre con entusiasmo y aliento.

A la Dra. Pamela Hidalgo, por su excepcional labor como directora. A la Sra. Fabiola Gaete, por su orientación siempre oportuna.

A la Agencia Nacional de Investigación y Desarrollo (ANID) por el financiamiento que hizo posible esta investigación (No. Proyecto: 21210079).

Curriculum Vitae

David Bustos Usta

FORMACIÓN ACADÉMICA

2020-2025: Doctor (c) en Oceanografía, Universidad de Concepción, Chile.

2020-2021: Magister en Física Aplicada, Universidad del Norte, Colombia.

2016-2019: Título profesional en Estadística, Universidad Nacional de Colombia, Colombia.

2010-2016: Título profesional en Ingeniería, Universidad de América, Colombia.

ÁREAS DE INVESTIGACIÓN

- Oceanografía Física, Inteligencia Artificial, Interacción océano-atmósfera, Cambio climático.

PUBLICACIONES

- Rodríguez López, L., Bustos Usta, D. F., Duran-Llacer, I., Bravo Alvarez, L., Bourrel, L., Frappart, F., & Urrutia, R. (2025). Advanced phycocyanin detection in a south American lake using landsat imagery and remote sensing. *Frontiers in Remote Sensing*, 6, 1633522.
- Bustos Usta, D. F., & Torres Parra, R. R. (2024). CMIP6 Ocean and Atmospheric Climate Change Projections in the Seaflower Biosphere

Reserve—Caribbean Sea—by the End of the Twenty-First Century. In *Climate Change Adaptation and Mitigation in the Seaflower Biosphere Reserve: From Local Thinking to Global Actions* (pp. 11-37). Singapore: Springer Nature Singapore.

- Bustos Usta, D. F., Rodríguez-López, L., Torres Parra, R. R., & Bourrel, L. (2025). Sea Surface Temperature Forecasting Using Foundational Models: A Novel Approach Assessed in the Caribbean Sea. *Remote Sensing*, 17(3), 517.
- Rodríguez-López, L., Bustos Usta, D. F., Bravo Alvarez, L., Duran-Llacer, I., Bourrel, L., Frappart, F., Cardenas, R., & Urrutia, R. (2024). Algal pigment estimation models to assess bloom toxicity in a South American lake. *Water*, 16(24), 3708.
- Parra, R. R. T., Usta, D. F. B., Díaz, L. J. O., & Moreno-Ardila, M. P. (2024). Eastern Tropical Pacific atmospheric and oceanic projected changes based on CMIP6 models. *Progress in Oceanography*, 229, 103362.
- Bustos, D. F., Narváez, D. A., Dewitte, B., Oerder, V., Vidal, M., & Tapia, F. (2024). Revisiting historical trends in the Eastern Boundary Upwelling Systems with a machine learning method. *Frontiers in Marine Science*, 11, 1446766.

- Bustos Usta, D. F., Torres Parra, R. R., Rodríguez-López, L., Castillo Alvarez, M., & Bourrel, L. (2024). Observation and projection of Marine heatwaves in the Caribbean Sea from CMIP6 models. *Remote Sensing*, 16(13), 2357.
- Rodríguez-López, L., Alvarez, D., Bustos Usta, D., Duran-Llacer, I., Bravo Alvarez, L., Fagel, N., Bourrel, L., Frappart, F., & Urrutia, R. (2024). Chlorophyll-a Detection Algorithms at Different Depths Using In Situ, Meteorological, and Remote Sensing Data in a Chilean Lake. *Remote Sensing*, 16(4), 647.
- Rodríguez-López, L., Usta, D. B., Duran-Llacer, I., Alvarez, L. B., Yépez, S., Bourrel, L., Frappart, F., & Urrutia, R. (2023). Estimation of Water Quality Parameters through a Combination of Deep Learning and Remote Sensing Techniques in a Lake in Southern Chile. *Remote Sensing*, 15(17), 4157.
- Bustos Usta, D. F., & Torres Parra, R. R. (2023). Projected wind changes in the Caribbean Sea based on CMIP6 models. *Climate Dynamics*, 60(11), 3713-3727.

- Rodríguez-López, L., Bustos Usta, D., Bravo Alvarez, L., Duran-Llacer, I., Lami, A., Martínez-Retureta, R., & Urrutia, R. (2023). Machine learning algorithms for the estimation of water quality parameters in lake Llanquihue in southern Chile. *Water*, 15(11), 1994.
- Bustos Usta, D. F., Teymouri, M., & Chatterjee, U. (2022). Projections of temperature changes over South America during the twenty-first century using CMIP6 models. *GeoJournal*, 87(Suppl 4), 739-763.
- Bustos Usta, D. F., Teymouri, M., Chatterjee, U., & Bandyopadhyay, N. (2022). Projections of atmospheric changes over Iran in 2014–2050 using the CMIP6-HighResMIP experiment. *Arabian Journal of Geosciences*, 15(15), 1335.
- Bustos Usta, D. F., Teymouri, M., & Chatterjee, U. (2022). Assessment of temperature changes over Iran during the twenty-first century using CMIP6 models under SSP1-26, SSP2-4.5, and SSP5-8.5 scenarios. *Arabian Journal of Geosciences*, 15(5), 416.
- Bustos Usta, D. F., & Torres Parra, R. R. (2021). Ocean and atmosphere changes in the Caribbean Sea during the twenty-first century using CMIP5 models. *Ocean Dynamics*, 71(6), 757-777.

- Bustos Usta, D. F., Teymouri, M., Chatterjee, U., & Koley, B. (2022). Temperature projections over Iran during the twenty-first century using CMIP5 models. *Modeling Earth Systems and Environment*, 8(1), 749-760.

EXPERIENCIA PROFESIONAL

- Senior ML Engineer, Conversion Logix , Octubre 2024 - Actualidad
- AI Engineer, Mechanized AI, Septiembre 2024 - Septiembre 2025
- Data Engineer, Level60, Octubre 2024 - Actualidad
- Data Scientist, Unilever, Febrero 2023 - Enero 2025
- Data Scientist, AbInBev, Marzo 2022 - Diciembre 2024
- AI specialist, Kenility, Dic 2022 - Julio 2025
- ML Engineer, Google, Jul 2026 - Dec 2021

EXPERIENCIA DOCENTE

- 2022-2024: Ayudante en cursos de pregrado: Procesamiento y análisis de series de tiempo en Matlab, Universidad de Concepción, Chile.
- 2020-2024: Curso Data Engineering, Data Science y Python Backend, Coderhouse, Argentina.

BECAS Y PREMIOS

- Gastos operacionales de ANID (2023)
- Beca de Doctorado Nacional de ANID (2021-2025).

Índice de contenido

RESUMEN.....	15
ABSTRACT	19
1. INTRODUCCIÓN	22
1.1. <i>Surgencia: Descripción general</i>	22
1.2 <i>Tipos de surgencia.....</i>	24
1.3 <i>Variabilidad local y regional de la surgencia costera</i>	26
1.4 <i>Variabilidad climática de la surgencia costera</i>	28
1.5 <i>Proyecciones a largo plazo</i>	31
1.6 <i>Uso de la IA para estudios en el océano</i>	37
2. HIPÓTESIS Y OBJETIVOS	42
3. MATERIALES Y MÉTODOS	44
3.1. <i>Área de estudio</i>	44
3.2. <i>Datos.....</i>	45
3.3. <i>Procesamiento de datos</i>	52
4. RESULTADOS.....	74
4.1 <i>Capítulo 1: "Revisando las tendencias históricas en los sistemas de surgencia del borde oriental utilizando un método de aprendizaje automático".</i> 74	
4.2 <i>Capítulo 2: "Evolución temporal y espacial de la surgencia costera en sistemas EBUS bajo escenarios climáticos históricos y futuros (1982-2050)".</i> 100	
4.3 <i>Capítulo 3: "Pronóstico de la intensidad de las surgencias en la costa del Pacífico Suroriental mediante inteligencia artificial".....</i>	143
5. DISCUSIÓN	194
6. CONCLUSIONES	198
7. REFERENCIAS.....	200

Índice de Tablas

Tabla 1. Fuentes de datos y detalles sobre las variables utilizadas en esta tesis.	50
Tabla 2. Modelos HighResMip utilizados para este estudio.....	105
Tabla 3 Evaluación del desempeño de los modelos CMIP6 HighResMIP. Métricas de evaluación incluyen la desviación estándar (STD), el coeficiente de correlación (CORR), la raíz del error cuadrático medio (RMSE), la Eficiencia de Nash-Sutcliffe (NSE) y el índice de concordancia (IA). El sufijo 'P' indica la clasificación del desempeño de 1 (Mejor) a 5 (Peor). representa el “valor de desempeño agregado” descrito en la sección 3 (Métodos); cuanto más bajo, mejor es el ranking. Las puntuaciones mínimas de para cada sistema se indican en verde claro.	115
Tabla 4 Evaluación estacional del desempeño del modelo HadGEM3-GC31-HH en las diferentes regiones de los EBUS. Las métricas de evaluación incluyen la desviación estándar normalizada (STD), el coeficiente de correlación (CORR), la raíz del error cuadrático medio (RMSE), la Eficiencia de Nash-Sutcliffe (NSE) y el índice de concordancia (IA). El sufijo 'P' indica la clasificación del desempeño de 1 (Mejor) a 5 (Peor). PT representa el “valor de desempeño agregado” descrito en la sección 3 (Métodos); cuanto más bajo, mejor es el ranking. Las puntuaciones mínimas de PT para cada sistema se indican en verde claro.	122

Índice de Figuras

- Figura 1 Cambios en variables atmosféricas respecto a la hipótesis de intensificación de surgencia en EBUS. (a) temperatura del aire, (b) presión a nivel del mar y (c) estrés de viento paralelo a costa. Los paneles de izquierda a derecha representan el promedio de verano para un período en el pasado (izquierda), futuro(centro) y la diferencia entre ambos (derecha) bajo el escenario RCP8.5 del CMIP5. Cambios significativos en puntos grises. (Extraído de Rykaczewski et al., 2015).....35
- Figura 2 Línea de tiempo con hitos en los campos de la oceanografía (azul) y Machine Learning (naranja). Las distintas eras principales dentro de cada campo se separan por líneas solidas en negro. La mayor pendiente de la línea naranja muestra una mayor aceleración de la generación de avances tecnológicos y de modelamiento en comparación con la línea azul (Sonnewald et al., 2021)39
- Figura 3 Ubicaciones geográficas y batimetría de las cuatro EBUS consideradas en este estudio: (A) Humboldt (HumCS), (B) Benguela (BenCS), (C) California (CanCS), (D) Canarias-Ibéricas (C-ICS). Datos de batimetría obtenidos de GEBCO (Dorschel et al., 2022).45
- Figura 4 Esquema metodológico de configuración de algoritmo SOM univariado. Los vectores de entrada representan a las variables cada día entre 1993-2019 utilizando en 4 estaciones distintas: DJF (Diciembre–Enero–Febrero), MAM (Marzo–Abril–Mayo), JJA (Junio–Julio–Agosto) y SON (Septiembre–Octubre–Noviembre).....55
- Figura 5 Esquema metodológico de configuración de algoritmo SOM. Los vectores de entrada representan a todas las variables como vectores para cada día entre 1993-2014 utilizando en 4 estaciones distintas: DJF (Diciembre–Enero–Febrero), MAM (Marzo–Abril–Mayo), JJA (Junio–Julio–Agosto) y SON (Septiembre–Octubre–Noviembre). La topología de la red puede ser rectangular (nxn) o no rectangular (nxm) con n,m=1,2,3,4,5.....57
- Figura 6. Flujo de procesamiento para la detección de surgencia costera a partir de datos de TSM, que ilustra la secuencia de transformación: desde el producto de TSM utilizado, pasando por la eliminación del gradiente Norte-Sur, la acentuación del gradiente Este-Oeste, la segmentación STSEC, hasta la derivación final del índice de surgencia.....71
- Figura 7 Diagramas de Taylor que evalúan el desempeño de los modelos CMIP6 HighResMIP y de la MMM frente al conjunto de datos OISST para el período 1982-2014. Los diagramas ilustran el CORR, el RMSE y la STD de la TSM diaria dentro de los EBUS. Las líneas discontinuas azules indican valores de correlación de 0.8 y 0.99, mientras que los círculos concéntricos grises representan el RMSE cada 0.2 unidades.114
- Figura 8 Sesgo espacial de la TSM para el período 1982-2014 del modelo con mejor desempeño (la puntuación P_T más baja), HadGEM3-GC31-HH. Los

- datos están organizados en filas designadas para HumCS (primera fila), BenCS (segunda fila), CalCS (tercera fila) y CanCS (cuarta fila). Las columnas representan las estaciones 119
- Figura 9 Diagramas de Taylor que evalúan el desempeño del modelo CMIP6 HadGEM3-GC31-HH frente al conjunto de datos MODIS para el período 2002-2014. Los diagramas ilustran el CORR, el RMSE y la STD de la TSM diaria dentro de los EBUS. Las líneas discontinuas azules indican valores de correlación de 0.8 y 0.99, mientras que los círculos concéntricos grises representan el RMSE cada 0.2 unidades. Cada color representa las diferentes estaciones y el gris claro considera todo el período de tiempo. 121
- Figura 10 Sesgo espacial de la Temperatura Superficial del Mar (TSM) para el período 2002-2014, obtenido del modelo con el mejor desempeño (menor puntaje PT), HadGEM3-GC31-HH (Tabla 2). Los datos se organizan en filas designadas para HumCS (primera fila), BenCS (segunda fila), CalCS (tercera fila) y CanCS (cuarta fila). Las columnas representan las estaciones del año. 126
- Figura 11 Series temporales anuales de las métricas de surgencia proyectadas (2015-2050) en los cuatro EBUS. Los paneles muestran **(a)** la anomalía de intensidad, **(b)** la frecuencia de eventos y **(c)** la duración media. Las líneas sólidas representan las tendencias lineales; su pendiente y significancia se muestran en la leyenda (* indica $p < 0.05$). 129
- Figura 12 Estructura mensual e interanual de las métricas de surgencia en el sistema de Humboldt (2015-2050). Fila superior: Resumen mensual climatológico para (A) Intensidad media ($^{\circ}\text{C}$), (B) Frecuencia (eventos/mes), y (C) Duración media (días). Para el panel (B), el promedio se calcula sobre los meses con frecuencia mayor a cero. Fila inferior: Evolución interanual mensual de (D) Intensidad, (E) Frecuencia, y (F) Duración. En el panel (E), los meses en negro indican una frecuencia de cero eventos. 131
- Figura 13 Métricas anuales de surgencia por centro de afloramiento en el sistema de Humboldt (2015-2050). Cada fila representa un centro de surgencia individual, ordenado de norte (arriba) a sur (abajo). Las columnas muestran las series temporales anuales y las tendencias lineales para **(A)** Intensidad media ($^{\circ}\text{C}$), **(B)** Frecuencia de eventos, y **(C)** Duración media (días). Las pendientes (por década) y los valores p se indican en cada panel. El asterisco (*) denota tendencias estadísticamente significativas ($p < 0.05$). 132
- Figura 14 Estructura mensual e interanual de las métricas de surgencia en el sistema de California (2015-2050). Fila superior: Resumen mensual climatológico para (A) Intensidad media ($^{\circ}\text{C}$), (B) Frecuencia (eventos/mes), y (C) Duración media (días). Para el panel (B), el promedio se calcula sobre los meses con frecuencia mayor a cero. Fila inferior: Evolución interanual

mensual de (D) Intensidad, (E) Frecuencia, y (F) Duración. En el panel (E), los meses en negro indican una frecuencia de cero eventos.	134
Figura 15 Métricas anuales de surgencia por centro de afloramiento en el sistema de California (2015-2050). Cada fila representa un centro de surgencia individual, ordenado de norte (arriba) a sur (abajo). Las columnas muestran las series temporales anuales y las tendencias lineales para (A) Intensidad media (°C), (B) Frecuencia de eventos, y (C) Duración media (días). Las pendientes (por década) y los valores p se indican en cada panel. El asterisco (*) denota tendencias estadísticamente significativas ($p < 0.05$).	135
Figura 16 Estructura mensual e interanual de las métricas de surgencia en el sistema de Benguela (2015-2050). Fila superior: Resumen mensual climatológico para (A) Intensidad media (°C), (B) Frecuencia (eventos/mes), y (C) Duración media (días). Para el panel (B), el promedio se calcula sobre los meses con frecuencia mayor a cero. Fila inferior: Evolución interanual mensual de (D) Intensidad, (E) Frecuencia, y (F) Duración. En el panel (E), los meses en negro indican una frecuencia de cero eventos.	137
Figura 17 Métricas anuales de surgencia por centro de afloramiento en el sistema de Benguela (2015-2050). Cada fila representa un centro de surgencia individual, ordenado de norte (arriba) a sur (abajo). Las columnas muestran las series temporales anuales y las tendencias lineales para (A) Intensidad media (°C), (B) Frecuencia de eventos, y (C) Duración media (días). Las pendientes (por década) y los valores p se indican en cada panel. El asterisco (*) denota tendencias estadísticamente significativas ($p < 0.05$).	138
Figura 18 Estructura mensual e interanual de las métricas de surgencia en el sistema de Canarias (2015-2050). Fila superior: Resumen mensual climatológico para (A) Intensidad media (°C), (B) Frecuencia (eventos/mes), y (C) Duración media (días). Para el panel (B), el promedio se calcula sobre los meses con frecuencia mayor a cero. Fila inferior: Evolución interanual mensual de (D) Intensidad, (E) Frecuencia, y (F) Duración. En el panel (E), los meses en negro indican una frecuencia de cero eventos.	140
Figura 19 Métricas anuales de surgencia por centro de afloramiento en el sistema de Canarias (2015-2050). Cada fila representa un centro de surgencia individual, ordenado de norte (arriba) a sur (abajo). Las columnas muestran las series temporales anuales y las tendencias lineales para (A) Intensidad media (°C), (B) Frecuencia de eventos, y (C) Duración media (días). Las pendientes (por década) y los valores p se indican en cada panel. El asterisco (*) denota tendencias estadísticamente significativas ($p < 0.05$).	141

RESUMEN

La surgencia costera ha sido ampliamente estudiada; sin embargo, los enfoques tradicionales a menudo limitados a análisis univariados y a escalas espaciales o temporales que no capturan completamente la variabilidad del fenómeno, han dejado vacíos en la comprensión del proceso. Resultados previos sugieren que los sistemas de borde oriental (EBUS por sus siglas en inglés) experimentarán diversos cambios, como un inicio más temprano y una mayor duración de la temporada de surgencia, aunque la falta de consenso, atribuible a la diversidad de datos y metodologías, evidencia la necesidad de un enfoque más integral. La limitada disponibilidad de datos y la capacidad de cómputo han dificultado históricamente la captura completa de la variabilidad asociada a la surgencia costera, un proceso inherentemente no lineal.

Esta tesis doctoral adopta un enfoque basado en datos (data-driven) y técnicas de inteligencia artificial (AI, por sus siglas en inglés). Para abordar estas limitaciones se integraron múltiples variables oceanográficas y atmosféricas provenientes de diversas fuentes incluyendo observaciones satelitales, reanálisis y modelos climáticos de alta resolución (CMIP6-HighResMIP) con los objetivos de: caracterizar la variabilidad histórica de la surgencia, proyectar sus cambios futuros y desarrollar un algoritmo de pronóstico basado en inteligencia artificial capaz de pronosticar el proceso a escala sinóptica.

En una primera fase, se caracterizaron los modos dominantes de variabilidad de la surgencia en los cuatro principales EBUS durante el período 1993-2019, mediante la aplicación de los algoritmos de inteligencia artificial SOM (*Self-Organizing Maps*) y HAC (*Hierarchical Agglomerative Clustering*). Un resultado central de este análisis fue la falta de respaldo para la hipótesis de Bakun, la cual menciona que debido al cambio climático se esperaría una intensificación de los gradientes tierra-océano en la temperatura del aire y en la presión a nivel del mar, lo cual provocaría un fortalecimiento de los vientos costeros dirigidos hacia el ecuador en las regiones EBUS. Los resultados obtenidos no mostraron cambios consistentes en los gradientes de presión o temperatura entre el océano y el continente. Una posible explicación para esta falta de respaldo es la ausencia de un fortalecimiento de los sistemas de baja presión térmica continental (CTLPS, por sus siglas en inglés) ante el aumento de las temperaturas. Observaciones de las últimas décadas indican que los vientos en los EBUS están impulsados principalmente por la posición e intensidad de los sistemas subtropicales de alta presión (SHPS, por su siglas en inglés). Por lo tanto, la mejor explicación para los cambios a gran escala observados en estos sistemas es el desplazamiento hacia el polo de los SHPS, impulsados por la expansión de las Celdas de Hadley debido a tasas de calentamiento más intensas en los trópicos en comparación con el ecuador. Los resultados obtenidos respaldan que los centros del SHPS efectivamente se han desplazado hacia el polo durante la primavera y el verano con excepción del BenCS.

Posteriormente, se evaluaron los posibles cambios futuros en la surgencia utilizando cinco modelos de alta resolución de la iniciativa HighResMIP del CMIP6, con base en los experimentos *hist-1950* (1982-2014) y *highres-future* (2015-2050). A pesar de una sobreestimación generalizada de la temperatura cerca de la costa, el modelo HadGEM-GC31-HH fue identificado como el de mejor desempeño para reproducir la firma espacial de la surgencia en la TSM. Las proyecciones futuras (2015-2050) bajo el escenario de altas emisiones *highres-future* indican una disminución estadísticamente significativa en la frecuencia y duración de los eventos en todos los EBUS, sugiriendo una transición hacia un régimen de afloramiento más intermitente y esporádico. No obstante, estos resultados deben interpretarse con cautela, dado que se derivan de un escenario de altas emisiones y el nivel de confianza asociado suele ser medio.

Finalmente, se desarrolló un sistema de pronóstico para el Sistema de la Corriente de Humboldt (HCS) utilizando modelos de aprendizaje profundo (*Deep Learning*). La arquitectura U-Net demostró una capacidad superior para predecir campos de TSM con un horizonte de siete días, manteniendo un error cuadrático medio (RMSE) inferior a 0.4°C . Este modelo se integró con un nuevo índice de surgencia, basado en una versión modificada de la metodología STSEC (*Spatio-Temporal Seeded Edge Clustering*), el cual fue validado con éxito en la predicción

de eventos extremos. Los enfoques tradicionales, como el Índice de Bakun, son intrínsecamente limitados al omitir la influencia de la circulación oceánica y el suministro de nutrientes. Si bien índices como el CUTI (Coastal Upwelling Transport Index) y el BEUTI (Biologically Effective Upwelling Transport Index) superan estas deficiencias, estos se encuentran típicamente restringidos a dominios geográficos específicos (Sistema de corrientes de California) y su resolución es a menudo insuficiente para capturar con precisión los procesos altamente no lineales y la variabilidad extrema costera a escala sinóptica en otros EBUS. De forma complementaria, se exploró el uso de Modelos Grandes de Lenguaje (LLMs), donde el modelo Chronos Large mostró un excelente rendimiento en pronósticos puntuales de TSM, con errores inferiores al 5% en predicciones semanales.

En conjunto, esta tesis demuestra el potencial de las técnicas de IA para avanzar en la comprensión y predicción de la surgencia costera. Los resultados no solo identifican los mecanismos físicos clave que modularán su evolución futura, sino que también proporcionan herramientas innovadoras con aplicabilidad directa en la gestión de los ecosistemas marinos.

ABSTRACT

Coastal upwelling has been extensively studied; however, traditional approaches—often limited to univariate analyses and spatial or temporal scales that do not fully capture the phenomenon’s variability—have left gaps in process understanding. Previous findings suggest that Eastern Boundary Upwelling Systems (EBUS) experience various changes, such as an earlier onset and longer duration of the upwelling season, although a lack of consensus, attributed to diverse datasets and methodologies, highlights the need for a more comprehensive approach. The historically limited availability of data and computational capacity has impeded fully capturing the variability associated with coastal upwelling, an inherently nonlinear process.

This doctoral thesis adopts a data-driven approach combined with artificial intelligence (AI) techniques. To overcome these limitations, multiple oceanographic and atmospheric variables from diverse sources—including satellite observations, reanalyses, and high-resolution climate models (CMIP6-HighResMIP)—were integrated with the objectives to characterize the historical variability of upwelling, project its future changes, and develop an AI-based forecasting algorithm capable of predicting the process at a synoptic scale.

In a first phase, the dominant variability modes of upwelling in the four principal EBUS during 1993–2019 were characterized using AI algorithms including Self-

Organizing Maps (SOM) and Hierarchical Agglomerative Clustering (HAC). A central result of this analysis was the lack of support for Bakun's hypothesis. Instead, it was demonstrated that the poleward migration of subtropical high-pressure systems constitutes a primary driver of the observed changes in upwelling dynamics. Additionally, it was shown that, except for the Canary Current system, upwelling events have become longer lasting in spring and more intense in summer.

Subsequently, potential future changes in upwelling were evaluated using five high-resolution models from the CMIP6 HighResMIP initiative, based on the hist-1950 (1982–2014) and highres-future (2015–2050) experiments. Despite a widespread overestimation of coastal sea surface temperature, the HadGEM-GC31-HH model was found to perform best in terms of reproducing the upwelling signal in SST. Future projections (2015–2050) under a high-emission scenario (highres-future) indicate a statistically significant decrease in the frequency and duration of upwelling events across all EBUS, suggesting a transition toward a more intermittent and sporadic upwelling regimes. Nonetheless, these results should be interpreted cautiously given the high-emissions scenario they are based on and commonly moderate confidence levels.

Finally, a forecasting system for the Humboldt Current System (HCS) was developed using deep learning models. The U-Net architecture demonstrated

superior capability in predicting SST fields with a seven-day lead time, maintaining a root mean squared error (RMSE) below 0.4°C . This model was integrated with a novel upwelling index based on a modified version of the Spatio-Temporal Seeded Edge Clustering (STSEC) methodology, which was successfully validated for the prediction of extreme events. Complementarily, the use of Large Language Models (LLMs) was explored, with the Chronos Large model showing excellent performance in point forecasts of SST, achieving errors below 5% for weekly predictions.

Together, this thesis demonstrates the potential of AI techniques to advance the understanding and forecasting of coastal upwelling. The results not only identify the key physical mechanisms modulating its future evolution but also provide innovative tools with direct applicability for marine ecosystem management.

1. INTRODUCCIÓN

La surgencia ha sido ampliamente estudiada a lo largo de los principales ecosistemas de borde oriental de los océanos (Bakun et al., 2015; Bograd et al., 2023; Sydeman et al., 2014; D. Wang et al., 2015). Se puede definir como un proceso físico resultante del balance de las fuerzas friccionales del viento y la rotación de la Tierra (Bakun, 1973; Ekman, 1905; Lambeck, 2005; Murphy, 1926; Rekier et al., 2022; Sverdrup & Defant, 1937). Del balance de fuerzas entre el viento y la rotación de la Tierra se produce un transporte integrado de la capa superficial conocido como transporte de Ekman (~200km) se genera una disminución del viento (drop-off) lo cual genera un efecto rotacional del viento favorable al bombeo de Ekman (Capet et al., 2004). Estos dos factores junto a otros como batimetría y topografía de la costa, conduce al afloramiento de aguas ricas en nutrientes que estimulan el crecimiento de fitoplancton, que es clave para el sostenimiento de las tramas cadena tróficas y flujos de energía en ecosistemas marinos (Jacox et al., 2018).

1.1. Surgencia: Descripción general

Las regiones donde ocurre surgencia costera ocupan menos del ~1% de la superficie del océano, pero contribuyen significativamente a la productividad primaria de los océanos y hasta el 40 % de la captura mundial de peces (Pauly & Christensen, 1995), jugando un rol importante para el ecosistema y las regiones

donde ocurre ya que juegan un rol clave para los flujos de carbono y el intercambio océano-atmósfera a nivel global. Por lo tanto, entender la dinámica y posibles cambios pasados, presentes y futuros en las distintas regiones con surgencia costera, resulta de gran importancia para entender la dinámica de los ecosistemas y la economía de las comunidades costeras alrededor del mundo (Large & Danabasoglu, 2006).

Es bien conocido que la surgencia genera cambios en propiedades físico-químicas del océano costero como acidificación y aumento de intercambio gaseoso (Lachkar, 2014; Montecino et al., 2017), desoxigenación (Bakun, 2017), disminución de la estratificación (He & Mahadevan, 2021), aumento de advección superficial (actividad de mesoescala) y transporte lateral (Reddin et al., 2015). Sin embargo, entender las escalas espaciales y temporales de estos cambios requiere un enfoque multiparamétrico que tome en cuenta tanto los mecanismos de generación de la surgencia como las variables físicas y biogeoquímicas afectadas por ésta. El presente trabajo de tesis se distingue por aplicar un enfoque basado en Inteligencia Artificial para el estudio de la surgencia costera, una aproximación poco convencional en la oceanografía. La finalidad es analizar las múltiples interacciones que modulan la generación, ocurrencia y consecuencias de este fenómeno, y así comprender los cambios en los principales Sistemas de Borde Oriental (EBUS).

1.2 Tipos de surgencia

- **Surgencia Costera:** debe su existencia a la presencia de vientos favorables al transporte costa afuera y bombeo de Ekman, línea de costa y un límite lateral impermeable. Este tipo de surgencia se presenta en los sistemas de corrientes de Perú-Chile, California, Benguela y Canarias (Chavez & Messié, 2009; Mackas et al., 2006), también conocidos como EBUS (Tomczak Jr, 1981). Los EBUS tienen diversas características en común, como variación estacional del estrés del viento, contracorrientes hacia los polos, una vasta zona de mínimo oxígeno, masas de agua con alto contenido de nutrientes y una alta variabilidad temporal y espacial (Bograd et al., 2023). Sin embargo, también existen diferencias en la estructura física y el forzamiento que puede generar respuestas divergentes. Los sistemas del Pacífico tienen plataformas continentales angostas, masas de aguas más antiguas, con altas (bajas) concentraciones de nutrientes (oxígeno), además son afectados en mayor magnitud por el ENSO (Garçon et al., 2019). En contraste, los sistemas del Atlántico tienen plataformas más anchas con masas de agua más jóvenes y no sufren tanto impacto por teleconexiones tropicales o extratropicales (Mackas et al., 2006). Por otro lado, la topografía de cada sistema permite la formación de distintos centros de surgencia que favorecen la productividad primaria.

- **Surgencia Ecuatorial:** existe debido al efecto combinado de los vientos alisios y el cambio de signo en el parámetro de Coriolis (rotación de Tierra) cuando se cruza el Ecuador, lo que permite que se genere una zona de divergencia que favorece el afloramiento de aguas de cierta profundidad. Este tipo de surgencia es afectada por la zona de interconvergencia tropical, ondas Kelvin y Rossby de baja latitud (Halpern et al., 1989; Johnson et al., 2001).
- **Surgencia en Bordes de hielo:** tiene su explicación en las diferencias del coeficiente de arrastre entre aire-océano y aire-hielo, siendo de 2 a 3 veces mayor en el segundo caso respecto al primero (Häkkinen, 1987), lo cual permite la transferencia de momentum mucho más eficiente que en el océano abierto, favoreciendo el transporte de Ekman (Kämpf & Chapman, 2016a). Estos sistemas se caracterizan por tener aportes relativamente grandes de agua dulce, amplios rangos estacionales de temperatura y condiciones invernales tormentosas (Mundy et al., 2009).
- **Surgencia por bombeo de Ekman:** como resultado de un campo de viento heterogéneo, que genera divergencia (convergencia) de la superficie del océano. Estas condiciones generan velocidades ascendentes (descendentes) en la base de la capa superficial inducida por

el bombeo de Ekman la cual es proporcional al rotor del viento permitiendo el afloramiento o hundimiento de agua (Capet et al., 2004).

1.3 Variabilidad local y regional de la surgencia costera

Los principales factores que modulan la surgencia en los EBUS son: transporte de Ekman y geostrófico, gradiente de presión, rotación de la Tierra (Coriolis), estrés del viento, intensidad de vientos paralelos a la costa, rotor del viento, topografía (puntas y cabos) y fricción (Kämpf & Chapman, 2016a). Además, la surgencia inducida por viento se puede explicar por dos mecanismos, el primero es la divergencia costera resultado del transporte de Ekman y el segundo el bombeo de Ekman, el cual es resultado del rotor del viento ciclónico y que se puede ver como la velocidad vertical en la base de la capa de Ekman (Jacox & Edwards, 2011).

Distintas escalas temporales tienen efectos en la variabilidad de la surgencia. La más importante es la escala sinóptica, la cual es la fuente principal de variabilidad de los vientos además de tormentas y ondas internas en la atmósfera (Mackas et al., 2006). Se ha mostrado que los sistemas de alta o baja presión hacia la costa dominan los patrones de viento, favoreciendo o inhibiendo la surgencia en períodos de intensificación o relajación que pueden durar entre 3 y 10 días (Pérez-Santos et al., 2019; Zaytsev et al., 2003). Por otro lado, en la escala

estacional los movimientos de los sistemas de alta presión subtropical regulan la ubicación e intensidad del viento en los EBUS (García-Reyes et al., 2013; Robinson & Brink, 2005), lo cual permite que en verano se intensifiquen los vientos favorables a surgencia, generando fuertes gradientes horizontales de densidad en la superficie del mar. Estos gradientes generan un frente de surgencia que limita la región de surgencia activa (Barton et al., 1998; Saldías et al., 2012; Zaytsev et al., 2003) y donde interactúan distintas estructuras de mesoescala como meandros y remolinos que afectan la circulación en estos sistemas (Chaigneau et al., 2009; Letelier et al., 2009).

Por último, en la escala interanual y decadal se tienen distintas oscilaciones como el ENSO o la PDO que pueden afectar la surgencia costera pero no en igual intensidad para todos los EBUS (Mackas et al., 2006; Robinson & Brink, 2005). En diversos estudios se ha mostrado que el ENSO en su fase positiva, p. ej., El Niño, genera alteraciones en la surgencia debido a que la piconoclina se profundiza, provocando que las aguas que llegan a superficie sean más superficiales, trayendo menos nutrientes (Espinoza-Morriberón et al., 2017; Jacox et al., 2015; Montecinos & Gomez, 2010). Lo contrario ocurre en la fase negativa, i.e., La Niña, que por lo general conduce al afloramiento de aguas más frías y más profundas, con bajas concentraciones de oxígeno (Nam et al., 2011; Riascos et al., 2012) y pH más bajo (Bednaršek et al., 2018; Kessouri et al.,

2021). Condiciones similares se han encontrado para el caso de la PDO en su fase positiva y negativa respecto al ENSO, siendo relevante principalmente para el sistema de corrientes de California junto a otras oscilaciones decadales como la Oscilación del giro del Pacífico Norte (NPGO, por sus siglas en inglés). Incluso pueden existir períodos de tiempo en los cuales la PDO y el ENSO oscilen en fase (Verdon & Franks, 2006).

1.4 Variabilidad climática de la surgencia costera

Uno de los primeros estudios realizados para analizar el impacto del cambio climático en la surgencia fue el de Bakun (1990). Este trabajo planteó la hipótesis de que el calentamiento global favorecería una mayor tasa de calentamiento sobre la tierra en comparación con el océano, provocando un aumento del gradiente de temperatura del aire y presión atmosférica océano-tierra, intensificando los vientos paralelos a la costa por balance geostrófico y favoreciendo la surgencia por transporte de Ekman. Bakun (1990) puso a prueba esta hipótesis calculando el estrés del viento a lo largo de la costa, mensualmente durante 40 años en base a estaciones meteorológicas, obteniendo tendencias positivas y significativas para todos los EBUS en primavera-verano. Algunos estudios posteriores han encontrado resultados similares, que apoyan la hipótesis de Bakun (1990), pero utilizando diferentes datos, períodos y en diversas regiones del mundo (Bakun & Weeks, 2008; Diffenbaugh et al., 2004;

Mendelssohn & Schwing, 2002; Santos et al., 2005; Schwing & Mendelssohn, 1997). No obstante, el trabajo de Bakun (1990) tuvo una fuente de sesgo relacionada con la altura de medición de los datos de viento utilizados del International Comprehensive Ocean-Atmosphere Data Set (ICOADS). Una vez corregido este sesgo, se ven tendencias significativas en los patrones de viento solo hacia los polos (Tokinaga & Xie, 2011).

Desde el punto de vista observacional, las conclusiones obtenidas hasta ahora respecto a posibles variaciones interanuales, decadales y de largo plazo de la surgencia a lo largo de los principales EBUS no han presentado uniformidad, con tendencias variables en intensidad, frecuencia y duración a lo largo de los principales EBUS (Abrahams et al., 2021b; García-Reyes et al., 2015) y resultados dependientes de la longitud de las series de tiempo, estacionalidad (mayores tendencias en el verano), latitud (mayores tendencias hacia latitudes altas) y el tipo de datos (mayores tendencias para datos observacionales respecto a modelos) (Sydeman et al., 2014; Taboada et al., 2019). De igual forma, otras metodologías basadas en datos de alta resolución espacio-temporal y modelación numérica muestran tendencias no consistentes en estrés de viento e incluso aumentos de temperatura superficial del mar (TSM) cerca de la costa a lo largo de los principales EBUS durante las últimas décadas (Varela et al., 2015, 2018), indicando que no hay evidencia de una intensificación general de la surgencia a lo largo de los EBUS.

Por otro lado, en algunos trabajos se ha analizado cómo la variabilidad atmosférica tanto en la escala sinóptica (p. ej. sistemas transitorios de alta o baja presión), estacional (movimiento de anticiclones subtropicales) e interanual (p. ej. fluctuaciones por oscilaciones como el ENSO o la PDO entre otras) pueden tener efectos en la surgencia, encontrando que a mayor estratificación se genera que el agua que llega a superficie sea más somera y pobre en nutrientes (Jacox & Edwards, 2011; Lentz & Chapman, 2004).

De acuerdo con estos resultados, se puede observar que no existe un consenso de cómo la variabilidad climática ha impactado a los EBUS en las décadas recientes, sobre todo debido que las escalas temporales están interconectadas. Es decir, la variabilidad sinóptica puede estar cambiando en términos de intensidad y duración debido al cambio climático (Abrahams et al., 2021b; Tim et al., 2016). Por otro lado, una serie de consideraciones adicionales generan dificultad en interpretar los resultados, que son altamente dependientes del modelo utilizado, fuente de datos, la variable considerada (directa o indirecta de la intensidad de surgencia) y del período de tiempo estudiado (Sydeman et al., 2014; Varela et al., 2018).

1.5 Proyecciones a largo plazo

Otro gran grupo de estudios que han evaluado el comportamiento de los EBUS se centra en entender cómo podrían cambiar las condiciones en estos sistemas bajo las proyecciones climáticas (Aguirre et al., 2019; Chamorro et al., 2021; Oyarzún & Brierley, 2019; Rykaczewski et al., 2015; Terada et al., 2020; Wang et al., 2015). Las proyecciones climáticas se realizan con modelos climáticos acoplados océano-atmósfera (AOGCMs). Los cuales son comparados por el “Proyecto de Intercomparación de Modelos Acoplados” (CMIP, por su siglas en inglés). Estas proyecciones son utilizadas por el Panel Intergubernamental en Cambio Climático (IPCC, por su sigla en inglés) en sus reportes con el fin de establecer impactos del cambio climático en la Tierra (<https://www.ipcc.ch/>). CMIP se centra en comprender mejor los cambios climáticos pasados, presentes y futuros que surgen de la variabilidad natural no forzada o en respuesta a cambios en el forzamiento radiativo en un contexto de múltiples modelos de diferentes instituciones alrededor de todo el mundo (Shukla et al., 2019).

Actualmente se encuentra publicada la sexta fase de este proyecto de intercomparación, CMIP6 (Parmesan et al., 2022). Esta fase se centra en tener un mejor entendimiento del futuro de la dinámica terrestre (Eyring et al., 2016) con mayor cantidad de modelos de mayor resolución a través de distintos experimentos como el HighResMIP (Haarsma et al., 2016a). La resolución espacial de los modelos globales es de ~250km en atmósfera y 100km en el

océano, con HighResMIP se busca alcanzar resolución entre 10-50km en componentes oceánicos y atmosféricos, que se adaptan mejor a las zonas costeras y a las necesidades científicas a través de diferentes escenarios socio-económicos (Riahi et al., 2017). Esto es importante porque en anteriores fases los modelos del CMIP no han tenido buen desempeño en reproducir las condiciones climáticas en los EBUS y una de las razones podría estar relacionada con el impacto de la resolución horizontal en los modelos globales (Pachauri & Reisinger, 2007; Pörtner et al., 2019).

Los resultados de CMIP muestran que el cambio climático tendría efectos en la surgencia de los EBUS, sugiriendo que los cambios en presión atmosférica y patrones de viento estarían asociados a la migración hacia los polos de los sistemas subtropicales de alta presión (García-Reyes et al., 2013; He et al., 2017; Schroeder et al., 2013; Wang et al., 2015). Con el incremento de gases de efecto invernadero, se produce un mayor calentamiento sobre los trópicos en comparación con el Ecuador, disminuyendo el gradiente térmico y aumentando el desplazamiento hacia los polos de las corrientes en chorro subtropicales (Frierson et al., 2007; Hu et al., 2013; Lu et al., 2007; Staten et al., 2018). Como consecuencia de lo anterior, se produce una expansión de celdas de Hadley, desplazando los anticiclones hacia los polos (Grise & Davis, 2020; Lu et al., 2007; Xian et al., 2021). En algunos estudios se ha mostrado que esta expansión no se daría de igual forma en los dos hemisferios, con tendencias variables de acuerdo

con las métricas (dinámicas, hidrológicas, térmicas o químicas) que se utilicen para evaluar la expansión (Xian et al., 2021). La celda de Hadley del hemisferio norte tiende a disminuir en intensidad, mientras que la del hemisferio sur aumentar (Ma & Xie, 2013). Esto se debe a la respuesta asimétrica de TSM en latitudes medias del hemisferio norte (más tierra) y del sur (menos tierra) junto con mayor calentamiento en los trópicos (J. Choi et al., 2014; Cook, 2003; Watt-Meyer et al., 2019).

También se ha propuesto que tanto el movimiento de los anticiclones hacia los polos debido a la expansión de las celdas de Hadley y el incremento en el gradiente de temperatura y presión océano-atmósfera pueden llegar a ser factores complementarios que pueden generar cambios en la surgencia costera, provocando que se generen zonas distintivas dentro de los EBUS con cambios significativos en el viento hacia el Ecuador y los polos por gradiente temperatura-presión favorecido y movimiento hacia los polos de anticiclones, respectivamente. Lo anterior conduciría a la formación de una zona de transición con pocos cambios en términos de forzamiento atmosférico, pero con posibles cambios en la productividad primaria (Weidberg et al., 2020).

Rykaczewski et al. (2015) propusieron que la migración de los sistemas de alta presión atmosféricos hacia los polos (Figura 1b) ejercería cambios de largo plazo en intensidad, ubicación y estacionalidad de los vientos favorables a la surgencia,

con una intensificación (reducción) en general de estos vientos hacia los polos (Ecuador) durante las estaciones de primavera-verano (Figura 1c), para los sistemas de Canarias (Cordeiro Pires et al., 2016; Lopes et al., 2014; Miranda et al., 2013; Rykaczewski et al., 2015; Sousa et al., 2017; Sylla et al., 2019; Varela, Rodríguez-Díaz, et al., 2022), Benguela (Rixen et al., 2021; Rykaczewski et al., 2015), California (Brady et al., 2017; Howard et al., 2020; Li et al., 2014; Pozo Buil et al., 2021; Rykaczewski et al., 2015; Snyder et al., 2003) y Humboldt (Belmadani et al., 2014; Chamorro et al., 2021; Goubanova et al., 2011; Oerder et al., 2015a; Oyarzún & Brierley, 2019; Rykaczewski et al., 2015; Tim et al., 2016; D. Wang et al., 2015) con tendencias más consistentes a mayor tasa de emisión de gases de efecto invernadero y con alta incertidumbre en el sistema de California (Tim et al., 2016).




Figura 1. Cambios en variables atmosféricas respecto a la hipótesis de intensificación de surgencia en EBUS. (a) temperatura del aire, (b) presión a nivel del mar y (c) estrés de viento paralelo a costa. Los paneles de izquierda a derecha representan el promedio de verano para un período en el pasado (izquierda), futuro (centro) y la diferencia entre ambos (derecha) bajo el escenario RCP8.5 del CMIP5. Cambios significativos en puntos grises. (Extraído de Rykaczewski et al., 2015)

Además diversos trabajos han mostrado que debido al cambio climático se esperarían en el futuro incrementos significativos en la estratificación de la columna de agua cerca de regiones costeras de los sistemas de California (Howard et al., 2020; Pozo Buil et al., 2021), Canarias (Cordeiro Pires et al., 2016; Lopes et al., 2014; Sousa et al., 2017), Humboldt (Echevin et al., 2020; Oerder

et al., 2015b; Oyarzún & Brierley, 2019) y Benguela (Cordeiro Pires et al., 2016; Sousa et al., 2017), haciendo que la mezcla se haga cada vez más delgada, aunque es importante resaltar que este incremento de la estratificación no es solamente en los EBUS, sino a nivel global (Capotondi et al., 2012) siendo un factor que entra en competencia con los posibles efectos de cambios locales del viento.

Otros trabajos se han concentrado en analizar cómo podría cambiar la duración de la surgencia, obteniendo como resultado mayor duración hacia los polos (Rykaczewski et al., 2015; Tim et al., 2016), aunque para el sistema de California se obtiene lo contrario a partir de mitad del siglo XXI bajo escenarios de alta emisión radiativa (Brady et al., 2017). Además, respecto al momento del año en el que ocurre la surgencia, Rykaczewski et al. (2015) proyectaron una transición primaveral más temprana y un alargamiento de la temporada de surgencia para todos los EBUS hacia los polos. Sin embargo, Snyder et al. (2003) mostraron para California tendencias contrarias a los demás EBUS. Estos cambios son importantes, ya que modificaciones en el período estacional y duración de la surgencia pueden impulsar cambios importantes en las interacciones tróficas de los EBUS (Bograd et al., 2019).

Por otro lado, otros estudios han mostrado que variaciones en la circulación termohalina y variaciones en la ventilación de masas de agua pueden tener

consecuencias en las concentraciones de nutrientes y oxígeno de las aguas de surgencia (Pitcher et al., 2021; Rykaczewski et al., 2015). Además, cambios de largo plazo en la frecuencia e intensidad de fenómenos de gran escala, que representan otros mecanismos remotos de forzamiento mediante los cuales el cambio climático puede afectar las propiedades de los EBUS, algunos de estos mecanismos pueden ser oscilaciones interanuales como el ENSO u otros modos de variabilidad (Bonino et al., 2019) que pueden modificar los patrones de viento (Jacox et al., 2015), patrones de circulación (Montes et al., 2011), actividad de mesoescala y eddies (Conejero et al., 2020), composición de masas de agua (Bograd et al., 2019) y propiedades biogeoquímicas (Garçon et al., 2019) de los EBUS.

1.6 Uso de la IA para estudios en el océano

Un aspecto que resulta importante a la hora de cuantificar posibles cambios en la surgencia costera tiene que ver con la forma en cómo se mide su intensidad, frecuencia y duración. Hoy en día aún se sigue utilizando como base la teoría clásica de Ekman, que tiene más de 100 años en vigencia (Bakun, 1973; Ekman, 1905). Muchos de los trabajos en las últimas décadas han desarrollado índices basados en la TSM utilizando datos in situ (Polonsky & Serebrennikov, 2021; Speth et al., 1978; Tapia et al., 2009; Wooster et al., 1976) e información de sensores remotos (González-Nuevo et al., 2014; Lluch-Cota, 2000; Marcello

et al., 2011; Marchesiello & Estrade, 2010; Santos et al., 2012). Por otro lado, otros trabajos se han cuantificado o evaluado la intensidad de la surgencia por medio del esfuerzo del viento (Aravena et al., 2014; Narayan et al., 2010; Naulita & Arhatin, 2020) y en algunos casos se ha considerado la clorofila superficial como un factor determinante para la cuantificación de la extensión espacial e intensidad de la surgencia (Cervantes-Duarte et al., 2013; Espinosa-Carreón et al., 2004; Pan et al., 1988; Thomas et al., 2001).

En los últimos años se han desarrollado técnicas innovadoras fundamentadas en Inteligencia Artificial (IA, por sus siglas en inglés), una disciplina que sienta sus pilares en las matemáticas, estadística y ciencias de la computación, siendo capaz de identificar patrones complejos (Sagi et al., 2020; Sonnewald et al., 2021). IA puede brindar soluciones a problemáticas de alta dimensionalidad y complejidad por medio de algoritmos y técnicas de aprendizaje supervisado, semi-supervisado o no supervisado que llevan más de cuatro décadas mostrando continuos avances (Sonnewald et al., 2021). La IA se ha estado aplicando en el campo de la oceanografía solamente en las últimas cuatro décadas (Figura 2). Este tipo de metodologías han permitido crear índices basados en técnicas de aprendizaje no supervisado (ie. Fuzzy C-means) (Chen et al., 2012; Sousa et al., 2008). Por otro lado, recientemente se han propuesto otras metodologías que tienen en cuenta la influencia de la topografía y TSM de alta resolución con alta

capacidad de describir la variabilidad espacio-temporal de la intensidad de la surgencia costera (Benazzouz et al., 2014).




Figura 2. Línea de tiempo con hitos en los campos de la oceanografía (azul) y Machine Learning (naranja). Las distintas eras principales dentro de cada campo se separan por líneas solidas en negro. La mayor pendiente de la línea naranja muestra una mayor aceleración de la generación de avances tecnológicos y de modelamiento en comparación con la línea azul (Sonnewald et al., 2021)

Algunos de los problemas que no permiten tener conclusiones del todo precisas respecto a posibles cambios en estos sistemas son, por ejemplo, la resolución espacio-temporal de las diferentes fuentes de datos, ya que usualmente no son las adecuadas para resolver los procesos que ocurren a la escala de la surgencia costera (entre 2-6 días y de 50-80km) (Small et al., 2015; Varela et al., 2015). Por otro lado, la mayoría de los estudios que buscan comprender la variabilidad en

estos sistemas, en su mayoría utilizan técnicas lineales como por ejemplo funciones ortogonales empíricas (EOFs), análisis de correlaciones y tendencias lineales (Sonnewald et al., 2021). Estas técnicas presentan problemas como pérdida de varianza, que se traduce en disminución del poder explicativo del proceso de interés (Hannachi, 2006), lo cual no permite analizar fenómenos asimétricos, no lineales y de alta complejidad como el caso de la surgencia costera (Dommenget & Latif, 2002; von Storch & Hannoschöck, 1985).

De acuerdo con lo anterior, se evidencia que existen diversos procesos asociados al cambio climático que pueden afectar la surgencia costera. Sin embargo, la mayoría de los estudios previos se enfocan sólo en ciertos cambios de algunos pocos forzantes de la surgencia (p. ej. presión-viento y viento). Por otro lado, la cantidad y calidad de bases de datos espaciales y temporales disponible para el océano y atmósfera ha incrementado considerablemente con la disponibilidad de data satelital, junto con el desarrollo de mejores herramientas de modelación y grandes programas de observación del océano (Groom et al., 2019; Jayne et al., 2017; Jean-Michel et al., 2021; Masina et al., 2017; Muñoz-Sabater et al., 2021; Perruche, 2018; Roberts-Jones et al., 2012; Roemmich & Team, 2009). Esta información, disponible a través de repositorios internacionales de libre acceso, permite aplicar nuevas técnicas disponibles para analizar grandes volúmenes de datos, tal como las relacionadas con la inteligencia artificial. Esta tesis se implementó con el fin de comprender los resultados que puede brindar una

aproximación data-driven (Guo, 2017; Qian et al., 2019) en la comprensión del comportamiento y variabilidad de los distintos forzantes y principales variables geofísicas que regulan la surgencia costera desde una perspectiva multivariada, considerando interacciones no lineales que pueda producir el cambio climático en los principales EBUS. La información proporcionada por este análisis, permitió entender mejor las posibles consecuencias que implicarían estos cambios y pronosticar en el corto plazo este proceso.

2. HIPÓTESIS Y OBJETIVOS

Según la revisión del estado del arte presentada, la hipótesis de este estudio es:

Hipótesis 1: El cambio climático afectará los EBUS a través de tres mecanismos principales, (1) el aumento del viento favorable a la surgencia por un incremento del gradiente de temperatura océano-tierra, (2) la migración de vientos favorables a surgencia hacia los polos, debido a la migración de los anticiclones por la expansión de celdas de Hadley y (3) el aumento de la estratificación del océano por el calentamiento global.

Estos mecanismos afectarían diferencialmente a los centros de surgencia a lo largo de los EBUS en cuanto a extensión, intensidad y duración de los eventos de surgencia. En centros de latitudes bajas, la intensificación de los vientos dominaría por sobre la estratificación, por lo tanto, la surgencia se intensificaría. En centros de latitudes medias la estratificación dominaría por sobre el viento, lo cual disminuiría la intensidad de la surgencia. Hacia latitudes altas, el desplazamiento del anticiclón produciría más eventos de surgencia, de mayor duración e intensidad, expandiendo los EBUS hacia los polos.

Objetivo general:

Evaluar los cambios espaciales y temporales de la surgencia costera en los principales sistemas de borde oriental utilizando técnicas de Inteligencia Artificial.

Objetivos específicos:

1. Caracterizar los principales modos de variabilidad según las principales variables atmosféricas y oceanográficas que modulan la surgencia en los principales EBUS.
2. Determinar si la surgencia costera se está extendiendo temporalmente, intensificando o expandiendo en los diferentes EBUS en el pasado (1982-2014) y bajo el escenario climático de emisión radiativa SSP5-8.5 (2014-2050).
3. Desarrollar un algoritmo de Inteligencia Artificial que permita pronosticar la intensidad en la escala sinóptica y estacional de la surgencia costera con base en información oceanográfica y atmosférica.

3. MATERIALES Y MÉTODOS

3.1. Área de estudio

Para este proyecto se analizaron los cuatro principales sistemas de surgencia (EBUS) los cuales son el sistema de corrientes de California (CalCS) ubicado entre 130-110°W y 20-50°N al oeste de Norteamérica, Humboldt (HCS) entre 85-65°W y 0-54°S al oeste de Sudamérica, Benguela (BCS) entre 5-25°E y 10-40°S al sur oeste de África y Canarias (CanCS) entre 25-5°W y 15-45°N al noroeste de África y la península Ibérica (Figura 3.1). Los límites en latitud y longitud definidos para el estudio fueron los mismos a los descritos en el trabajo de Wang et al. (2015). Estos sistemas abarcan un amplio rango de latitudes, por lo tanto, son entornos espacialmente heterogéneos (Kämpf & Chapman, 2016b). A mayores latitudes, la surgencia se caracteriza por un marcado ciclo estacional iniciando en primavera y extendiéndose hasta el verano y principios del otoño, mientras que en invierno dominan vientos favorables al hundimiento. La duración de la temporada de surgencia aumenta progresivamente a medida que disminuye la latitud, y el afloramiento se convierte en un fenómeno que ocurre durante todo el año en las latitudes tropicales y subtropicales (García-Reyes et al., 2015; Wang et al., 2015).




Figura 3. Ubicaciones geográficas y batimetría de los cuatro sistemas EBUS considerados en este estudio: (A) Humboldt (HumCS), (B) Benguela (BenCS), (C) California (CanCS), (D) Canarias-Ibéricas (C-ICS). Datos de batimetría obtenidos de GEBCO (Dorschel et al., 2022).

3.2. Datos

Para el desarrollo del presente estudio se realizó una recopilación de información oceanográfica y atmosférica de diversas fuentes de datos, incluyendo datos de modelos, productos de análisis combinados con datos observacionales que se describen a continuación (Tabla 1).

1. **Temperatura superficial de mar (TSM):** obtenido del producto *Global Ocean OSTIA Sea Surface Temperature And Sea Ice Reprocessed* (OSTIA) para el período 1993-2019. Este producto combina información satelital (ESA SST CCI, C3S EUMETSAT y REMSS) con datos in situ (HadIOD) con resolución espacial de $0.05^\circ \times 0.05^\circ$ y temporal diaria (Good

et al., 2020). Los datos se encuentran disponibles en <https://doi.org/10.48670/moi-00168>. Este producto se ha utilizado en diferentes estudios asociados al océano a nivel global y regional (Donlon et al., 2012; Roberts-Jones et al., 2012; Stark et al., 2007). Por otra parte, se utilizaron datos de TSM del producto NOAA OI SST V2 High Resolution Dataset, el cual es una combinación de información satelital e información observacionales creado por la NOAA, con resolución espacial de $0.25^{\circ} \times 0.25^{\circ}$ y temporal diaria (Reynolds et al., 2007). Los datos se encuentran disponibles en <https://psl.noaa.gov/data/gridded/data.noaa.oisst.v2.highres.html>. Este producto se ha utilizado previamente en diversos estudios del océano global y regional (Gelaro et al., 2017; Huang et al., 2017; Saha et al., 2010, 2014)

2. **Salinidad superficial, altura de la superficie del mar (SSH, por su siglas en inglés), profundidad de la capa de mezcla (MLD, por sus siglas en inglés) y corrientes superficiales (u,v)** del producto *Global Ocean Ensemble Physics Reanalysis* para el período 1993-2019. Este producto corresponde a un promedio o “ensemble” de productos de reanálisis oceánicos globales que incluye GLORYS2V4 de Mercator-Francia, ORAS5 de ECMWF-Europa, GloSea5 de la Met Office-UK y C-GLORS05 del CMCC-Italia, con asimilación de datos de observaciones 3D y satélites. Este promedio puede incluso proporcionar, para ciertas

regiones y/o períodos, una estimación más confiable que cualquier producto de reanálisis individual (Storto & Masina, 2016) con resolución espacial (temporal) de $0.25^{\circ} \times 0.25^{\circ}$ (diaria) el cual se encuentra disponible en <https://doi.org/10.48670/moi-00024>. Este producto ha sido utilizado en diferentes estudios asociados al océano en diferentes escalas temporales y espaciales (de Souza et al., 2021; Storto & Masina, 2016)

3. **Viento (u,v), rotor y estrés del viento** del producto *Global Ocean Wind L4 Reprocessed 6 hourly Observations* para el período 1993-2019 producido por el centro CMEMS Ifremer como resultado del procesamiento de diferentes misiones satelitales (ERS-1, ERS-2, QuikSCAT, RapidScat, EUMETSAT OSI, ASCAT-A, ASCAT-B, HY-2A y OceanSat-2), sistemas de sensores remotos (SSM/I SSMIS, y WindSat) y reanálisis (Bentamy et al., 2007) con resolución espacial (temporal) $0.25^{\circ} \times 0.25^{\circ}$ (diaria) disponible en: <https://doi.org/10.48670/moi-00185>. Este producto ha sido utilizado en estudios asociados al océano, mostrando un buen desempeño en general (Desbiolles et al., 2017; Kent et al., 2012).
4. **Clorofila y Oxígeno disuelto** del producto *Global ocean biogeochemistry hindcast*, el cual es un hindcast biogeoquímico del océano global en el período 1993-2019 producido por Mercator-Francia que utiliza el modelo PISCES junto con el modelo oceánico NEMO (Perruche, 2018) con resolución espacial (temporal) de $0.25^{\circ} \times 0.25^{\circ}$ (diaria) disponible en: <https://doi.org/10.48670/moi-00024>. Este producto se ha utilizado para

realizar análisis de condiciones biogeoquímicas en el océano (Doney et al., 2003, 2009). También se utilizaron datos de clorofila del proyecto Ocean Colour en el período 1997-2019 para el caso de la clorofila (Groom et al., 2019) con el fin de validar los resultados del producto Hindcast mencionado anteriormente.

5. **Presión atmosférica, temperatura del aire y radiación incidente** del *European Centre for Medium-Range Weather Forecasts Reanalysis v5 (ERA5)* en el período 1993-2019 como fuente de datos independiente para evaluar el comportamiento de los modelos del CMIP6 y para analizar el comportamiento de la presión atmosférica y temperatura superficial del aire (Muñoz-Sabater et al., 2021). Este producto tiene una resolución espacial (temporal) de $0.25^{\circ} \times 0.25^{\circ}$ (diaria) y se encuentra disponible en: <https://cds.climate.copernicus.eu/>. También se utilizaron datos del producto OAflux (L. Yu & Weller, 2007) para validar la radiación incidente de ERA5 ya que a los modelos les es difícil reproducir la capa de nubes bajas característica de los EBUS (Thandlam & Rahaman, 2019).
6. **Temperatura, salinidad y densidad, clorofila y oxígeno** de *perfiladores ARGO* en el período 2002-2019 de parámetros físicos en la columna de agua como además de parámetros biológicos como el cual es un proyecto desarrollado por CLIVAR y el Experimento Global de Asimilación de Datos Oceánicos (GODAE) desde finales de los años 90, como una iniciativa internacional para el monitoreo de condiciones oceanográficas (Roemmich

& Team, 2009; Wong et al., 2020). Este tipo de datos se ha utilizado ampliamente en diferentes estudios para la validación de parámetros oceanográficos de modelos y productos de análisis a lo largo de todo el mundo (Acreman & Jeffery, 2007; Banks et al., 2011).

7. **Viento, salinidad, TSM, y presión atmosférica** de 5 *Modelos de CMIP6* (Tabla 1) del experimento HighResMIP (Haarsma et al., 2016a) en dos períodos (Experimento hist-1950) el cual representa las condiciones del presente y 2014-2050 (Experimento highres-future) que representa el período de proyección. Los modelos elegidos cuentan con una resolución espacial (temporal) de ~25-50km (diaria). Se accedió y descargaron los datos por medio del sistema ESFG <https://esgf-node.llnl.gov/search/cmip6/>.
8. **Temperatura, salinidad, densidad y viento** registrados por el *Instituto de Fomento Pesquero (IFOP)* sobre la actividad pesquera extractiva entre el período 1996-2019 con información de variables físicas, disponibles a través del siguiente repositorio <https://www.ifop.cl/en/busqueda-de-informes/>.
9. **Profundidad de la capa de mezcla (MLD)** del producto *Argo Mixed Layers* con climatología a nivel global que cuenta con cerca de 2.5 millones de perfiles Argo recopilados entre enero de 2000 y marzo de 2021 de acuerdo a la metodología propuesta por (de Boyer Montégut et al., 2004;

Holte & Talley, 2009). La información se encuentra disponible en <http://mixedlayer.ucsd.edu/>.

Tabla 1. Fuentes de datos y detalles sobre las variables utilizadas en esta tesis.

Nombre	Descripción	Periodo	Variables	Resolución espacial	Resolución diaria
Global Ocean OSTIA Sea Surface Temperature And Sea Ice Reprocessed (OSTIA)	Satelites (ESA SST CCI, C3S EUMETSAT y REMSS) e in situ (HadIOD) creado por el sistema OSTIA (Operational SST and Ice Analysis)	1993-2019	TSM	0.05°x0.05°	Diaria
Multi-scale Ultra-high Resolution Sea Surface Temperature (MUR)	Satelites (AMSR-2, MODIS, WindSat, AVHRR) e in situ de boyas y barcos	2002-2023	TSM	0.05°x0.05°	Diaria
NOAA OI SST V2 High Resolution Dataset	Satelites (AVHRR, AMSR) e in situ (ICOADS) creado por la NOAA	1982-2019	TSM	0.25°x0.25°	Diaria
Global Ocean Ensemble Physics Reanalysis	Reanálisis oceánicos globales (GLORYS2V4 de Mercator-Francia, ORAS5 de ECMWF-Europa, GloSea5 de la Met Office-UK y C-GLORS05 del CMCC-Italia) + observaciones+ satélites	1993-2019	Salinidad, MLD y Corrientes (u,v)	0.25°x0.25°	Diaria
Global Ocean Wind L4 Reprocessed 6 hourly Observations	Satelites (ERS-1, ERS-2, QuikSCAT, RapidScat, EUMETSAT OSI, ASCAT-A, ASCAT-B, HY-2A y OceanSat-2), sistemas de	1993-2019	Viento (u,v)	0.25°x0.25°	Diaria

	sensores remotos (SSM/I SSMIS, y WindSat) y reanálisis				
Global ocean biogeochemistry hindcast	Hindcast biogeoquímico del océano global Mercator-Francia, modelo PISCES + NEMO	1993-2019	Clorofila y Oxígeno	0.25°x0.25°	Diaria
Global ocean colour	Información satelital de Clorofila	1997-2019	Clorofila	0.01°x0.01°	Diaria
European Centre for Medium-Range Weather Forecasts Reanalysis v5 (ERA5)	Producto de reanálisis atmosférico producido por el ECMWF	1993-2019	Presión atmosférica Radiación Temperatura ambiente	0.25°x0.25°	Diaria
Objectively Analyzed air-sea Fluxes for the global oceans	Ensamble de satélites y reanálisis atmosféricos	1958-2012	Radiación	1°x1°	Diaria
5 Modelos CMIP6 - Highers	Producido por IPCC AR6. Dos experimentos: hist-1950 (condiciones presentes) y highres-future (2015-2100)	1982-2014 2015-2050	TSM, Salinidad, Viento (u,v), Presión atmosférica	50km	Diaria
Series de tiempo de desembarques	Producido por IFOP a través de Anuarios Estadísticos de Pesca	1996-2019	T,S,D, Viento	Puertos (Puntual)	Mensual
Datos de perfiladores ARGO	Producido por el programa ARGO en colaboración con CLIVAR y GODAE	2002-2019	T,S,D, Oxígeno, Clorofila	1°x1°	Mensual

3.3. Procesamiento de datos

A continuación se detalla el procesamiento y análisis de la información presentada en la sección 3.2, separada de acuerdo a los objetivos planteados.

Objetivo específico 1: Caracterizar los principales modos de variabilidad según las principales variables atmosféricas y oceanográficas que modulan la surgencia en los principales EBUS.

De los productos mencionados en la sección 3.2, se seleccionaron el viento, presión y temperatura atmosférica, radiación de onda corta, corrientes, TSM, salinidad, oxígeno, clorofila, altura de nivel del mar, rotor y estrés del viento, como las principales variables oceanográficas y meteorológicas debido a que con ellas se puede analizar el comportamiento de los principales forzantes físicos (viento y presión) que controlan la surgencia costera (Rykaczewski et al., 2015) e identificar variaciones en las principales condiciones atmosféricas (deCastro et al., 2008), oceánicas (Aguirre et al., 2012) y biológicas (Montecino & Lange, 2009) en distintas escalas espacio-temporales dentro de los principales EBUS. Estos datos tienen distinta resolución espacial, por lo que se interpolaron a una grilla rectangular de $0.25^{\circ} \times 0.25^{\circ}$ por medio de una interpolación bilineal, la cual evita problemas de extrapolación. Este método se ha utilizado ampliamente en diferentes estudios del océano y la atmósfera y ha demostrado ser sencillo de implementar con alta eficiencia computacional (K.-H. Kim et al., 2019). De esta

manera se garantiza preservar la naturaleza sinóptica (2-6 días) de la surgencia y su escala espacial (<30km) (Aguirre et al., 2019).

Las variables oceanográficas de modelos y reanálisis fueron validadas en los primeros 500m con datos de los perfiladores ARGO en la escala estacional. Se compararon datos superficiales y transectas longitudinales y latitudinales en cada sistema de surgencia mediante diagramas de Taylor. Por otro lado, los productos del Hindcast biogeoquímico fueron validados utilizando datos de los perfiladores bioquímicos de ARGO para el oxígeno en los primeros 300m e imágenes de satélites del proyecto Ocean Colour en el período 1997-2019 para el caso de la clorofila (Groom et al., 2019). Adicionalmente los datos de cruceros oceanográficos del IFOP se utilizaron en las validaciones cerca de la costa donde no se cuenta con alta disponibilidad de datos en las boyas ARGO.

Posteriormente se generó una climatología estacional con las variables elegidas para cada sistema utilizando los 27 años de datos disponibles, generando una descripción del régimen promedio para cada EBUS.

Para la obtención de los principales modos de variabilidad se aplicó una técnica de inteligencia artificial conocida como Self-Organized-Maps (SOM) con dos variantes (univariada y multivariada). Este método, propuesto por Kohonen (1982), ha sido aplicado en estudios de la atmósfera y el océano (Sonnewald et al., 2021) y consiste en una técnica de aprendizaje no supervisada que se

fundamenta en el uso de redes neuronales artificiales, utilizando aprendizaje competitivo con el fin de descubrir patrones no lineales en datos unidimensionales o bidimensionales (Qian et al., 2019). A través de los nodos que constituyen la estructura topológica de la red se pueden detectar los diferentes modos de variabilidad predominantes. Esta metodología se ha aplicado en diferentes estudios con el fin de extraer características espacio temporales en corrientes oceánicas, temperatura y salinidad (Arnault et al., 2021; Liu et al., 2006). Por otro lado, el uso de esta técnica ha demostrado tener un alto poder discriminante (diferenciación entre grupos de datos) y habilidad para poder lidiar con aspectos no lineales de fenómenos biofísicos en comparación con otras metodologías del aprendizaje automático como el K-means (Badran et al., 2005) o estadísticas como las Funciones Empíricas Ortogonales (Jouini et al., 2016; North, 1984).

Un esquema general del modelo a implementar se puede observar en la Figura 4, donde para cada momento del tiempo se asocia el patrón espacial de la variable de entrada a un único nodo que agrupa patrones similares por medio de métricas de similitud. La versión implementada del S-SOM fue la propuesta por (Doan et al., 2021), en la cual se encuentra la Best Matching Unit (BMU) por medio de un nuevo índice de similitud denominado S-SIM (Wang et al., 2004) que permite trabajar con datos estructurales en dos dimensiones. Este índice está compuesto de tres medidas: luminancia que representa la similitud en el brillo, el

contraste que cuantifica la variabilidad en la iluminación y la estructura que mide la correlación en dependencias espaciales para imágenes (Wang & Bovik, 2009). Adicionalmente al algoritmo S-SOM se utilizaron las versiones ED-SOM (Distancia Euclideana), COR-SOM (Correlación), LUM-SOM (Luminosidad) y CNT-SOM (Contraste), con distintas métricas de distancia para calcular la interdependencia espacial, esto con el fin de identificar cual estructura tiene mejor desempeño ante los datos.




Figura 4. Esquema metodológico de configuración de algoritmo SOM univariado. Los vectores de entrada representan a las variables cada día entre 1993-2019 utilizando en 4 estaciones distintas: DJF (Diciembre–Enero–Febrero), MAM (Marzo–Abril–Mayo), JJA (Junio–Julio–Agosto) y SON (Septiembre–Octubre–Noviembre).

En el proceso de entrenamiento del algoritmo se utilizaron tres métricas para medir el desempeño: la primera denominada “score de silhouette” que permite interpretar y validar la consistencia de los datos dentro de cada conjunto o “cluster” midiendo cohesión dentro de cada clúster (Rousseeuw, 1987), la segunda llamada error de cuantización, que provee un indicador confiable de cambios potencialmente críticos en la estructura espacial a lo largo del tiempo (Sun, 2000) y la tercera denominada error topológico que permite cuantificar la preservación geométrica de las estructuras dominantes (Gibson et al., 2017). Estas tres métricas son recomendables y ampliamente usadas para validar el desempeño del algoritmo SOM (Liu et al., 2006; Aslam et al., 2020).

Luego de implementar la variante univariada se procedió a la interpretación de los principales modos de variabilidad para cada estación del año en los cuatro sistemas de surgencia analizados (Sección 3.1). Una vez terminada la fase univariada se procedió al análisis multivariado, el cual es una generalización del esquema univariado. El esquema general para este caso se puede observar en la Figura 5. Los datos de entrada consistieron en información diaria de las variables descritas en la sección 3.1 concatenadas en un vector X_t para $t = 1, \dots, n$ con n representando el número de días analizados según cada región de estudio.




Figura 5. Esquema metodológico de configuración de algoritmo SOM. Los vectores de entrada representan a todas las variables como vectores para cada día entre 1993-2014 en 4 estaciones distintas: DJF (Diciembre–Enero–Febrero), MAM (Marzo–Abril–Mayo), JJA (Junio–Julio–Agosto) y SON (Septiembre–Octubre–Noviembre). La topología de la red puede ser cuadrada ($n \times n$) o rectangular ($n \times m$) con $n, m = 1, 2, 3, 4, 5$

Posteriormente, se identificó la mejor configuración de la red utilizando las métricas de error topológico y error de cuantización buscando obtener los mejores resultados de segmentación siguiendo la metodología establecida por (Jebri et al., 2022). Lo anterior permitió la extracción de modos de variabilidad dominantes junto con su duración relativa en el período de estudio analizado (Jouini et al., 2016; Y. Liu et al., 2006). Cada uno de estos modos de variabilidad representan señales dinámicas del comportamiento dominante para el proceso de estudio. La ventaja de aplicar esta metodología radica en que se pueden

capturar patrones diferentes a los obtenidos con medias y tendencias que por lo general tienen efectos de suavizamiento que enmascaran una gran variabilidad del fenómeno de interés (Jouini et al., 2016; Kohonen, 1982).

Luego de esto se seleccionaron los centros de surgencia más importantes de cada sistema siendo para el sistema de Humboldt, Antofagasta, Mejillones, Concepción, Valparaíso y Coquimbo Thiel et al. (2007); para California, las puntas Arena, Reyes, Año nuevo y Concepción (Chase et al., 2005); para Canarias, Cabos Silleira, Beddouza, St. Vincent y Blanc (Aristegui et al., 2009); para Benguela, Cabo Frío, Bahía Walvis, Luderitz, Namaqualand, Bahía Santa Elena y Cape Town (Kämpf & Chapman, 2016b). Posteriormente se utilizaron las características obtenidas para los patrones de variabilidad que más contribuyen a la varianza total. Se promediaron modos de variabilidad que presentaron condiciones similares y luego se generaron categorías ilustrativas con 3 factores posibles de acuerdo con la distribución de los percentiles 33 y 66 para cada variable (Bajo: P0-P33, Medio: P33-P66 y Alto: P66-P100) con Px indicando el percentil x% para la distribución analizada.

Las categorías ilustrativas creadas junto con los valores de las variables oceanográficas y atmosféricas permitieron caracterizar los principales centros de surgencia para cada sistema utilizando técnicas de reducción de dimensionalidad y clustering como:

1. **Análisis de correspondencias múltiples (ACM):** que corresponde a un método de tipo descriptivo con aplicaciones en diversos campos de la ciencia que funciona con variables categóricas (Khangar & Kamalja, 2017).
2. **Análisis Factorial Múltiple (MFA):** método de tipo descriptivo para resumir y visualizar una tabla de datos compleja en la que las muestras se describen mediante varios conjuntos de variables (cuantitativas y/o cualitativas) estructuradas en grupos. Tiene en cuenta la contribución de todos los grupos activos de variables para definir la distancia entre muestras (Escofier & Pagès, 1994).
3. **Uniform Manifold Approximation and Projection for Dimension Reduction (UMAP):** técnica de aprendizaje múltiple para la reducción de dimensiones numéricas que se construye a partir de un marco teórico basado en la geometría Riemanniana y la topología algebraica generando algoritmo escalable práctico que se aplica a datos del mundo real con muchas aplicaciones en la ingeniería y la ciencia (Milošević et al., 2022).

Adicionalmente, para poder identificar el rol de la posición de los anticiclones subtropicales en la configuración de los modos de variabilidad obtenidos previamente se procedió a implementar en algoritmo sugerido por Gilliland & Keim (2018) con el fin de detectar la posición central diaria

de los anticiclones subtropicales del Pacífico Norte (100°W - 170°W y 10 - 50°N) según Choi et al. (2016), Pacífico Sur (140°W - 65°W y 15 - 50°S) según Pizarro A et al. (1994), Atlántico Norte (80°W - 0°E y 15 - 50°N) según Hasanean (2004) y Atlántico Sur (10° - 50°S y 60°W - 20°E) según Gilliland & Keim (2018). Este algoritmo permite que no sea necesario utilizar información mensual de presión atmosférica ya que resuelve los problemas que surgen debido a la presencia de anticiclones migratorios y centros de presión fragmentados que pueden enmascarar la posición central real de los anticiclones subtropicales sugeridos en trabajos previos (Blender & Schubert-Frisius, 2000; Murray & Simmonds, 1991; Salcedo-Castro et al., 2015; Sinclair, 1996; Wernli & Schwierz, 2006). Este algoritmo consiste en 6 etapas que se describen a continuación:

- **Fase 1:** se calcula el valor medio de presión atmosférica basado en los límites de latitud y longitud iniciales definidos previamente.
- **Fase 2:** se seleccionan los nodos que son mayores que el promedio diario para su posterior procesamiento.
- **Fase 3:** se repite el procedimiento de la segunda fase con los nodos resultantes de la fase 2.
- **Fase 4:** se repite el procedimiento de la tercera fase con los nodos resultantes de la fase 3.

- **Fase 5:** se eligen los nodos resultantes de la fase 4 con una desviación estándar por encima de la media.
- **Fase 6:** se promedian las coordenadas de los nodos resultantes de la fase 5 para encontrar la posición final diaria de los anticiclones.

Luego de tener las coordenadas diarias de posición central se calcularon tendencias latitudinales y longitudinales de movimiento por año y por década en el período de tiempo analizado con el fin de identificar el movimiento relativo de los anticiclones subtropicales en cada sistema. Finalmente se calculó la posición central de los anticiclones para cada modo de variabilidad calculando el transporte de Ekman zonal por cada 0.25° de latitud se cuantificaron la variaciones latitudinales y extensión espacial de la surgencia costera según cada modo de variabilidad. Para el cálculo del transporte zonal meridional se siguió la metodología propuesta por Varela et al. (2015) utilizando la isóbata de 200m para el cálculo del ángulo proyectado sobre la costa utilizando datos de GEBCO (Dorschel et al., 2022).

Objetivo específico 2: Determinar si la surgencia costera se está extendiendo temporalmente, intensificando o expandiendo en los diferentes EBUS en el pasado (1982-2014) y bajo el escenario climático de emisión radiativa SSP5-8.5 (2014-2050)

Se utilizaron los resultados del proyecto de intercomparación HighResMIP (Haarsma et al., 2016a) seleccionando dos escenarios: hist-1950 (1982-2014) que representa el presente y highres-future (2015-2050) que representa el futuro bajo una tasa de emisión radiativa de 8.5 Wm^2 . Los modelos utilizados se ilustran en la Tabla 2. Las variables seleccionadas fueron presión atmosférica a nivel del mar (psl), componentes de viento (u,v), temperatura superficial del mar (tos) y salinidad superficial (sos), el criterio de selección de los modelos fue el de seleccionar aquellos que tengan una resolución oceánica $< 25\text{km}$ y que cuenten con resolución temporal diaria. Luego de esto se procedió a filtrar los datos según los límites de latitud y longitud descritos en la Figura 1 de cada región de estudio para luego construir un ensamble de los modelos (MMM, por sus siglas en inglés); para esto se tuvo cuenta el modelo con resolución más gruesa en el componente oceánico y atmosférico con el fin de no cometer errores de extrapolación.

Posteriormente se realizó un proceso de validación utilizando diagramas de Taylor para cada variable elegida: viento con el producto Global Ocean Wind L4 Reprocessed 6 hourly Observations, TSM con el producto NOAA OISST y MODIS, Salinidad con el producto Global Ocean Ensemble Physics Reanalysis

y presión atmosférica con datos de ERA5 (Sección 3.2). El objetivo se centró en detectar señales de surgencia y caracterizarlas en términos de intensidad, frecuencia y duración de los eventos de surgencia; para ello se siguió la metodología propuesta por Abrahams et al. (2021a).

La primera fase consistió en la detección de eventos de surgencia; para ello se utilizaron dos criterios que se mencionan a continuación: 1) índice de surgencia propuesto por Fielding (1989), dado por la ecuación (1) donde μ representa la velocidad del viento en ms^{-1} , θ la dirección del viento en grados y τ la orientación de la línea de costa; este índice se fundamenta en la velocidad y dirección del viento para identificar condiciones favorables para la surgencia y 2) valores de TSM inferiores al percentil 25 de la distribución estacional, de esta manera se logró identificar de una mejor manera los eventos de surgencia como lo sugiere Abrahams et al. (2021a).

$$UI = \mu (\cos \theta - \tau) \quad (1)$$

Teniendo en cuenta los criterios anteriores, se utilizó la función para identificar olas de calor marinas *detect_event* de la librería *heatwaveR* creada por (Hobday et al., 2016), adaptada a Python. Esta función también permite identificar olas de frío marino (o eventos de baja TSM) bajo el criterio de valores por debajo del percentil 25 en la distribución de TSM y valores de UI favorables a la surgencia (Abrahams et al., 2021a). Estos eventos fríos se pueden utilizar para identificar

el número de eventos de surgencia por año (n), la intensidad media como promedio de anomalías de temperatura durante señales de surgencia ($^{\circ}\text{C}$) y la intensidad acumulada como la suma de las anomalías durante el período de la señal ($^{\circ}\text{C}$ días). De igual forma que con la TSM, se puede trabajar con información de Salinidad y viento para identificar períodos de relajación o intensificación de estas variables. Para el cálculo de los eventos se utilizaron los píxeles más cercanos a la costa.

Se calcularon tendencias para los dos períodos de análisis (1982-2014 y 2015-2050) con el fin de entender cómo fluctuarán el comportamiento de TSM y viento en la escala interanual con énfasis en el verano austral (DJF) y boreal (JJA), esto se logró debido a que se contó con información de más de 30 años considerando los períodos analizados entre 1982 y 2050, lo que permitió calcular tendencias evitando las fluctuaciones estacionales y presencia de ruido interanual (Hobday et al., 2018).

Objetivo específico 3: Desarrollar un algoritmo de Inteligencia Artificial que permita pronosticar la intensidad en la escala sinóptica y estacional de la surgencia costera con base en información oceanográfica y atmosférica

Se utilizaron diversos conjuntos de datos de teledetección incluyendo (1) La TSM se obtuvo del producto *Multi-scale Ultra-high Resolution* (MUR), con una resolución espacial de $0.01^{\circ} \times 0.01^{\circ}$ (1 km) y resolución diaria desde el 1 de junio

de 2002 hasta el 31 de diciembre de 2023. (2) El producto *Operational Sea Surface Temperature and Sea Ice Analysis* (OSTIA), desarrollado originalmente por la Met Office, que cuenta con una resolución espacial de $0.05^\circ \times 0.05^\circ$ (5 km) y resolución diaria desde el 30 de septiembre de 1981 hasta el 3 de julio de 2025. (3) El producto *C3S global Sea Surface and Sea Ice Temperature* (C3S), con una resolución espacial de $0.05^\circ \times 0.05^\circ$ (5 km) y resolución diaria desde el 31 de agosto de 1981 hasta el 30 de diciembre de 2024 (Tabla 1). (4) Datos atmosféricos como la temperatura del aire (TA), la radiación de onda corta (QSW), la presión a nivel del mar (PSL) y la componente meridional del viento a 10m de altura (V10) se obtuvieron del reanálisis atmosférico ERA5 del ECMWF, con una resolución de $0.25^\circ \times 0.25^\circ$ (25 km) para el período de 1993 a 2023 (Tabla 1). (5) Los datos de viento se extrajeron del conjunto de datos horarios *Global Ocean Sea Surface Wind and Stress* (WIND_GLOB), con una resolución de $0.125^\circ \times 0.125^\circ$ (12.5 km), disponible desde el 31 de mayo de 1994 hasta el 21 de agosto de 2024. Adicionalmente, para validar los resultados de MUR, se utilizó el (6) *Moderate Resolution Imaging Spectroradiometer* (MODIS), empleando los datos globales grillados (L3) de temperatura superficial *skin* de la NASA, con resolución diaria de 4 km y registros diurnos y nocturnos, abarcando desde el 3 de julio de 2002 hasta el 31 de diciembre de 2023. La validación se llevó a cabo mediante diagramas de Taylor y mapas de comparación espacial.

Posteriormente se procedió a identificar la Configuración Óptima del Modelo (OMC, por sus siglas en inglés) lo cual consistió en evaluar la capacidad predictiva de diversos modelos de Deep Learning basándose en una combinación de cinco variables de entrada promediadas diariamente (TSM, PSL, QSW, TA y V10), tres resoluciones espaciales (5, 12.5 y 25 km) y cinco arquitecturas de aprendizaje profundo (ConvLSTM, 3D-CNN-LSTM, IRSTN, TCN y U-Net) utilizando el Error Cuadrático Medio (RMSE, por sus siglas en inglés) como métrica de referencia. Inicialmente, y en función de la disponibilidad de los datos, se realizaron diferentes experimentos permutando entre las variables y la resolución espacial; posteriormente, para los mismos experimentos, se emplearon distintos modelos de aprendizaje profundo con el fin de encontrar la arquitectura más adecuada para pronosticar la temperatura superficial del mar.

Para estandarizar las resoluciones temporales entre los diferentes conjuntos de datos, el período de análisis se restringió del 1 de junio de 2002 al 31 de diciembre de 2023 (7884 muestras). Los datos se dividieron en un 70% (5850 días) para el entrenamiento del modelo, incluyendo la validación cruzada (una técnica en la cual los datos de entrenamiento se dividen en varias partes para probar el modelo en diferentes subconjuntos, lo que ayuda a verificar su desempeño frente a datos nuevos no observados previamente), y un 30% (2034 días) para la prueba de rendimiento predictivo. Cada experimento consistió en utilizar los 7 días previos

para pronosticar los 7 días siguientes, y el rendimiento (mediante la métrica de error RMSE) se estimó para cada día en cada punto del dominio.

Para determinar la mejor configuración, se seleccionaron tres resoluciones espaciales experimentales: 25 km, 12.5 km y 5 km. La escala de 25 km incluyó las variables TSM, TA, QSW, PSL y V10 de ERA5 (81.50–69.75 °W, 39.75–20.00 °S), probándose 16 permutaciones de variables en las que la TSM se utilizó como variable dependiente. La escala de 12.5 km empleó la TSM y V10 (80.06–70.19 °W, 38.94–21.06 °S), lo que resultó en dos combinaciones. La escala de 5 km implicó una configuración única utilizando los datos de TSM del producto MUR (74.01–70.24 °W, 38.8–22.17 °S). Finalmente, se llevaron a cabo cuatro experimentos adicionales combinando modelos de DL con Modelos de Lenguaje Grandes (LLMs) utilizando los datos de TSM de MUR para analizar los principales centros de surgencia (pronóstico puntual, usando los datos del nodo más cercano disponible de MUR): Mejillones (71.07–70.28 °W, 24.50–22.50 °S), Coquimbo (72.06–71.27 °W, 30.48–28.73 °S), Valparaíso (72.21–71.42 °W, 33.96–32.21 °S) y Concepción (73.37–72.58 °W, 37.25–35.50 °S).

Las técnicas de Deep Learning abarcan una amplia gama de metodologías adecuadas para su uso en modelos de pronóstico oceánico, desde enfoques más sencillos basados en Redes Neuronales Artificiales clásicas para la predicción de series temporales (Patil & Deo, 2017; J. Taylor & Feng, 2022), hasta arquitecturas

más avanzadas como: redes de Memoria a Corto y Largo Plazo (LSTM) (H.-M. Choi et al., 2023), Redes Neuronales Convolucionales (CNN) (Wei & Guan, 2022), Redes Neuronales Recurrentes (RNN) (Song et al., 2020) y enfoques híbridos como las redes Convolucionales de Memoria a Corto y Largo Plazo (ConvLSTM) (Fei et al., 2022) o los modelos tipo Transformer (Fu et al., 2024).

Además, las arquitecturas de red encoder-decoder en forma de U (U-Net) (Ren et al., 2024) y las Unidades Recurrentes con Compuertas (GRUs) (Yu et al., 2020) se han utilizado previamente para tareas distintas pero complementarias en la predicción de la temperatura superficial del mar (TSM). Las redes U-Net se aplican principalmente para el pronóstico espacial, prediciendo campos bidimensionales completos de TSM al capturar patrones espaciales complejos, mientras que las GRUs se emplean para el pronóstico de series temporales, prediciendo cambios de TSM en ubicaciones específicas e individuales mediante el aprendizaje de dependencias temporales a largo plazo.

De todas las variantes presentadas, alternativas como las redes neuronales convolucionales encoder-decoder U-Net y U-Net-LSTM han demostrado un rendimiento predictivo superior con un menor número de parámetros en comparación con otras arquitecturas de DL (Larraondo et al., 2019), particularmente en tareas que implican el pronóstico de campos espaciales 2D. Su fortaleza radica en su capacidad para capturar y reconstruir eficientemente

patrones espaciales complejos y características multiescala, lo que las hace altamente efectivas para aplicaciones como la predicción de mapas de temperatura superficial del mar o de anomalías del nivel del mar.

Se evaluaron cinco técnicas de DL diferentes en las cuatro escalas experimentales descritas en la sección anterior:

1. ConvLSTM, como modelo recurrente fundamental capaz de preservar la estructura espacial en datos de tipo grilla (Shi et al., 2015).
2. 3D-CNN-LSTM, para evaluar un enfoque desacoplado donde las convoluciones 3D extraen primero características de movimiento a corto plazo, antes de que una LSTM modele patrones temporales a más largo plazo (Wang et al., 2019).
3. IRSTN, para evaluar la capacidad del modelo para capturar las dependencias no locales y de largo alcance características de la dinámica oceánica a gran escala, una limitación conocida en otros modelos (Kim et al., 2018).
4. TCN, por su eficiencia y capacidad para capturar patrones temporales de largo alcance utilizando convoluciones dilatadas no recurrentes (M. Liu et al., 2021).

5. U-Net, por su probada excelencia en la reconstrucción de campos espaciales detallados y multiescala, un requisito crítico para predecir mapas oceánicos 2D (Ronneberger et al., 2015).

Los eventos de surgencia durante el período de estudio se identificaron siguiendo la metodología propuesta por Bustos et al. (2024), la cual se basa en el trabajo previo de Abrahams et al. (2021b). Para derivar el índice de surgencia, primero se eliminó el gradiente de temperatura dominante norte-sur de los campos de TSM utilizando la herramienta *grdtrend* de las Herramientas de Mapeo Genérico (GMT, por sus siglas en inglés) (Wessel et al., 2019), aislando así la variabilidad de mesoescala relevante para las fluctuaciones de la surgencia. La reducción de ruido se logró mediante un promedio de ventana deslizante (tamaño de ventana $W=5$), para mejorar la visibilidad de las señales de surgencia.

Para acentuar aún más el gradiente este-oeste de la TSM, que es crítico para detectar la surgencia costera, se normalizaron los valores de TSM a lo largo de las transectas perpendiculares a la línea de costa, un paso que también mitiga el riesgo de sobre segmentación en la subsiguiente clasificación no supervisada. La segmentación de las regiones de surgencia se realizó posteriormente utilizando el algoritmo de Agrupamiento de Bordes Sembrados Espacio-Temporal (STSEC, por sus siglas en inglés) (El Aouni et al., 2020; Nascimento et al., 2015). Para cada región extraída, se calcularon métricas como el área (en mi^2) y la TSM

promedio (en °C). Finalmente, la intensidad de la surgencia se clasificó utilizando los deciles de TSM de la región extraída, donde el decil 1 corresponde a la TSM más alta y el decil 10 a la más baja, proporcionando así un índice cuantitativo de la intensidad y extensión espacial de la surgencia. Se proporciona una representación esquemática de estos pasos en la Figura 6.




Figura 6. Flujo de procesamiento para la detección de surgencia costera a partir de datos de TSM, que ilustra la secuencia de transformación: desde el producto de TSM utilizado, pasando por la eliminación del gradiente Norte-Sur, la acentuación del gradiente Este-Oeste, la segmentación STSEC, hasta la derivación final del índice de surgencia.

El rendimiento del índice se validó utilizando todos los días del periodo de validación con eventos de surgencia de las estaciones de primavera y verano del conjunto de datos de prueba (entre el 07-09-2019 y el 31-12-2023). Esta evaluación implicó la comparación de los campos de TSM pronosticados con los valores observados. Se utilizó un conjunto de métricas para evaluar tanto la correlación como las discrepancias topológicas (geometría y estructura). Métricas

clásicas, como la correlación (CORR) y la puntuación F1 (F1), cuantificaron el grado de alineación en los deciles.

Para evaluar las variaciones topológicas, se aplicaron tres métricas: el índice de similitud estructural (SMI), que examina las diferencias distribucionales en términos de media y varianza (Wang et al., 2004); el Índice de Jaccard (JI), que mide la proporción de nodos pronosticados que se superponen con las geometrías de surgencia observadas (Real & Vargas, 1996); y la diferencia porcentual (DIF %), que calcula la fracción de nodos ausentes en la matriz pronosticada en relación con la matriz observada.

Finalmente se utilizó un enfoque diferente para generar pronósticos unidimensionales cuando solo se disponía de una serie de tiempo de un solo nodo: se emplearon dos Modelos de Lenguaje Grandes (LLMs), Chronos y Lag-Llama, respectivamente, para cada centro de surgencia seleccionado. Chronos aprovecha arquitecturas de modelos de lenguaje existentes, como el *Transformer de Transferencia de Texto a Texto de Google (T5)*, para el pronóstico de series temporales sin requerir ajustes específicos del dominio (Ansari et al., 2024). Existen varias arquitecturas disponibles para este modelo, incluyendo las versiones *Tiny*, *Mini*, *Small*, *Base* y *Large*. Notablemente, se obtuvieron resultados superiores con la versión *Large*, lo cual es previsible dado su mayor

número de parámetros. Por otro lado, Lag-Llama sirvió como un modelo fundacional para el pronóstico probabilístico univariado, entrenado sobre un conjunto diverso de datos de series temporales (Rasul et al., 2023).

A diferencia de la configuración de pronóstico espacial descrita en secciones anteriores, donde se probaron diferentes puntos de la malla para cada región de surgencia, este enfoque 1D está diseñado específicamente para operar con una única ubicación. Esta elección es deliberada, ya que tanto Chronos como Lag-Llama están inherentemente diseñados para el pronóstico de un solo nodo, evitando así la necesidad de evaluar múltiples entradas espaciales.

Para cada centro de surgencia (Mejillones, Coquimbo, Valparaíso y Concepción), los dos modelos fueron entrenados utilizando los datos de TSM de MUR de las coordenadas más cercanas, aprovechando el registro temporal completo. La validación se realizó utilizando una ventana diaria deslizando, actualizada continuamente durante la fase de prueba, siguiendo el mismo enfoque de Bustos Usta et al. (2025). El objetivo principal de esta implementación fue evaluar la eficacia de estos modelos innovadores en el pronóstico de series temporales geofísicas como la TSM.

4. RESULTADOS

La presente tesis doctoral se estructura bajo la modalidad de compendio de publicaciones científicas. Los resultados que responden a los objetivos específicos de la investigación se presentan en tres capítulos. Los Capítulos 1 y 3 corresponden a manuscritos científicos, mientras que el Capítulo 2 expone los hallazgos en un formato de capítulo convencional.

4.1 **Capítulo 1:** "Revisando las tendencias históricas en los sistemas de surgencia del borde oriental utilizando un método de aprendizaje automático". Artículo científico publicado en la revista "Frontiers in Marine Science". <https://doi.org/10.3389/fmars.2024.1446766>. Los resultados de este manuscrito responden a al objetivo específico 1 de la tesis.

Resumen

Los sistemas de surgencia en los márgenes orientales de los océanos (EBUS, por sus siglas en inglés) albergan ecosistemas marinos de alta productividad que brindan servicios a numerosos países circundantes. El impacto del calentamiento global en su funcionamiento es motivo de debate debido a la escasez de observaciones a largo plazo, fuentes de incertidumbres en los modelos climáticos y una gran variabilidad natural. En este estudio se utiliza una técnica de

aprendizaje automático para documentar la variabilidad a largo plazo en sistemas de surgencia entre 1993 y 2019, con énfasis en eventos sinópticos de alta frecuencia. Dado que estos eventos están modulados por la circulación atmosférica y oceánica general, se plantea la hipótesis de que cambios en sus características estadísticas pueden reflejar fluctuaciones y aportar información sobre la variabilidad a largo plazo de los EBUS. Se empleó un enfoque en dos etapas utilizando los algoritmos SOM (Self-Organizing Maps) y HAC (Agrupamiento Jerárquico Aglomerativo, aplicados a conjuntos de eventos de surgencia para caracterizar las firmas en presión atmosférica, viento meridional, radiación de onda corta, temperatura superficial del mar (TSM) y bombeo de Ekman, con base en patrones espaciales dominantes. Los resultados indicaron que el patrón espacial dominante, que explica entre un 56% y 75% de la varianza total, representa el patrón estacional debido a la marcada estacionalidad en la actividad del viento a lo largo de la costa. Los hallazgos muestran que, excepto en la región de Canarias, los eventos de surgencia se han vuelto más largos en primavera y más intensos en verano. Los sistemas del Hemisferio Sur (Humboldt y Benguela) registraron una mayor ocurrencia de eventos de surgencia en verano (hasta 0,022 eventos/km²) en comparación con la primavera (<0,016 eventos/km²), contrastando con los sistemas del Hemisferio Norte (<0,012 eventos/km²). Además, se analizaron los cambios a largo plazo en los patrones espaciales dominantes dividiendo el período en dos subperíodos para comparar cambios pasados (1993-2006) con cambios más recientes (2007-2019),

revelando desplazamientos en variables clave. Estos incluyen desplazamientos hacia los polos en los sistemas subtropicales de alta presión, aumento de vientos favorables a la surgencia y disminuciones de la SST hacia latitudes más altas. El Sistema de Corriente de Humboldt (HumCS) mostró un patrón distintivo de primavera a verano, con debilitamiento del viento meridional en latitudes medias y decrecimientos simultáneos de TSM. Finalmente, al comparar los centros de surgencia dentro de los EBUS, enfocándose en cambios en gradientes de presión y temperatura, viento meridional, profundidad de capa de mezcla, transporte zonal de Ekman y bombeo de Ekman, no se encontró evidencia que respalde la hipótesis de Bakun. Los cambios temporales en estas métricas variaron dentro y entre los EBUS, sugiriendo impactos y respuestas diferenciales en diferentes áreas.



OPEN ACCESS

EDITED BY
Francisco Machín,
University of Las Palmas de Gran Canaria,
Spain

REVIEWED BY
Marisol García-Reyes,
Farallon Institute, United States
María Adela Monreal Gómez,
National Autonomous University of Mexico,
Mexico

*CORRESPONDENCE
David F. Bustos
✉ davidbustos@udec.cl

RECEIVED 10 June 2024
ACCEPTED 12 August 2024
PUBLISHED 02 September 2024

CITATION
Bustos DF, Narváez DA, Dewitte B, Oerder V,
Vidal M and Tapia F (2024) Revisiting
historical trends in the Eastern
Boundary Upwelling Systems with
a machine learning method.
Front. Mar. Sci. 11:1446766.
doi: 10.3389/fmars.2024.1446766

COPYRIGHT
© 2024 Bustos, Narváez, Dewitte, Oerder, Vidal
and Tapia. This is an open-access article
distributed under the terms of the [Creative
Commons Attribution License \(CC BY\)](#). The
use, distribution or reproduction in other
forums is permitted, provided the original
author(s) and the copyright owner(s) are
credited and that the original publication in
this journal is cited, in accordance with
accepted academic practice. No use,
distribution or reproduction is permitted
which does not comply with these terms.

Revisiting historical trends in the Eastern Boundary Upwelling Systems with a machine learning method

David F. Bustos^{1,2*}, Diego A. Narváez^{2,3}, Boris Dewitte^{4,5,6},
Vera Oerder^{2,7}, Mabel Vidal⁸ and Fabián Tapia^{2,3}

¹Programa de Posgrado en Oceanografía, Departamento de Oceanografía, Facultad de Ciencias Naturales y Oceanográficas, Universidad de Concepción, Concepción, Chile, ²Departamento de Oceanografía, Facultad de Ciencias Naturales y Oceanográficas, Universidad de Concepción, Concepción, Chile, ³Centro de Investigación Oceanográfica COPAS Coastal, Universidad de Concepción, Concepción, Chile, ⁴Centro de Estudios Avanzados en Zonas Áridas (CEAZA), Coquimbo, Chile, ⁵Centro de Ecología y Gestión Sostenible de Islas Oceánicas (ESMOI), Departamento de Biología Marina, Facultad de Ciencias del Mar, Universidad Católica del Norte, Antofagasta, Chile, ⁶Clima, Medio Ambiente, Acoplamientos e Incertidumbres (CECI), Universidad de Toulouse, Centre Européen de Recherche et de Formation Avancée en Calcul Scientifique (CERFACS)/ Centre National de la Recherche Scientifique (CNRS), Toulouse, France, ⁷Instituto Milenio de Oceanografía (IMO), Universidad de Concepción, Concepción, Chile, ⁸Departamento de Ciencias de la Computación, Universidad de Concepción, Concepción, Chile

Eastern boundary upwelling systems (EBUS) host very productive marine ecosystems that provide services to many surrounding countries. The impact of global warming on their functioning is debated due to limited long-term observations, climate model uncertainties, and significant natural variability. This study utilizes the usefulness of a machine learning technique to document long-term variability in upwelling systems from 1993 to 2019, focusing on high-frequency synoptic upwelling events. Because the latter are modulated by the general atmospheric and oceanic circulation, it is hypothesized that changes in their statistics can reflect fluctuations and provide insights into the long-term variability of EBUS. A two-step approach using Self-Organizing Maps (SOM) and Hierarchical Agglomerative Clustering (HAC) algorithms was employed. These algorithms were applied to sets of upwelling events to characterize signatures in sea-level pressure, meridional wind, shortwave radiation, sea-surface temperature (SST), and Ekman pumping based on dominant spatial patterns. Results indicated that the dominant spatial pattern, accounting for 56%-75% of total variance, representing the seasonal pattern, due to the marked seasonality in along-shore wind activity. Findings showed that, except for the Canary-Iberian region, upwelling events have become longer in spring and more intense in summer. Southern Hemisphere systems (Humboldt and Benguela) had a higher occurrence of upwelling events in summer (up to 0.022 Events/km²) compared to spring (<0.016 Events/km²), contrasting with Northern Hemisphere systems (<0.012 Events/km²). Furthermore, long-term changes in dominant spatial patterns were examined by dividing the time period in approximately two equally periods, to compare past changes (1993-2006) with relatively new changes (2007-2019), revealing shifts in key variables. These included poleward shifts in subtropical high-pressure systems (SHPS), increased upwelling-favorable winds, and SST drops towards higher latitudes. The Humboldt Current System (HumCS) exhibited a distinctive spring-to-summer pattern, with mid-latitude meridional wind weakening and concurrent SST

decreases. Finally, a comparison of upwelling centers within EBUS, focusing on changes in pressure and temperature gradients, meridional wind, mixed-layer depth, zonal Ekman transport, and Ekman pumping, found no evidence supporting Bakun's hypothesis. Temporal changes in these metrics varied within and across EBUS, suggesting differential impacts and responses in different locations.

KEYWORDS

EBUS, self-organized maps (SOM), coastal upwelling, climate change, artificial intelligence

1 Introduction

The Eastern Boundary Upwelling Systems (EBUS) span less than 1% of the ocean surface, yet they account for up to 20% of global fisheries catches (FAO, 2022). Understanding the dynamics and potential changes in these highly productive coastal ecosystems is crucial to the well-being of the communities inhabiting these regions (Large and Danabasoglu, 2006). The term “upwelling” refers to the transport of water from the deeper ocean to the surface. This water tends to be cold and nutrient-rich, supporting the high productivity in these regions (Boje and Tomczak, 2012; Kämpf and Chapman, 2016).

Coastal upwelling can be induced by the interaction among equatorward-wind frictional forces on the surface of the ocean (i.e., wind stress), Earth's rotation (i.e., Coriolis force), and coastal topography, leading to an offshore transport of surface waters, commonly known as Ekman transport (Brink, 1983), which is replaced by upwelling of deeper waters (e.g., Ekman, 1905; Stewart, 2008; Kämpf and Chapman, 2016; Montecino and Lange, 2009). The spatial changes in the rotation of the wind stress (i.e., wind stress curl) can also produce convergences and divergences through variability in Ekman transport magnitude and direction, leading to a vertical motion called Ekman pumping (e.g., Ekman, 1905; Gaube et al., 2015; Sverdrup, 1947). Both drivers of upwelling are common in the Humboldt, California, Benguela, and Canarias Current Systems, where they strongly influence nutrient availability and phytoplankton productivity and composition, which are key to structuring and sustaining marine food webs.

The synoptic temporal scale is predominant in upwelling systems, caused by wind variability from low pressure systems (i.e., storms) and internal atmospheric waves (Renault et al., 2009; Aguirre et al., 2021). This in turn results in periods of intensification and relaxation of coastal upwelling that typically last 3–10 days (e.g., Aguirre et al., 2019; García-Reyes and Largier, 2012; Lamont et al., 2018; Renault et al., 2009). Furthermore, displacements of subtropical high-pressure systems regulate wind location and intensity at seasonal scales (García-Reyes et al., 2013). Lastly at interannual and decadal scales, coastal upwelling may vary due to

oscillations such as the El Niño Southern Oscillation (ENSO) and Pacific Decadal Oscillation (PDO). These oscillations can affect equatorward (upwelling-favorable) winds and the pycnocline depth through both atmospheric and oceanic teleconnections, thereby modulating the supply of nutrients to the surface (Jacox et al., 2015; Espinoza-Morriberón et al., 2017).

Climate change impacts on coastal upwelling have been studied in the four main upwelling systems around the world (e.g., Bakun et al., 2015; Bograd et al., 2023; Sydeman et al., 2014; Wang et al., 2015). However, there is no absolute consensus on how climate change and climate variability have impacted EBUS over the past decades, especially because the time scales are interconnected and upwelling synoptic variability may be changing in terms of intensity and duration due to climate change (Abrahams et al., 2021).

In the early 1990's, it was hypothesized that climate change would intensify coastal upwelling through an intensification of the land-ocean gradients in air temperature and sea-level pressure, which would cause intensification of alongshore equatorward winds in EBUS regions (Bakun, 1990). This proposition was based on long-term shipboard wind observations, which were later shown to be biased compared to coastal winds (Tokinaga and Xie, 2011; Belmadani et al., 2014). This bias, may yield differing statistics on the intensity, frequency, and duration of upwelling events depending on the length of the available time series, seasonality, latitude, and the source of data and model simulations (e.g., Abrahams et al., 2021; García-Reyes et al., 2015; Small et al., 2015). The fate of the EBUS in a warmer climate also largely depends on non-linearities in the coastal upwelling dynamics (Gruber et al., 2011; Chang et al., 2023). Observations and numerical modeling studies exhibit inconsistent trends in wind stress and sea surface temperature (SST) among EBUS over recent decades, with increasing trends observed only in nearshore waters of the Benguela, northern Humboldt (Peru), Canary, and northern California EBUS (Varela et al., 2015, 2018). Similarly, wind stress increases towards the poles only in the California, Benguela, and Humboldt EBUS (Sydeman et al., 2014), with observational data showing higher trends in the magnitude compared to model outputs (Taboada et al., 2019).

Recent studies have assessed potential changes in upwelling-favorable winds, atmospheric pressure gradients, and migration of subtropical-high systems in EBUS under climate-model projections (Rykaczewski et al., 2015; Wang et al., 2015; Aguirre et al., 2019; Oyarzún and Brierley, 2019; Chamorro et al., 2021). Results from the Coupled Model Intercomparison Project (CMIP) suggest that climate change will impact coastal upwelling within EBUS due to a poleward shift of subtropical jet streams (Frierson et al., 2007; Lu et al., 2007; Hu et al., 2013; Grise et al., 2018). Consequently, Hadley cells are expected to expand (Grise and Davis, 2020; Xian et al., 2021) and produce a poleward displacement of subtropical highs (García-Reyes et al., 2013; Wang et al., 2015). However, this expansion may occur differently in the two hemispheres, with varying trends depending on the metrics used to assess it (Xian et al., 2021). This poleward migration would induce long-term changes in the intensity, location, and seasonality of upwelling-favorable winds, with a general intensification (relaxation) of these winds toward the equator (poles) during the spring-summer seasons in the mid-latitudes (Goubanova et al., 2011; Belmadani et al., 2014; Rykaczewski et al., 2015; Wang et al., 2015; Brady et al., 2017), while the changes in the EBUS within the tropics are more uncertain.

Due to the non-linear nature of coastal upwelling dynamics (Estrade et al., 2008; Gruber et al., 2011) and the existence of natural variability embedded in their forcings, inferring changes in the circulation of these systems has been challenging. Linear techniques such as trend analysis and empirical orthogonal functions (EOFs) are usually employed to gain insights into changes in ocean and atmospheric circulation, but they have inherent limitations for analyzing changes in non-stationary signals that deviate from Gaussianity (Hannachi et al., 2006). New approaches based on Artificial Intelligence techniques are offering a more appropriate framework for addressing complex non-linear problems with high dimensionality, such as coastal upwelling. They may allow us to gain better insights into circulation changes across systems while considering peculiarities in geographical settings and the balance between remote and local drivers of upwelling.


Here we thus propose to explore changes in ocean and atmospheric conditions associated with coastal upwelling across the four major EBUS over the last three decades using the Self-Organized Map and a Hierarchical Clustering algorithm, combining observational and modeling products. Our aim is to confirm or refute established scientific knowledge about changes in upwelling due to long-term variability across the four major EBUS. The paper is organized into four sections, which describe data sources, data-analysis methods, and model's performance assessment (Section 2); present the main spatial patterns variability and assess differences among upwelling centers (Section 3). Finally, Section 4, summarizes and discusses these results.

2 Materials and methods

2.1 Study areas

We focused on the four main EBUS worldwide, namely the California Current System (CalCS) on the west coast of North America (130–110°W, 20–50°N), the Humboldt Current System (HumCS) on the west coast of South America (85–65°W, 0–54°S), the Benguela Current System (BenCS) on the southwest coast of Africa (5–25°E, 10–40°S), and the Canary-Iberian Peninsula Current System (C-ICS) spanning the northwestern of Africa and the Iberian Peninsula (25–5°W, 15–45°N) (Figure 1). These regions are similar in their extent to those described by Wang et al. (2015) and Thiel et al. (2007) for the HumCS.

Since these systems span wide latitudinal ranges, they are spatially heterogeneous environments (Kämpf and Chapman, 2016). At higher latitudes (25–40°N/S), upwelling is characterized by a marked seasonal cycle beginning in spring and extending through summer and early fall, with dominant downwelling-favorable winds in winter. The length of the upwelling season increases as latitude decreases, becoming a year-round process in



tropical and subtropical latitudes (0–23.5°N/S) (García-Reyes et al., 2015; Wang et al., 2015).

To better understand and quantify upwelling variability within each EBUS, we selected the most recognized upwelling centers from the literature for each system based on productivity and coastal upwelling intensity, following Kämpf and Chapman (2016). For the HumCS, we chose Chimbote (CHI), Callao (CAL) Mejillones (MEJ), Coquimbo (COQ), Valparaíso (VAL), and Concepción (CON). For the BenCS, we selected Cape Frio (CFR), Walvis Bay (WAL), Luderitz (LUD), Namaqualand (NAM), Santa Elena Bay (SEB), and Cape Town (CTO). For the CalCS, we chose Point. Conception (PCO), Point. Año Nuevo (PAN), Point. Reyes (PRE),

and Point. Arena (PAR). Finally, for the C-ICS we selected Cape Blanc (BLA), Cape Juby (JUB), Beddouza (BED), Saint Vincent (SVI), and Cabos Silleira (CSI). The main features of these upwelling centers are shown in Table 1.

2.2 Data sources and processing

Oceanographic and atmospheric data were obtained from various sources, including *in situ* observations, model simulations, and reanalysis products. An exhaustive description of the data used is presented in Table 2. Additionally, the meridional and zonal

TABLE 1 Upwelling centers characterized in terms of their Location, Depth, Coastline orientation, Distance to the Equator and Distance to grid point.

Humboldt						
Center	Lat (-90°S - 90°N)	Lon (-180°W - 180°E)	Depth (m)	Coastline Angle (°)	Distance Equator (km)	Distance to grid point *(km)
Chimbote (CHI)	-9.50	-78.75	125	132.60	1056.58	38.84
Callao (CAL)	-12.00	-77.25	72	143.44	1334.57	12.24
Mejillones (MEJ)	-22.50	-70.50	821	196.90	2501.65	26.11
Coquimbo (COQ)	-30.00	-71.50	461	191.62	3336.08	8.02
Valparaíso (VAL)	-33.00	-71.75	157	198.73	3669.66	18.26
Concepción (CON)	-36.50	-73.00	47	202.32	4058.84	7.44
Benguela						
Cape Frio (CFR)	-18.50	11.75	169	153.01	2057.34	43.50
Walvis Bay (WAL)	-22.50	14.25	68	162.70	2502.12	23.54
Luderitz (LUD)	-26.50	14.75	173	166.14	2946.89	41.87
Namaqualand (NAM)	-30.50	17.25	131	149.08	3391.68	11.18
Saint Elena Bay (SEB)	-32.50	18.00	80	164.99	3614.07	30.87
Cape Town (CTO)	-33.50	18.00	103	169.93	3725.26	28.59
California						
Pt. Conception (PCO)	34.50	-120.75	268	147.85	3836.46	22.91
Pt. Año Nuevo (PAN)	37.00	-121.50	26	122.90	4114.44	1.11
Pt. Reyes (PRE)	38.00	-123.00	34	121.93	4225.64	144.94
Pt. Arena (PAR)	38.50	-123.50	140	125.20	4281.24	23.57
Canary-Iberian Peninsula						
Blanc (BLA)	21.00	-17.00	3	188.92	2335.33	33.74
Juby (JUB)	28.00	-12.75	28	112.14	3113.69	47.86
Beddouza (BED)	32.50	-9.50	86	208.83	3614.07	22.27
St. Vincent (SVI)	37.00	-9.00	41	231.33	4114.44	253.82
Cabos Silleira (CSI)	42.00	-9.00	104	151.65	4670.42	9.64

*Distance to the grid point refers to the linear distance from the center defined by Kämpf and Chapman (2016) to the closest grid point with available data.

TABLE 2 Data sources and details on the variables used for this study.

Product	Description	Period	Variables	Spatial Resolution (lat x lon degrees)	Time Resolution
Global Ocean OSTIA SST dataset ¹	Satellites (ESA, SST CCI, C3S EUMETSAT and REMSS) and data <i>in situ</i> (HadIOD) from OSTIA	1993-2019	SST	0.05 x 0.05	Daily
Global Ocean Ensemble Physics Reanalysis ^{2,4}	Global Ocean Reanalysis (GLORYS2V4 from Mercator, ORAS5 from ECMWF, GloSea5 from MetOffice and C-GLORS05 from CMCC) + observations	1993-2019	SSS, SSH, MLD and Ocean currents (U,V)	0.25 x 0.25	Daily
Global Ocean Wind L4 Reprocessed 6 hourly Observations ³	Satellites (ERS-1, ERS-2, QuickSCAT, RapidSCAT, EUMETSTAT OSI, ASCAT-A, ASCAT-B, HY-2A and OceanSat-2), remote sensors (SSM/I SSMIS and WindSAT) and reanalysis	1993-2019	Wind (u, v) and curl	0.25 x 0.25	Daily
Global Ocean Biogeochemistry hindcast ^{4,*}	Biogeochemical hindcast from global ocean (Mercator), PISCES + NEMO models	1997-2019	Surface Chlorophyll and oxygen	0.25 x 0.25	Daily
Global Ocean Colour ⁵	Satellite data from chlorophyll	1993-2019	Surface Chlorophyll	0.01 x 0.01	Daily
ERA5 ⁶	Atmospheric reanalysis from ECMWF	1993-2019	SLP, Ta and Qsw	0.25 x 0.25	Daily
Fisheries landing time series ⁷	Data retrieved from IFOP using fishing statistics yearbooks	1996-2019	T,S,Density and wind	Nearby fisheries information	Monthly
ARGO profiles ⁸	Data from ARGO program in collaboration with CLIVAR and GODAE programs	2002-2019	T,S,Density, oxygen and chlorophyll	1 x 1	Monthly
Argo Mixed Layers ⁹	Climatology from 2.5 million of ARGO profiles from 2000-2019	2000-2021	MLD	1.00 x 1.00	Monthly

¹ https://data.marine.copernicus.eu/product/SST_GLO_SST_L4_REP_OBSERVATIONS_010_011/description (Accessed: March 19, 2024).

² https://data.marine.copernicus.eu/product/GLOBAL_MULTIYEAR_PHY_ENS_001_031/description (Accessed: March 19, 2024).

³ <https://www.pigma.org/geonetwork/srv/api/records/85c907d3-98fc-4ce7-b7e4-7332aa3fe660> (Accessed: March 19, 2024).

⁴ https://data.marine.copernicus.eu/product/GLOBAL_MULTIYEAR_BGC_001_029/description (Accessed: March 19, 2024).

⁵ https://data.marine.copernicus.eu/product/OCEANCOLOUR_GLO_BGC_L4_MY_009_104/services (Accessed: March 19, 2024).

⁶ <https://cds.climate.copernicus.eu/cdsapp#!/dataset/reanalysis-era5-single-levels?tab=overview> (Accessed: March 19, 2024).

⁷ <https://www.ifop.cl/busqueda-de-informes/> (Accessed: March 19, 2024).

⁸ <https://argo.ucsd.edu/data/> (Accessed: March 19, 2024).

⁹ <https://mixedlayer.ucsd.edu/> (Accessed: March 19, 2024).

*Indicates ocean model simulations.

Product names in bold were used for validation while non bold products are those used to feed the algorithms. Variables in blue were excluded from the results discussion (section 2.3.4) but are presented in Supplementary Annex F.

components of Ekman transport (E_v , E_t), as well as Ekman pumping (E_p), were derived from the wind time series using Equations 1-3 as follows (cf. Ekman, 1905; Jacox et al., 2018; Stewart, 2008):

$$E_v = \frac{-\tau_o^x}{\rho_o f} \quad (1)$$

$$E_t = \frac{\tau_o^y}{\rho_o f} \quad (2)$$

$$E_p = \frac{1}{\rho_{DEF}} \left(\frac{\partial \tau_o^y}{\partial x} - \frac{\partial \tau_o^x}{\partial y} \right) + \frac{\beta \tau_o^x}{\rho f^2} \quad (3)$$

Where f is the Coriolis parameter, ρ_o is a reference density, β is the Coriolis parameter gradient, which is negligible since latitudinal variations are not significant. The wind stress in the eastward and northward directions are represented by τ^x and τ^y , respectively.

The wind curl is $\frac{\partial \tau_o^y}{\partial x} - \frac{\partial \tau_o^x}{\partial y}$ and, ρ_{DE} represents the density at the base of the Ekman layer, obtained using Equation A16 (Supplementary Annex A).

Since spatial resolution varies among products, from 0.01 to 0.25 degrees (Table 2), all products were interpolated to a regular 0.25°x 0.25° grid using a conservative normalized method (Hill et al., 2004; Chen et al., 2016) to avoid shifting and sharp gradient issues, thereby ensuring conformity to a standardized reference grid. This method has been proven to uphold maximum and minimum values, maintaining the integrity of range and central tendency metrics (Hurrell et al., 2013), and is guaranteed to preserve the synoptic (2-6 days) and spatial scales (25-100km) of coastal upwelling (Aguirre et al., 2019).

Ocean model simulations (* in Table 2) were validated within the top 500m at seasonal scale using data from ARGO profiles. Temperature and salinity simulations in each upwelling system were compared to ARGO data using Taylor diagrams. Besides, oxygen and chlorophyll simulations were validated using data from

ARGO's biogeochemical profiles using data from the top 300m for oxygen, and using Ocean Global Colour satellite products for 1997–2019 in the case of chlorophyll (Groom et al., 2019). Additionally, data from oceanographic cruises conducted by IFOP (Instituto de Fomento Pesquero, Chile) were used for validations nearshore where ARGO profiles are scarce. The validation was conducted for all products, including satellite data (sea surface temperature, sea surface height, chlorophyll) and model outcomes (oxygen and chlorophyll), therefore there is no redundancy in assessment. Detailed results of this validation can be found at https://github.com/dfbustosus/Validation_EBUS_DavidBU (Supplementary Table B1 Supplementary Annex B).

For the following analysis we selected 15 variables: surface meridional and zonal wind (Mw always positive equatorward and Zw, respectively), sea level pressure (SLP), air temperature (Ta), shortwave radiation (Qsw), surface currents (u,v), sea surface temperature (SST), sea surface salinity (SSS), sea surface oxygen (SSO), sea surface chlorophyll (SSC), sea surface height (SSH), mixed layer depth (MLD), wind stress magnitude and wind curl. These variables were selected based on previous studies analyzing long-term variations in the circulation in EBUS both in terms of physical (e.g., Bograd et al., 2023; Wang et al., 2015; Rylkaczewski et al., 2015; Aguirre et al., 2012; Alvarez et al., 2008) and biological (Chavez and Messié, 2009; Andrews and Hutchings, 1980) conditions.

2.3 Data analysis

2.3.1 Identification of upwelling events

One of the distinctive features of EBUS oceanic and atmospheric circulation is its variability spanning periods from one day to several months. This variability is characterized by the occurrence of short-lived upwelling events with a marked seasonality. Changes in environmental forcings within EBUS lead to variations in this high-frequency variability, which motivates the analysis in the context of our study. Although there are different ways to identify upwelling events such as cross-shore SST differences (Benazzouz et al., 2014) and the vertical water transport rate along the coastline (CUTI) (Jacox et al., 2018; Bograd et al., 2023). All existing indices consider three important factors: SST, wind speed and the relative alignment of wind direction respect the coastline. Thus, these factors were used as key indicators to identify upwelling events through the upwelling index proposed by Fielding and Davis (1989):

$$UI = \mu(\cos(\theta - \alpha)) \quad (4)$$

Where μ and θ represent the wind speed (ms^{-1}) and direction (degrees), and α indicates the coastline orientation relative to the north. An upwelling event was identified based on three criteria: (1) $UI > 0$, (2) SST below a 25th percentile threshold (Schlegel and Smit, 2018) using the SST daily climatology for each season, and (3) persistence of these conditions for more than 3 consecutive days. Different upwelling metrics were obtained for each system, including frequency of occurrence (Events/ km^2), mean intensity

and duration. Frequency of occurrence indicates the number of events occurring per grid point, calculated by dividing the total number of events by the spatial extent in km^2 . Mean intensity refers to the average temperature drop relative to the daily climatological baseline during an upwelling event, while duration measures the span in days of an upwelling event (Abrahams et al., 2021). Figure 2 illustrates an example for the HumCS.

2.3.2 Self-organized map

The SOM is an Artificial Intelligence technique based on competitive learning (Kohonen and Somervuo, 1998; Vesanto and Alhoniemi, 2000) that has found application in oceanographic and atmospheric studies (e.g., Le Bars et al., 2016; Sonnewald et al., 2021) to characterize circulation patterns resulting from non-linear processes in multidimensional data (Qian et al., 2016). This method offers distinct advantages over linear approaches such as EOFs (North, 1984) and K-means (Dreyfus et al., 2005) for three primary reasons: first, it handles non-linearities inherent in biophysical processes not assuming normal data distributions; second, it preserves topology to maintain spatial relationships; and third, demonstrates robustness to outliers (Liu and Weisberg, 2011). Despite these advantages, however, the application of this technique to analyze the dynamics of upwelling within EBUS over an extended period remains unexplored.

The SOM is used to obtain the main patterns of spatial variability (i.e. clusters) within each EBUS separately, along with the dates of upwelling events. For this purpose, we selected 15 variables (Section 2.3.1) considering solely unique dates when upwelling events occurring in any of the nodes along the coast for each EBUS by two reasons: first, upwelling events are the primary focus, and second, incorporating other data would introduce noise into the algorithm's learning. Figure 3 provides a schematic overview of the multivariate SOM technique. All the data (k) for each time (t) are flattened into vectors (x_t) that contain only ocean nodes. These vectors form a 2D array, which is used first to find the best network configuration (rectangular 2-D maps, which represents the optimal configuration for the model's learning process) and second to update the weights (W) of the SOM neural network with competitive learning. The best network configuration (2-D map neurons, Figure 3) ensures an efficient learning process (see Supplementary Annex C Supplementary Figure S1). This optimal configuration is identified using two metrics following Jebri et al. (2022): the quantization error (QE) and topological error (TE). While QE provides a reliable indicator of potentially critical changes in spatial structure over time (Sun, 2000), TE allows quantifying geometric preservation of the dominant structures, which implies understanding the quality of the map's representation and organization of the input data (Gibson et al., 2017). These two metrics are widely used to validate the performance of the SOM algorithm (Liu et al., 2006; Naik and Shah, 2014).

During the learning process the algorithm weights are calibrated based on QE and TE metrics. The SOM outputs an $m \times r$ list of clusters, each containing times associated with similar spatio-temporal variability. These clusters are reshaped back into




FIGURE 2

Upwelling events identification method for node at 73°W , 16.5°S (yellow cross in a). (A) represents the peak SST anomaly ($^{\circ}\text{C}$) during an upwelling event spanning 23–31 December 1998. The second column (B) displays the SST time series (black), SST climatology (blue), and 25th percentile threshold (green) during the event. (C) Upwelling Index (UI) computed with Equation 4. Red shading marks the duration of the identified upwelling event.




FIGURE 3

Schematic of the SOM technique adapted from Liu and Weisberg (2011). The 3-D data time series (lat,lon,time) for each variable (k) (left panel) are rearranged in a 2D array that includes all variables considered, where each time step is reshaped as a row vector (x_i) (middle panel, Data array). For each time step (t), the row vector is used to update the weights (W) of the SOM network with competitive learning. The iterative process is also known as self-organizing (Right panel, Self-organizing). The outcome clusters from SOM neurons (blue circles) are reshaped back into characteristic patterns. Each neuron contains different instances with similar variability, basal structure, etc., and these can be associated as clusters of data.

characteristic patterns by averaging maps for all times associated to the cluster. These patterns reveal dynamic signals of dominant upwelling behavior, distinct from those derived from mean nor linear trend analyses, which are often smooth masking the large variability in the process of interest (Kohonen and Somervuo, 1998; Jouini et al., 2016), potentially offering new insights into circulation changes. Further details on SOM parametrization are provided in [Supplementary Material, Supplementary Annex C \(Supplementary Table C1\)](#).

2.3.3 Hierarchical clustering algorithm

The SOM algorithm yields between 12 and 16 spatial patterns of variability, many of which exhibit similar spatial structure. To simplify these results and derive the final spatial patterns for each EBUS, we implemented the Hierarchical Clustering Algorithm (HAC) technique (Jain et al., 1999). HAC is an unsupervised machine learning method known for its ability to uncover patterns and relationships within complex datasets (Saraceno et al., 2006; Li et al., 2020; Liu et al., 2021). This technique clusters data based on similarities and dissimilarities using a distance metric and grouping criterion.

We applied HAC to reduce the number of clusters generated by the SOM, resulting in the final patterns of variability. Similarity between objects was assessed using the Euclidean distance metric (Nielsen and Nielsen, 2016) and clustering was performed based on the Ward criterion (Murtagh and Legendre, 2014). The dendrogram helped identify a small number of cohesive groups. [Figure 4](#) illustrates the integration of SOM and HAC. For each resultant cluster, we counted the number of associated days, yielding the number of days with upwelling events related to this pattern

(section 3.1). Subsequently, temporal averages are computed to obtain the mean spatial structure linked to each cluster (section 3.2). These averages can be calculated for the entire period or for shorter intervals (see section 2.3.4) to observe the evolution of spatial structures (sections 3.3 and 3.4).

2.3.4 Long-term analysis

Yearly time series spanning from 1993 to 2019 were constructed for the number of days with upwelling occurrences, derived from the principal spatio-temporal patterns of variability obtained for each EBUS and season (i.e., spring and summer). This approach allows for comparison of the variability explained by each pattern. Spatial averages of SLP, meridional wind component (Mw), Qsw, SST, and Ep were calculated from the dominant spatial pattern (see Section 2.2). These averages help identify similarities and differences across each EBUS and season analysis.

Certain variables (highlighted in blue, [Table 2](#)) were excluded from the primary analysis but are presented in [Supplementary Annex F](#) due to the following reasons. First, surface chlorophyll and oxygen were omitted due to incomplete representation nearshore accuracy in the hindcast product (Fransner et al., 2020). Secondly, wind stress and curl are used for Ek and Ep calculations respectively (Section 2.2), SSS lacks notable variability, and its exclusion makes it possible to avert Simpson's paradox in the analysis (Wagner, 1982). Ocean currents were not included as they derive from atmospheric and ocean factors already included in the analysis. Finally, SSH was omitted to prevent redundancy, as it reflects the influence of atmospheric pressure, surface wind, SST, and SSS (Stewart, 2008). However, all variables are included because this approach, unlike multivariate techniques such as EOFs, accounts for nonlinear




FIGURE 4
Illustration of two-level abstraction clustering algorithm SOM - Hierarchical Clustering. Daily tag/cluster results from multivariate SOM (see [Figure 3](#)) are used to provide the input (middle panels, Self-organizing Tag) to the second level of abstraction level using the clustering technique (right panel, Hierarchical Clustering (HAC)).

interactions between variables. This method had shown benefits in providing a more accurate representation of highly variable systems (Lachkar and Gruber, 2012; Nakaoka et al., 2013). Nonetheless, its implementation in other studies has been focused narrowly on discerning patterns within a limited subset of variables (Richardson et al., 2003; Liu and Weisberg, 2011).

To quantify the long-term changes of the dominant spatial patterns obtained for each EBUS, we compared approximately two different decades by dividing the time period in past changes (1993–2006) and relatively new changes (2007–2019), based on the data availability. Spatial anomalies, computed by contrasting these two periods, were used to assess the magnitude of variations using SLP, the meridional wind component, Qsw, SST, zonal Ekman transport (Ek), mixed layer depth (MLD), and Ep.

Furthermore, to assess long term temporal changes in specific areas with strong upwelling, i.e., upwelling centers (Table 1), we conducted paired t-tests with Bonferroni correction using the dominant spatial pattern and the two selected periods (1993–2006 and 2007–2019). The Bonferroni correction (Perneger, 1998) adjusts the significance level of hypothesis tests to account for multiple comparisons simultaneously, thereby reducing the risk of false positives (Type I error) by setting a stricter p-value threshold for each individual test (Napierala, 2012). A significance level of 5% was applied. This approach allows quantification of the extent of change in each center, while controlling for potential confounding effects of the unique geographical location and physical conditions at each site. By accounting for these differences, the t-statistic enables isolation and fair comparison of variability magnitude. Selected variables such as SST, Mw, QST and Ep were used in the comparisons. Additionally, Pressure Gradient (PG) and Temperature Gradient (TG) were calculated as differences between the closest three ocean-to-land grid points at each latitude following the methodology proposed by Jacox et al. (2018) to test the Bakun hypothesis. Mixed-layer depth was also included in the analysis to assess potential changes in the oceanic vertical structure.

2.3.5 Subtropical high detection center

To assess the role of latitudinal shifts in the subtropical-high systems (SPHS), we identified and tracked the centers of subtropical highs in EBUS, the North Pacific Subtropical High (NPSH), North Atlantic Subtropical High (NASH), South Pacific Subtropical High (SPSH), and South Atlantic Subtropical High (SASH). The geographic limits considered were: NPSH (25–45°N, 180°E–130°W), NASH (25–45°N, 70–20°W) from Song et al. (2018), SPSH (15–50°S, 150–69°W) based on Ancapichún and Garcés-Vargas (2015), and SASH (20–40°S, 42°W–12°E) as described by Reboita et al. (2019).

Two versions of an eight-step algorithm to identify subtropical-high centers were applied (see Supplementary Annex D for more details). The first algorithm, described by Gilliland and Keim (2018) and the second algorithm, described by Lambert (1988 and Murray and Simmonds (1991). The second algorithm addresses issues related to disturbances caused by transient weather systems and offers robustness against the potential fragmentation of subtropical

highs by cold fronts and anticyclones, particularly when daily data are used to locate the center (Degola, 2013). Results from algorithm 1 (Supplementary Material Table D1) were used to determine the daily position of subtropical highs, associating them with various spatial patterns of variability identified by the SOM algorithm. Additionally, results from algorithm 2 (Supplementary Material Table D2) were used to investigate decadal trends in the movement of each subtropical high center (results not shown).

3 Results

This section begins detailing the number of days with upwelling events within the primary variability patterns. Therefore, describes the principal spatial pattern for each EBUS, followed by an analysis of how these patterns evolve over time. Finally, summary statistics, including various upwelling metrics, are provided to facilitate comparison across the different EBUS.

3.1 Number of days with upwelling events in the main variability patterns

The principal spatial pattern of variability derived from the SOM-HAC algorithm characterizes the upwelling regime, revealing the predominant signal within each season and EBUS. The results demonstrate a distinct separation among the dominant spatial pattern of variability (depicted by blue lines in Figure 5), with prevalence exceeding 56% across all EBUS. The mean number of days with upwelling per year and season (denoted as $\bar{X}$ in Figure 5, resulting from adding the blue, red, and green lines) shows higher values during spring (Figures 5A–D) compared to summer (Figures 5E, F), ranging from 50.4 days yr^{-1} (Figure 5H) to 83.6 days yr^{-1} (Figure 5A). The CalCS and HumCS exhibit the highest number of days with upwelling events per year, with HumCS recording the highest number (83.59 days yr^{-1}). No significant linear trends were observed at the inter-annual scale for either spring or summer.

3.2 Spatial structure of SOM dominant spatial pattern

Using the dates associated with the dominant spatial pattern (selecting spatial pattern-specific dates and averaging them), we reconstructed the spatial structure of the key variables relevant for understanding changes in the ocean and atmospheric circulation within these coastal upwelling systems. These variables were SLP, Mw, Qsw, SST and Ep (Figures 6, 7). Interestingly the dominant spatial pattern captures the seasonal cycle across all EBUS, which is clearly evidenced by the presence of the Coastal Jets (Mw) and the subtropical anticyclones (SLP). This is noteworthy given that the input data only includes short-lived upwelling events. It suggests that the marked seasonality in intraseasonal variability within EBUS systems is driven by upwelling-favorable winds due to extratropical




FIGURE 5

Time series of the annual upwelling duration (in days, this represents how many distinct dates where under upwelling events for a given season, spring (A-D) and summer (E-H)) of the main three dominant spatial patterns detected by SOM-HAC algorithm for each EBUS and season (spring (left) and summer (right)). The y-axis represents the duration (days), and the x-axis represents the years. The first spatial pattern (blue), second (green), and the third (red) presented in decreasing order of occurrence. Mean numbers of days with upwelling per year ($\bar{X}$) are reported in upper left corner of each panel. Legends show the percentages of the total variance explained by each spatial pattern.

disturbances and seasonal changes in oceanic mixing (e.g. Renault et al. (2009) for HumCS, Goubanova et al. (2013) for BenCS).

In the spring season (Figure 6), significant SLP isobars exceeding 1020 hPa are observed near the coast and displaced polewards in CalCS, C-ICS and BenCS. The meridional wind component (Mw) exhibits higher values in the mid-latitude regions and towards the poles across most of the systems, with particularly elevated values in BenCS and CalCS ($> 8 \text{ m s}^{-1}$). Shortwave radiation (Qsw) ranges between 200 and 300 W m^{-2} across all upwelling centers, with higher values in BenCS (up to 300 W m^{-2}). Sea surface temperature (SST) drops below 15°C nearshore in the major upwelling centers along HumCS, BenCS and CalCS. Conversely, C-ICS shows higher SST values ($15\text{--}20^\circ\text{C}$) throughout the region. The Ekman pumping (Ep) displays an increasing trend nearshore with values exceeding 0.1 md^{-1} at the most significant upwelling centers.


In the summer season (Figure 7), the spatial distribution of SLP exhibited a similar pattern to spring, with the 1020 hPa isobar situated closer to shore in CalCS and C-ICS compared to HumCS and BenCS. As expected for summer, there was a notable increase in the meridional wind (Mw) ($> 6 \text{ m s}^{-1}$) from mid-latitude and toward the poles across all EBUS. SST and Ep, displayed spatial patterns similar to those observed in the spring season (Figures 6, 7).

We do not present the second and third spatial patterns of variability as each contribute less than 50% of the total variability for each system and season considered. However, a detailed

description of these spatial patterns of variability is presented in Supplementary Annex E, Supplementary Material (Supplementary Figures S5-S8).


3.3 Spatiotemporal changes in the dominant spatial pattern of variability

When comparing the decadal changes in the principal spatial pattern of variability, mid-latitude regions in all EBUS showed an increase in SLP ranging between 0.2 and 0.8 hPa (Figure 8, positive anomalies SLP column). The centers of all subtropical highs (SPHs) exhibited a poleward displacement ranging from 89 and 224 km, accompanied by a slight offshore shift, except for CalCS (Table 3, Supplementary Annex C, Supplementary Figure S2). There was a noticeable increase in the meridional wind component (Mw) ranging from 0.5 to 1 m s^{-1} (Figure 8, Mw column) in CalCS and C-ICS toward the poles. In HumCS and BenCS, Mw showed slight increases in opposite directions: HumCS with a more pronounced trend at lower latitudes, excluding regions around $15\text{--}20^\circ\text{S}$ and near 40°S , while BenCS, the trend was poleward of 20°N . Qsw increased up to 5 W m^{-2} in BenCS, CalCS, and C-ICS, especially nearshore. Conversely, HumCS experienced a reduction in Qsw across the entire system ranging from 5 to 10 W m^{-2} (Figure 8, Qsw column). SST displayed a decrease nearshore ranging from 0.3 to 0.6°C in middle and higher latitudes, except in C-ICS and BenCS where an




increase between 0.2 and 0.4°C was observed. HumCS showed a significant northward increase ($>1^{\circ}C$) northward from 25°S, consistent with the reduction in Mw (Figure 8, SST column). Moreover, there was a reduction in Ep nearshore for all EBUS, except for HumCS, where Ep increased (Figure 8, Ep column).

For the summer season (Figure 9), subtropical high-pressure systems exhibited a poleward (and slightly shoreward) shift, with displacements ranging between 57 and 443 km, except for BenCS, which showed a westward shift (Table 3). However, SLP increases were less pronounced compared to spring, with increments less than



0.5 hPa across all systems (Figure 9, left column). Furthermore, most systems showed an increase in meridional wind (Mw) during summer, ranging from 0.2 to 0.8 m s^{-1} . However, reductions were observed in CalCS and C-ICS, for instance towards BLA upwelling center. HumCS showed a different pattern with a weakening of equatorward winds ranging from 0.1 to 0.4 m s^{-1} at mid-latitudes (25–35°S). In contrast to spring, Qsw decreased by 5 to 15 W m^{-2} in most systems during

summer. SST patterns varied across EBUS: HumCS and CalCS showed decreases ranging between 0.1 and 0.6°C, while C-ICS and BenCS showed increases in nearshore waters ranging from 0.2 to 0.6°C. In the HumCS, SST increased ($> 0.1^\circ\text{C}$) significantly northward from 25°S, consistent with the decrease in nearshore Mw. Finally, there were reductions in Ep nearshore in BenCS and CalCS, while summer Ep increased in HumCS and CanCS (Figure 9).



3.4 Decadal changes in the upwelling centers

In addition to the general spatial and long-term changes described above, we conducted a detailed analysis of specific areas

known for strong upwelling (i.e. upwelling centers). Figure 10 presents the result of the Bonferroni multiple comparisons test, which adjusts for differences in averages and variability between the approximately two decades 2007–2019 and 1993–2006. Alongside the variables described in section 3.3: Pressure Gradient (PG),

TABLE 3 Displacement of Subtropical-High Centers when comparing 2007-2019 with 1993-2006.

Season	System	SPH Center migration (direction, distance)
Spring	HumCS	(SW, 224 km)
	BenCS	(SW, 127 km)
	CalCS	(NE, 97 km)
	C-ICS	(NW, 89 km)
Summer	HumCS	(SE, 57 km)
	BenCS	(SW, 191 km)
	CalCS	(NE, 122 km)
	C-ICS	(NE, 443 km)

Calculations were done averaging the mean distance obtained from two different algorithms (see section 2.3.6).

Temperature Gradient (TG), Zonal Ekman transport (Ek) and Mixed Layer Depth (MLD) were included to assess potential changes in the oceanographic vertical structure at these centers.

During spring, an increase in the Pressure Gradient (PG) (i.e., larger land-ocean) was observed at HumCS for upwelling centers Mejillones (MEJ), Coquimbo (COQ), and Valparaíso (VAL) (Figure 10). Conversely, in summer, there was a slight drop in PG for Chimbote (CHI), Callao (CAL), and Mejillones (MEJ) in HumCS, as well as for Blanc (BLA) in the C-ICS. Point Año Nuevo (PAN) in CalCS showed a decreasing pattern in both seasons analyzed, while no significant changes (white spaces) were observed for BenCS. Besides, a distinctive pattern emerged in HumCS where PG increased towards the south during spring, coinciding with an increase in TG towards the north. In summer, as PG decreased towards the north, TG decreased towards the south. Point Año Nuevo (PAN) in CalCS was the only upwelling center that displayed significant reductions in TG. Additionally, an opposite pattern of TG change was observed in C-ICS between Blanc (increase) and St. Vincent (decrease).

Meridional winds (Mw) decreased at most upwelling centers in the HumCS during both spring and summer, except for Coquimbo (COQ) and Valparaíso (VAL) in spring. In summer, Mw weakened notable at Chimbote (CHI) and Callao (CAL) in HumCS, Walvis Bay (WAL) in BenCS, Pt. Conception (PCO) in the CalCS, and Blanc (BLA) in the C-ICS. Conversely, Cabo Silleira (CSI) showed an opposite pattern in spring within C-ICS, while Beddouzza (BED) and St. Vincent (SVI) exhibited changes in summer. Significant drops in SST were observed at most upwelling centers, particularly those at higher latitudes, except for Walvis Bay (WAB) in BenCS, and Beddouzza (BED) in C-ICS during summer. Similar patterns were observed for MLD. Zonal Ekman transport (Ek) showed increases during only in the Pacific systems, specifically at Coquimbo (COQ) and Callao (CAL) in HumCS, Point Reyes (PRE), and Point Arena (PAR) in CalCS. Conversely, Ek decreased during summer at most centers, with no significant changes observed in BenCS. Ekman pumping (Ep), increased in both spring and summer for HumCS, while higher-latitude centers in BenCS showed decreases in both seasons. In CalCS, Ep increased

at Point Reyes (PER) and Point Arena (PAR) but decreased at Blanc (BLA) and Beddouzza (BED) in C-ICS.

Besides, we calculate relative changes in the seasonal cycle using Equation 5 (see Supplementary Material, Supplementary Annex C, Supplementary Figure S3). Results indicate an amplification in the seasonal cycle across the EBUS.

$$\frac{[Spring - Summer]_{difference}}{[Spring - Summer]_{mean}} \quad (5)$$


3.5 Summary upwelling metrics

The SOM-HAC results are based on the days when upwelling occurs (section 2.3.1), enabling the description of the upwelling process in the EBUS using various metrics. The upwelling metrics derived for each system during the study period (events/km² affected, mean duration and intensity), reveal that HumCS experiences significant more events (Table 4), with a higher occurrence during summer (0.022) than spring (0.016). BenCS shows a similar pattern. Conversely, CalCS and C-ICS exhibit significantly more events during spring than summer (Table 4). In terms of mean duration, events last significantly longer in spring across all EBUS (One-way ANOVA, $F=27.86$, $p<0.001$, $df=3$). Upwelling events persist longer in the HumCS and CalCS, ranging from 6.8 to 8.5 days, whereas in other regions, durations do not exceed 6 days. Regarding the mean intensity of upwelling events, values are significantly higher during summer in all EBUS except C-ICS (One-way ANOVA, $F=985.04$, $p\sim 0$, $df=3$), reaching up to -1.7°C in BenCS.

4 Discussion

In this study, we utilized various metrics (frequency of occurrence, mean duration, and intensity) to characterize and compare the phenology and interannual trends of the upwelling process across major EBUS worldwide. Analysis of upwelling metrics across these regions revealed that, on average, upwelling events are longer during spring and more intense in the summer. An exception to this trend is observed in the Canary Islands region (C-ICS, Table 4), where recent observations indicate an increase in upwelling-favorable winds without significant changes in SST nor the vertical motion of coastal waters (Narayan et al., 2010; Patti et al., 2010).


We also assessed the principal spatial patterns of upwelling variability in the four major EBUS from 1993-2019 using various datasets for atmospheric and oceanic variables (Table 2). These spatial patterns were extracted using an innovative clustering technique known as SOM-HAC, focusing on periods classified as upwelling events (i.e. upwelling-favorable winds for more than three days and SST below the 25th percentile climatological threshold). Additionally, changes in dominant spatial pattern were examined across different known upwelling centers within each EBUS.



In this study we implemented a novel approach in oceanography based on Artificial Intelligence applied to multivariate datasets (15 variables). This technique considers the nonlinear interactions that may be linked to climate change in the main EBUS. Through this approach, we aimed to expand our understanding of the complexities underlying coastal upwelling processes and their response to climate-driven changes in

atmospheric and oceanographic forcing. While our findings align with previous studies, they also reveal new insights into the variability of upwelling in these regions.

The method yields a main spatial pattern of variability that accounts for the seasonality in the circulation in the EBUS. During spring, the most prominent signal in EBUS is characterized by a poleward displacement of subtropical high-pressure systems,



accompanied by stronger equatorward winds in the mid to high latitudes for some regions. This is associated with higher shortwave radiation, lower SST, and consistent increases in Ekman pumping nearshore. Similar conditions are observed during summer, with stronger winds in mid-latitude regions, lower SST nearshore, increased Qsw and similar Ep values. The principal spatial

pattern of variability resembles the differences between spring and summer, especially in terms of sea level pressure (SLP) and the meridional wind (Mw) (see [Figures 6, 7](#)). Despite the similarity among EBUS in terms of physical drivers for coastal upwelling, the specific responses can vary among regions. For instance, mid-latitude SST in Benguela rises from spring to summer ([Figures 6, 7](#)), consistent with previously reports results ([García-Reyes et al., 2023](#)), attributed to the impact of anticyclone intensity on lower-latitude sections of the Benguela system ([Bordbar et al., 2023](#)). [Mahlobo et al. \(2024\)](#) suggest that the change in intensity at the equator and consequent reduction in the wind-stress-curl-driven is decreasing due to the migration of the South Atlantic Subtropical High (SASH). Another notable difference among regions is the much greater surface area with meridional winds above 6 ms^{-1} at BenCS and C-ICS, especially in mid-latitude regions and towards the poles, contrasting with the more focalized increases in Mw at HumCS (30–40°S) and CalCS (35–45°N).

In recent decades studies focused on the C-ICS have indicated a rise in SST attributed to a weakening or reversal of the trade winds ([Vallis, 1986](#); [Saji et al., 1999](#); [Sambe et al., 2016](#)). Our findings confirm this warming trend, particularly evident in the first principal spatial pattern of variability from the SOM, showing a substantial increase in both spring and summer ([Figures 8, 9](#)). However, distinctive patterns emerge in the second and third spatial patterns of variability, particularly in BenCS and C-ICS (see [Supplementary Annex E](#)).

We found that the area affected by upwelling in Southern Hemisphere systems is larger in summer than in spring, which contrasts with the pattern observed for the Northern Hemisphere

TABLE 4 Upwelling metrics (Events/km² affected, mean duration and intensity defined in Section 2.3.1) from events detected (Section 2.3.2) in the 1993–2019 period.

EBUS	Metric	Spring	Summer
HumCS	Events/km ² affected	0.016	0.022
	Mean duration (d)	8.462	7.706
	Mean Intensity (°C)	-0.602	-1.150
BenCS	Events/km ² affected	0.007	0.008
	Mean duration (d)	6.034	5.840
	Mean Intensity (°C)	-1.126	-1.722
CalCS	Events/km ² affected	0.012	0.010
	Mean duration (d)	6.757	6.347
	Mean intensity (°C)	-1.336	-1.467
C-ICS	Events/km ² affected	0.010	0.007
	Mean duration (d)	5.949	5.873
	Mean Intensity (°C)	-1.293	-1.155

km² affected is defined as the spatial extent over which distinct upwelling events occurred during the analyzed time period.

systems (see Table 4). The occurrence of shorter and more intense upwelling events in spring (Table 4) aligns with the findings of Abrahams et al. (2021), despite differences in the spatial scope of the datasets used. Our study encompasses a broader dataset, extending beyond the coast. Other studies also support the idea that more upwelling events occur in spring. For instance, Miranda et al. (2013) and Tim et al. (2016) found more frequent high-intensity upwelling events from spring to summer in CalCS and C-ICS, similar to our results.

Our results showed no evidence supporting the Bakun hypothesis (Bakun, 1990) across EBUS upwelling centers, indicating an absence of consistent changes in ocean-land pressure or temperature gradients (see Figure 10). Similar findings have been reported in others studies (Ryckaczewski et al., 2015; Abrahams et al., 2021; Chang et al., 2023). One possible explanation for this lack of support for Bakun's hypothesis is the absence of deepening in the continental thermal low-pressure systems (CTLPS) with increasing temperatures (Ryckaczewski et al., 2015; Chamorro et al., 2021). Additionally, observations from recent decades (Sydeman et al., 2014), and evidence that winds in the EBUS are driven mainly by the position and intensity of the subtropical high-pressure system (SHPS) (García-Reyes et al., 2013; Schroeder et al., 2013; Flores-Aqueveque et al., 2020; Yang et al., 2022), suggest that wind intensity trends might be more sensitive to the poleward migration of the SHPS rather than to changes in the CTLPS (Bakun et al., 2015; Belmadani et al., 2014; Garreaud and Falvey, 2009; Ryckaczewski et al., 2015). Thus, the best explanation for the large-scale changes observed in these systems is the poleward displacement of the SHPS, driven by the expansion of Hadley Cells due to increased warming rates over the tropics relative to the equator. Our results show that the SHPS centers have indeed migrated poleward during spring and summer (Figures 8, 9, Table 3, Supplementary Material Figure S2), except for BenCS. This is consistent with previous studies on the HumCS (Ancapichún and Garcés-Vargas, 2015; Flores-Aqueveque et al., 2020; Weidberg et al., 2020), BenCS (Gilliland and Keim, 2018; Reboita et al., 2019), CalCS (Riyu, 2002; Song et al., 2018), and C-ICS (Yang et al., 2020; Zhou et al., 2021). Although these previous studies used a variety of datasets, methodologies, and spatio-temporal resolutions, they all support the hypothesis of upwelling intensification due to poleward SHPS migration and the resulting intensification of upwelling-favorable winds from mid to high latitudes (see Figures 8, 9). Our findings support this statement, except for the Humboldt system where no significant decadal changes were observed. This result differs from those of Sydeman et al. (2014) who reported that the C-ICS was the only system with non-significant wind trends in recent decades. Although all the SHPS showed a poleward displacement, not all were moving closer to the coast, especially in the South Atlantic (see BenCS in Table 4, Supplementary Material Figure S2). Most reanalysis products and climate models for this region typically exhibit considerable errors, including a severe warm bias in simulated SST, which tends to be accompanied by an erroneous westward shift of the South Atlantic Subtropical High (SASH) (Seager et al., 2003; Richter et al., 2012; Zilli and Carvalho, 2021).

Distinctive patterns are evident across all upwelling centers analyzed. Atmospheric variables (Pressure Gradient, Meridional wind) exhibited inconsistent changes, except for the HumCS, where PG and Mw increase in spring and decrease in summer. Lower-latitude upwelling centers display reduced Mw in the summer (i.e. CHI, CAL in HumCS and BLA, JUB in C-ICS). Oceanographic variables revealed a reduction in SST and MLD at mid-latitude centers, except in C-ICS during summer, similar to results reported from CMIP6 (Masson-Delmotte et al., 2021). However, diverging patterns are observed, with some regions displaying increased (spring) and reduced (summer) Ekman transport, and enhanced Ekman pumping solely in the HumCS and CalCS. Notably, despite certain upwelling centers sharing similar latitudes (e.g., Concepcion in HumCS and Pt. Concepcion in CalCS), observed changes differ. These differences might be partly explained by the unique dynamics under each center, influenced not only by atmospheric drivers such as SLP and Mw but also by factors such as hydrographic conditions, depth, coastline complexity, water masses, slope, and orientation (Table 2).

Many of the previous studies have described coastal upwelling without distinguishing between spring and summer (e.g. Gomez-Gesteira et al., 2006; Wang et al., 2015). Our results showed that patterns can differ and even be opposite between these two seasons. For instance, when analyzing the degree of change in the principal spatial pattern of variability for HumCS, a contrasting pattern is found for summer and spring, with a weakening of meridional wind at mid-latitude during summer, but a drop in SST throughout the system, particularly in the central region (see Figures 8, 9, top row). One possible explanation for this observation is the presence of extremely narrow at submarine canyons (i.e. the BioBio and the Itata canyons) which modify coastal circulation and induce upwelling of water from depths greater than 200 m even in the absence of upwelling-favorable winds (Sobarzo et al., 2001, 2016). Another potentially confounding factor is the coastal transition zone off central-southern Chile which is characterized by moderate levels of eddy kinetic energy generating intense mesoscale activity out to 600–800 km from the coast (Escribano and Morales, 2012). This apparent inconsistency highlights the importance of understanding the background conditions of ocean state (e.g. stratification, water masses, vertical structure) to better comprehend the sources of variability seasonally and interannually (Jacox et al., 2018; Bonino et al., 2019). A general summary of the results obtained in this study is presented in Table 5.

To our knowledge, this is the first study to compare multiple EBUS using nonlinear techniques that include a within-EBUS comparison of upwelling centers. The SOM offers distinct advantages over techniques like EOF analysis. First, SOM retains the topological properties of input data, preserving spatial relationships across spatio-temporal dimensions (Kalteh et al., 2008). Second, it enables continual learning and adaptation for ongoing refinement of data representation (Baçao et al., 2005). Finally, by using similarity measures during data organization, SOM adeptly captures complex nonlinear patterns and relationships, potentially overlooked by EOF analysis, which

TABLE 5 Overview of main findings in this study with indication of discrepancies or consistency with previous studies.

	HumCS	CalCS	BenCS	C-ICS
Primary Atmospheric Forcing Hypothesis				
Bakun Hypothesis	Not supported, similar to Abrahams et al. (2021) ; García-Reyes et al. (2013) , and Chang et al. (2023)	Not supported, similar to Rykczewski et al. (2015) an opposite to Sydeman et al. (2014)	Not supported, similar to Varela et al. (2015) and Rykczewski et al. (2015)	Not supported, similar to Barton et al. (2013) and Abrahams et al. (2021)
Subtropical Highs migration	Southwest, spring Southeast, summer Supported by Cherchi et al. (2018) and Aguirre et al. (2019)	Northeast, spring Northeast, summer Supported by Schmidt et al. (2020) and Cherchi et al. (2018)	Southwest, spring Southwest, summer Supported by Sperling et al. (2004) and Aguirre et al. (2019)	Northwest, spring Northeast, summer Supported by Polonsky and Serebrennikov (2020)
Upwelling metrics				
Spatial extension	Greater in spring, not enough evidence to contrast	Greater in spring, not enough evidence to contrast	Greater in summer, not enough evidence to contrast	Greater in summer, not enough evidence to contrast
Intensity	Higher in summer similar to Abrahams et al. (2021)	Higher in summer, similar to Brady et al. (2017)	Higher in summer similar to Miranda et al. (2013)	Higher in spring similar to Rixen et al. (2021)
Duration	Longer in spring similar to Abrahams et al. (2021)	Longer in spring, similar to Brady et al. (2017)	Longer in spring, and protracted upwelling season similar to Miranda et al. (2013) and Tim et al. (2016)	Longer in spring, similar to Rixen et al. (2021)
Decadal changes in SOM principal spatial pattern				
Seal level pressure (SLP)	Strong (Moderate) poleward increase in spring (summer), consistent with Chamorro et al. (2021) and Belmadani et al. (2014)	Strong poleward in spring and summer, similar to Arellano and Rivas (2019) and Pozo Buil et al. (2021)	Strong poleward in spring and summer similar to Miranda et al., 2013 ; Sylla et al., 2022)	Strong (Moderate) poleward increase in spring (summer) similar to Rixen et al., 2021)
Meridional wind (Mw)	Moderate (non-consistent) poleward increase in spring (summer), consistent with Oerder et al. (2015) and Goubanova et al. (2011) with reductions in the equator	Strong (Moderate) poleward increase in spring (summer) similar to Rykczewski et al. (2015) and Wang et al. (2015)	Strong (Moderate) poleward increase in spring (summer) similar to Miranda et al. (2013) , Lopes et al. (2014) and Sylla et al. (2022)	Strong poleward increase in both spring and summer
Shortwave radiation (Qsw)	Strong decrease towards the poles in both seasons, not enough evidence to contrast	Moderate increase (decrease) in spring (summer), not enough evidence to contrast	Strong decrease towards the poles in both seasons, not enough evidence to contrast	Insignificant increase (Significant decrease) in spring (summer), not enough evidence to contrast
Sea surface temperature (SST)	Strong decrease towards the pole in both seasons. Strong increases towards equator in spring similar to Abrahams et al. (2021) and Yari et al., 2023)	Strong increase towards the equator in both seasons. Moderate decreases toward the poles on spring, similar to Seabra et al. (2019)	Moderate decreases (increases) towards the poles (equator) contrary to Cropper et al. (2014) but similar to Barton et al. (2013) and Bode et al., 2019)	Moderate increases (decreases) towards the poles (equator) similar to Santos et al. (2012)
Ekman pumping (Ep)	Increasing nearshore in both seasons across the entire system, not enough evidence to contrast	Decreasing nearshore in both seasons across the entire system, not enough evidence to contrast	Insignificant changes nearshore in both seasons across the entire system, not enough evidence to contrast	Moderate increase in mid-latitudes during summer, not enough evidence to contrast

Columns represent upwelling systems, rows indicate features.

predominantly focuses on linear and orthogonal variable combinations ([Liu and Weisberg, 2011](#)). Despite its advantages, SOM has some drawbacks such as intricate algorithm design, increased computational requirements, sensitivity to critical hyperparameters (map size, learning rate, neighborhood function) and a susceptibility to overfitting when confronted with noisy or sparse data, potentially misrepresenting outliers or noise as significant patterns ([Kohonen and Somervuo, 1998](#); [Liu and Weisberg, 2011](#)). Our results, however, highlight previously unreported and distinct patterns. For instance, SST remains low

in the HumCS despite minimal changes in meridional wind (Mw), whereas Northern Hemisphere systems experience stronger Mw, especially in spring. Along the BenCS both Mw and SST have increased significantly in recent decades, potentially indicating that enhanced stratification could be a more influential factor in affecting coastal upwelling in some regions. These results illustrate the potential benefit of combining this method with other novel techniques including machine learning and deep learning, as they could help understand sources of variability that may remain indistinguishable through conventional methods.

Finally, an important aspect to discuss is the potential biases due to the data sources used. Coastal upwelling is a process manifested in temporal scales between 2–6 days and spatial scales between 25–150 km (Aguirre et al., 2019). There is a notable lack of high-resolution observational and model-derived datasets. For instance, results from CMIP5 and CMIP6 climate models reveal substantial natural variability, hampered by inadequate representation primarily due to their coarse resolution. This is a significant and challenging constraint (Small et al., 2015; Bindoff et al., 2019). In fact, most CMIP6 GCMs often display substantial overestimations across EBUS regions, except for the high-resolution models that exhibit better fidelity (Varela et al., 2022). This underscores the critical significance of utilizing high-resolution products.

Although retrieving higher-resolution data to analyze changes in upwelling centers would provide a more in-depth understanding of the magnitude and direction of these changes, substantial deviations from our results are not expected. This is because most of our findings are consistent with previous studies (Narayan et al., 2010; Sydeaman et al., 2014; García-Reyes et al., 2015; Rykaczewski et al., 2015; Wang et al., 2015). The results of this study can serve as a starting point for the more routine use of Artificial Intelligence techniques to identify questions that may guide future observational efforts. With a greater volume of datasets, novel approaches for processing and analyzing this data are required. Additionally, there are still many unknowns about the impacts of large-scale changes on coastal upwelling, particularly regarding non-periodical physical processes such as ENSO and extreme events like marine heatwaves. Finally, it is crucial to take in account the significant role of previous linear techniques, such as EOF, in shaping the understanding of coastal upwelling. We are confident that integrating these methods with novel approaches such as the one presented in this manuscript will enhance our comprehension of how coastal upwelling may evolve in the future.

5 Conclusions

Our study found no significant or consistent changes in land-ocean gradients across all upwelling centers, thus not supporting the Bakun hypothesis, which attributes upwelling intensification to increased land-ocean gradients. However, there was a coherent poleward increase in sea level pressure along all EBUS, accompanied by increases in upwelling-favorable winds, solar radiation, and Ekman pumping, as well as reductions in nearshore SST. These findings align with the current paradigm for explaining the increase in upwelling-favorable winds in subtropical EBUS, which is based on the expansion of the Hadley cells in a warmer climate, inducing a poleward migration of subtropical high-pressure systems. Despite the shared patterns across the EBUS studied, dominant spatial patterns of variability showed markedly dissimilar behaviors in certain systems, such as HumCS and C-ICS. For instance, SST and Ekman pumping patterns in the HumCS differed significantly from those observed in other systems.

To our knowledge, this study is one of the first to utilize AI techniques to analyze and compare upwelling dynamics across EBUS. Although our results largely align with previous studies, they also provide new insights. For instance, we identified differences in upwelling metrics between spring and summer periods across EBUS, noting shorter and more intense upwelling events during the transition from spring to summer. Additionally, we observed an onshore migration of the SHPS in some systems such as BenCS during summer, while significant interannual changes in the dominant spatial pattern of upwelling variability were evident in systems such as HumCS and BenCS, during both seasons. Therefore, integrating this type of approach into the oceanographer's toolkit can uncover overlooked aspects of variability in coastal upwelling and related phenomena.

Data availability statement

The raw data supporting the conclusions of this article will be made available by the authors, without undue reservation.

Author contributions

DB: Conceptualization, Data curation, Formal analysis, Investigation, Methodology, Software, Validation, Visualization, Writing – original draft. DN: Supervision, Writing – review & editing. BD: Writing – review & editing. VO: Writing – review & editing. MV: Writing – review & editing. FT: Writing – review & editing.

Funding

The author(s) declare financial support was received for the research, authorship, and/or publication of this article. DFB acknowledges support from ANID scholarship Doctorado Nacional 2021-21210079. DAN, FT and BD are partially funded by COPAS Coastal ANID FB210021. BD also acknowledges support from ANID (Concurso de Fortalecimiento al Desarrollo Científico de Centros Regionales 2020- R20F0008-CEAZA and Fondecyt Regular N°1231174). BD was also supported by the EU H2020 FutureMares project (Theme LC-CLA-06-2019, Grant agreement No 869300).

Acknowledgments

DB acknowledges support from ANID scholarship Doctorado Nacional 2021-21210079. DN, FT and BD are partially funded by COPAS Coastal ANID FB210021. BD also acknowledges support from ANID (Concurso de Fortalecimiento al Desarrollo Científico de Centros Regionales 2020-R20F0008-CEAZA and Fondecyt Regular N°1231174).

Conflict of interest

The authors declare that the research was conducted in the absence of any commercial or financial relationships that could be construed as a potential conflict of interest.

Publisher's note

All claims expressed in this article are solely those of the authors and do not necessarily represent those of their affiliated

organizations, or those of the publisher, the editors and the reviewers. Any product that may be evaluated in this article, or claim that may be made by its manufacturer, is not guaranteed or endorsed by the publisher.

Supplementary material

The Supplementary Material for this article can be found online at: <https://www.frontiersin.org/articles/10.3389/fmars.2024.1446766/full#supplementary-material>

References

- Abrahams, A., Schlegel, R. W., and Smit, A. J. (2021). Variation and change of upwelling dynamics detected in the world's eastern boundary upwelling systems. *Front. Mar. Sci.* 8, 626411. doi: 10.3389/fmars.2021.626411
- Aguirre, C., Garreaud, R., Belmar, L., Farias, L., Ramajo, L., and Barrera, F. (2021). High-frequency variability of the surface ocean properties off central Chile during the upwelling season. *Front. Mar. Sci.* 8, 702051. doi: 10.3389/fmars.2021.702051
- Aguirre, C., Rojas, M., Garreaud, R. D., and Rahn, D. A. (2019). Role of synoptic activity on projected changes in upwelling-favourable winds at the ocean's eastern boundaries. *NPJ Climate Atmospheric Sci.* 2, 44. doi: 10.1038/s41612-019-0101-9
- Aguirre, C., Pizarro, O., Strub, P. T., Garreaud, R., and Barth, J. A. (2012). Seasonal dynamics of the near-surface alongshore flow off central Chile. *J. Geophys. Res.* 117, C01006. doi: 10.1029/2011JC007379
- Alvarez, I., Gomez-Gesteira, M., deCastro, M., and Dias, J. (2008). Spatiotemporal evolution of upwelling regime along the western coast of the Iberian Peninsula. *J. Geophys. Res.* 113, C07020. doi: 10.1029/2008JC004744
- Anapichin, S., and Garcés-Vargas, J. (2015). Variability of the Southeast Pacific Subtropical Anticyclone and its impact on sea surface temperature off north-central Chile. *Cienc. Marinas* 41, 1–20. doi: 10.7773/cm.v41i1.2338
- Andrews, W. R. H., and Hutchings, L. (1980). Upwelling in the southern benguela current. *Prog. Oceanography* 9, 1–81. doi: 10.1016/0079-6611(80)90015-4
- Arellano, B., and Rivas, D. (2019). Coastal upwelling will intensify along the Baja California coast under climate change by mid-21st century: Insights from a GCM-nested physical-NPZD coupled numerical ocean model. *J. Mar. Syst.* 199, 103207. doi: 10.1016/j.jmarsys.2019.103207
- Baço, F., Lobo, V., and Painho, M. (2005). The self-organizing map, the Geo-SOM, and relevant variants for geosciences. *Comput. geosciences* 31, 155–163. doi: 10.1016/j.cageo.2004.06.013
- Bakun, A. (1990). Global climate change and intensification of coastal ocean upwelling. *Science* 247, 198–201. doi: 10.1126/science.247.4939.198
- Bakun, A., Black, B. A., Bograd, S. J., Garcia-Reyes, M., Miller, A. J., Rykaczewski, R. R., et al. (2015). Anticipated effects of climate change on coastal upwelling ecosystems. *Curr. Climate Change Rep.* 1, 85–93. doi: 10.1007/s40641-015-0008-4
- Barton, E. D., Field, D. B., and Roy, C. (2013). Canary current upwelling: More or less? *Prog. Oceanography* 116, 167–178. doi: 10.1016/j.pocan.2013.07.007
- Belmadani, A., Echevin, V., Codron, F., Takahashi, K., and Junquas, C. (2014). What dynamics drive future wind scenarios for coastal upwelling off Peru and Chile? *Climate dynamics* 43, 1893–1914. doi: 10.1007/s00382-013-2015-2
- Benazzouz, A., Mordane, S., Orbi, A., Chagdali, M., Hilmi, K., Atillah, A., et al. (2014). An improved coastal upwelling index from sea surface temperature using satellite-based approach – The case of the Canary Current upwelling system. *Continental Shelf Res.* 81, 38–54. doi: 10.1016/j.csr.2014.03.012
- Bindoff, N. L., Cheung, W. W., Kairo, J. G., Aristegui, J., Guinder, V. A., Hallberg, R., et al. (2019). Changing Ocean, Marine Ecosystems, and Dependent Communities. In: *IPCC Special Report on the Ocean and Cryosphere in a Changing Climate* [H. Pörtner, D. C. Roberts, V. Masson-Delmotte, P. Zhai, M. Tignor, E. Poloczanska, et al. (eds.)]. Cambridge University Press, Cambridge, UK and New York, NY, USA, pp. 447–587. doi: 10.1017/9781009157964.007
- Bode, A., Álvarez, M., Ruiz-Villareal, M., and Varela, M. M. (2019). Changes in phytoplankton production and upwelling intensity off A Coruña (NW Spain) for the last 28 years. *Ocean Dynamics* 69, 861–873. doi: 10.1007/s10236-019-01278-y
- Bograd, S. J., Jaxco, M. G., Hazen, E. L., Lovecchio, E., Montes, I., Pozo Buil, M., et al. (2023). Climate change impacts on eastern boundary upwelling systems. *Annu. Rev. Mar. Sci.* 15 (1), 303–328. doi: 10.1146/annurev-marine-032122-021945
- Boje, R., and Tomczak, M. (2012). *Upwelling ecosystems*. (Berlin-Heidelberg-New York: Springer Science & Business Media) 1978, 1–303.
- Bonino, G., Di Lorenzo, E., Masina, S., and Iovino, D. (2019). Interannual to decadal variability within and across the major Eastern Boundary Upwelling Systems. *Sci. Rep.* 9, 19949. doi: 10.1038/s41598-019-56514-8
- Bordbar, M. H., Mohrholz, V., and Schmidt, M. (2023). Low confidence in multi-decadal trends of wind-driven upwelling across the Benguela Upwelling System. *Earth System Dynamics* 14, 1065–1080. doi: 10.5194/esd-14-1065-2023
- Brady, R. X., Alexander, M. A., Lovenduski, N. S., and Rykaczewski, R. R. (2017). Emergent anthropogenic trends in California Current upwelling. *Geophysical Res. Lett.* 44, 5044–5052. doi: 10.1002/2017GL072945
- Brink, K. H. (1983). The near-surface dynamics of coastal upwelling. *Prog. Oceanography* 12, 223–257. doi: 10.1016/0079-6611(83)90009-5
- Chamorro, A., Echevin, V., Duthiel, C., Tam, J., Gutiérrez, D., and Colas, F. (2021). Projection of upwelling-favorable winds in the Peruvian upwelling system under the RCP8.5 scenario using a high-resolution regional model. *Climate Dynamics* 57, 1–16. doi: 10.1007/s00382-021-05689-w
- Chang, P., Xu, G., Kurian, J., Small, R. J., Danabasoglu, G., Yeager, S., et al. (2023). Uncertain future of sustainable fisheries environment in eastern boundary upwelling zones under climate change. *Commun. Earth Environ.* 4, 19. doi: 10.1038/s43247-023-00681-0
- Chavez, F. P., and Messié, M. (2009). A comparison of eastern boundary upwelling ecosystems. *Prog. Oceanography* 83, 80–96. doi: 10.1016/j.pocan.2009.07.032
- Chen, J., Adams, A., Wadhwa, N., and Hasinoff, S. W. (2016). Bilateral guided upsampling. *ACM Trans. Graphics (TOG)* 35, 1–8. doi: 10.1145/2980179.2982423
- Cherchi, A., Ambrizzi, T., Behera, S., Freitas, A. C. V., Morioka, Y., and Zhou, T. (2018). The response of subtropical highs to climate change. *Curr. Climate Change Rep.* 4, 371–382. doi: 10.1007/s40641-018-0114-1
- Cropper, T. E., Hanna, E., and Bigg, G. R. (2014). Spatial and temporal seasonal trends in coastal upwelling off Northwest Africa 1981–2012. *Deep Sea Res. Part I: Oceanographic Res. Papers* 86, 94–111. doi: 10.1016/j.dsr.2014.01.007
- Degola, T. S. D. (2013). *Impacts and variability of the South Atlantic subtropical anticyclone on Brazil in the present climate and in future scenarios* (Brazil: University of São Paulo São Paulo).
- Dorschel, B., Hehemann, L., Viquerat, S., Warnke, F., Dreutter, S., Tenberge, Y. S., et al. (2022). The international bathymetric chart of the southern ocean version 2. *Sci. Data* 9, 275. doi: 10.1038/s41597-022-01366-7
- Dreyfus, G., Badran, F., Yacoub, M., and Thiria, S. (2005). Self-organizing maps and unsupervised classification. *Neural networks: Method. Appl.* 379–442.
- Ekman, V. W. (1905). On the influence of the earth's rotation on ocean-currents. *Arkiv För Matematik, Astronomi och Fysik*, Bd 2, No 11, 1–53.
- Escribano, R., and Morales, C. E. (2012). Spatial and temporal scales of variability in the coastal upwelling and coastal transition zones off central-southern Chile (35–40 S). *Progress in Oceanography* 92, 1–7.
- Espinoza-Morriberón, D., Echevin, V., Colas, F., Tam, J., Ledesma, J., Vásquez, L., et al. (2017). Impacts of El Niño events on the Peruvian upwelling system productivity. *J. Geophysical Research: Oceans* 122, 5423–5444. doi: 10.1002/2016JC012439
- Estrade, P., Marchesiello, P., De Verdière, A. C., and Roy, C. (2008). Cross-shelf structure of coastal upwelling: A two-dimensional extension of Ekman's theory and a mechanism for inner shelf upwelling shut down. *J. Mar. Res.* 66, 589–616. doi: 10.1357/002224008787536790
- FAO (2022). *The State of World Fisheries and Aquaculture 2022*. (Rome, FAO: Towards Blue Transformation).
- Fielding, P. J., and Davis, C. L. (1989). Carbon and nitrogen resources available to kelp bed filter feeders in an upwelling environment. *Mar. Ecol. Prog. Ser.*, 181–189. doi: 10.3354/meps055181

- Flores-Aqueveque, V., Rojas, M., Aguirre, C., Arias, P. A., and González, C. (2020). South Pacific Subtropical High from the late Holocene to the end of the 21st century: insights from climate proxies and general circulation models. *Climate Past* 16, 79–99. doi: 10.5194/cp-16-79-2020
- Fransner, F., Counillon, F., Bethke, I., Tjiputra, J., Samuelsen, A., Nummelin, A., et al. (2020). Ocean biogeochemical predictions—initialization and limits of predictability. *Front. Mar. Sci.* 7, 386. doi: 10.3389/fmars.2020.00386
- Friererson, D. M., Lu, J., and Chen, G. (2007). Width of the Hadley cell in simple and comprehensive general circulation models. *Geophysical Res. Lett.* 34, L18804. doi: 10.1029/2007GL031115
- García-Reyes, M., Koval, G., Sydean, W. J., Palacios, D., Bedriñana-Romano, L., DeForest, K., et al. (2023). Most eastern boundary upwelling regions represent thermal refugia in the age of climate change. *Front. Mar. Sci.* 10, 1158472. doi: 10.3389/fmars.2023.1158472
- García-Reyes, M., and Largier, J. L. (2012). Seasonality of coastal upwelling off central and northern California: New insights, including temporal and spatial variability. *J. Geophysical Research: Oceans* 117, C03028. doi: 10.1029/2011JC007629
- García-Reyes, M., Sydean, W. J., Black, B. A., Rykaczewski, R. R., Schoeman, D. S., Thompson, S. A., et al. (2013). Relative influence of oceanic and terrestrial pressure systems in driving upwelling-favorable winds. *Geophysical Res. Lett.* 40, 5311–5315. doi: 10.1002/2013GL057729
- García-Reyes, M., Sydean, W. J., Schoeman, D. S., Rykaczewski, R. R., Black, B. A., Smit, A. J., et al. (2015). Under pressure: Climate change, upwelling, and eastern boundary upwelling ecosystems. *Front. Mar. Sci.* 2, 109. doi: 10.3389/fmars.2015.00109
- Garreaud, R. D., and Falvey, M. (2009). The coastal winds off western subtropical South America in future climate scenarios. *Int. J. Climatology: A J. R. Meteorological Soc.* 29, 543–554. doi: 10.1029/2008JD010519
- Gaube, P., Chelton, D. B., Samelson, R. M., Schlax, M. G., and O'Neill, L. W. (2015). Satellite observations of mesoscale eddy-induced Ekman pumping. *J. Phys. Oceanography* 45, 104–132. doi: 10.1175/JPO-D-14-0032.1
- Gibson, P. B., Perkins-Kirkpatrick, S. E., Uotila, P., Pepler, A. S., and Alexander, L. V. (2017). On the use of self-organizing maps for studying climate extremes. *J. Geophysical Research: Atmospheres* 122, 3891–3903. doi: 10.1002/2016JD026256
- Gilliland, J. M., and Keim, B. D. (2018). Position of the South Atlantic Anticyclone and its impact on surface conditions across Brazil. *J. Appl. Meteorology Climatology* 57, 535–553. doi: 10.1175/JAMC-D-17-0178.1
- Gomez-Gesteira, M., Moreira, C., Alvarez, I., and DeCastro, M. (2006). Ekman transport along the Galician coast (northwest Spain) calculated from forecasted winds. *J. Geophysical Research: Oceans* 111, C10005. doi: 10.1029/2005JC003331
- Goubanova, K., Echevin, V., Dewitte, B., Codron, F., Takahashi, K., Terray, P., et al. (2011). Statistical downscaling of sea-surface wind over the Peru–Chile upwelling region: diagnosing the impact of climate change from the IPSL-CM4 model. *Climate Dynamics* 36, 1365–1378. doi: 10.1007/s00382-010-0824-0
- Goubanova, K., Illig, S., Machu, E., Garçon, V., and Dewitte, B. (2013). SST subseasonal variability in the central Benguela upwelling system as inferred from satellite observations, (1999–2009). *J. Geophysical Research: Oceans* 118, 4092–4110. doi: 10.1002/jgrc.20287
- Grise, K. M., and Davis, S. M. (2020). Hadley cell expansion in CMIP6 models. *Atmospheric Chem. Phys.* 20, 5249–5268. doi: 10.5194/acp-20-5249-2020
- Grise, K. M., Davis, S. M., Staten, P. W., and Adam, O. (2018). Regional and seasonal characteristics of the recent expansion of the tropics. *J. Climate* 31, 6839–6856. doi: 10.1175/JCLI-D-18-0060.1
- Groom, S., Sathyendranath, S., Ban, Y., Bernard, S., Brewin, R., Brotas, V., et al. (2019). Satellite ocean colour: current status and future perspective. *Front. Mar. Sci.* 6, 485. doi: 10.3389/fmars.2019.00485
- Gruber, N., Lachkar, Z., Frenzel, H., Marchesio, P., Münnich, M., McWilliams, J. C., et al. (2011). Eddy-induced reduction of biological production in eastern boundary upwelling systems. *Nat. Geosci.* 4, 787–792. doi: 10.1038/ngeo1273
- Hannachi, A., Jolliffe, I. T., Stephenson, D. B., and Trendafilov, N. (2006). In search of simple structures in climate: simplifying EOFs. *Int. J. Climatology: A J. R. Meteorological Soc.* 26, 7–28. doi: 10.1002/joc.1243
- Hill, C., DeLuca, C., Suarez, M., and Da Silva, A. (2004). The architecture of the earth system modeling framework. *Computing Sci. Eng.* 6, 18–28. doi: 10.1109/MCISE.2004.1255817
- Hu, Y., Tao, L., and Liu, J. (2013). Poleward expansion of the Hadley circulation in CMIP5 simulations. *Adv. Atmospheric Sci.* 30, 790–795. doi: 10.1007/s00376-012-2187-4
- Hurrell, J. W., Holland, M. M., Gent, P. R., Ghan, S., Kay, J. E., Kushner, P. J., et al. (2013). The community earth system model: a framework for collaborative research. *Bull. Am. Meteorological Soc.* 94, 1339–1360. doi: 10.1175/BAMS-D-12-00121.1
- Jacox, M. G., Edwards, C. A., Hazen, E. L., and Bograd, S. J. (2018). Coastal upwelling revisited: Ekman, Bakun, and improved upwelling indices for the US West Coast. *J. Geophysical Research: Oceans* 123, 7332–7350. doi: 10.1029/2018JC014187
- Jacox, M. G., Fiechter, J., Moore, A. M., and Edwards, C. A. (2015). ENSO and the California current coastal upwelling response. *J. Geophysical Research: Oceans* 120, 1691–1702. doi: 10.1002/2014JC010650
- Jain, A. K., Murty, M. N., and Flynn, P. J. (1999). Data clustering: a review. *ACM computing surveys (CSUR)* 31, 264–323. doi: 10.1145/331499.331504
- Jebri, F., Srokosz, M., Jacobs, Z. L., Nencioli, F., and Popova, E. (2022). Earth observation and machine learning reveal the dynamics of productive upwelling regimes on the agulhas bank. *Front. Mar. Sci.* 629. doi: 10.3389/fmars.2022.872515
- Jouini, M., Béranger, K., Arsouze, T., Beuvier, J., Thiria, S., Crépon, M., et al. (2016). The Sicily Channel surface circulation revisited using a neural clustering analysis of a high-resolution simulation. *J. Geophysical Research: Oceans* 121, 4545–4567. doi: 10.1002/2015JC011472
- Kalthe, A. M., Hjorth, P., and Berndtsson, R. (2008). Review of the self-organizing map (SOM) approach in water resources: Analysis, modelling and application. *Environ. Model. Software* 23, 835–845. doi: 10.1016/j.envsoft.2007.10.001
- Kämpf, J., and Chapman, P. (2016). *Upwelling Systems of the World*. (Switzerland: Springer International Publishing), 31–42.
- Kohonen, T., and Somervuo, P. (1998). Self-organizing maps of symbol strings. *Neurocomputing* 21, 19–30. doi: 10.1016/S0925-2312(98)00031-9
- Lachkar, Z., and Gruber, N. (2012). A comparative study of biological production in eastern boundary upwelling systems using an artificial neural network. *Biogeosciences* 9, 293–308. doi: 10.5194/bg-9-293-2012
- Lambert, S. J. (1988). A cyclone climatology of the Canadian Climate Centre general circulation model. *J. Climate* 1, 109–115. doi: 10.1175/1520-0442(1988)001<0109:ACCOTC>2.0.CO;2
- Lamont, T., García-Reyes, M., Bograd, S. J., van der Lingen, C. D., and Sydean, W. J. (2018). Upwelling indices for comparative ecosystem studies: Variability in the Benguela Upwelling System. *J. Mar. Syst.* 188, 3–16. doi: 10.1016/j.jmarsys.2017.05.007
- Large, W. G., and Danabasoglu, G. (2006). Attribution and impacts of upper-ocean biases in CCSM3. *J. Climate* 19, 2325–2346. doi: 10.1175/JCLI3740.1
- Le Bars, D., Viebahn, J. P., and Dijkstra, H. A. (2016). A Southern Ocean mode of multidecadal variability. *Geophysical Res. Lett.* 43, 2102–2110. doi: 10.1002/2016GL068177
- Li, Y., Yang, Z., and Han, K. (2020). Research on the clustering algorithm of ocean big data based on self-organizing neural network. *Comput. Intell.* 36, 1609–1620. doi: 10.1111/coin.12299
- Liu, Y., Chen, W., Chen, Y., Chen, W., Ma, L., and Meng, Z. (2021). Ocean front reconstruction method based on k-means algorithm iterative hierarchical clustering sound speed profile. *J. Mar. Sci. Eng.* 9, 1233. doi: 10.3390/jmse9111233
- Liu, Y., and Weisberg, R. H. (2011). A review of self-organizing map applications in meteorology and oceanography. *Self-organizing maps: Appl. novel algorithm design* 1, 253–272.
- Liu, Y., Weisberg, R. H., and He, R. (2006). Sea surface temperature patterns on the West Florida Shelf using growing hierarchical self-organizing maps. *J. Atmospheric Oceanic Technol.* 23, 325–338. doi: 10.1175/JTECH1848.1
- Lopes, J. F., Ferreira, J. A., Cardoso, A. C., and Rocha, A. C. (2014). Variability of temperature and chlorophyll of the Iberian Peninsula near coastal ecosystem during an upwelling event for the present climate and a future climate scenario. *J. Mar. Syst.* 129, 271–288. doi: 10.1016/j.jmarsys.2013.07.002
- Lu, J., Vecchi, G. A., and Reichler, T. (2007). Expansion of the Hadley cell under global warming. *Geophysical Res. Lett.* 34, L06805. doi: 10.1029/2006GL028443
- Mahlobo, D., Engelbrecht, F., Ndarana, T., et al. (2024). Analysis of the Hadley cell, subtropical anticyclones and their effect on South African rainfall. *Theor Appl Climatol* 155, 1035–1054. doi: 10.1007/s00704-023-04674-z
- Masson-Delmotte, V., Zhai, P., Pirani, A., Connors, S. L., Péan, C., Berger, S., et al. (2021). Climate change 2021: the physical science basis. Contribution of working group I to the sixth assessment report of the intergovernmental panel on climate change. Cambridge, United Kingdom and New York, NY, USA: Cambridge University Press. Available at: <http://hdl.handle.net/10204/12710>
- Miranda, P. M. A., Alves, J. M. R., and Serra, N. (2013). Climate change and upwelling: response of Iberian upwelling to atmospheric forcing in a regional climate scenario. *Climate dynamics* 40, 2813–2824. doi: 10.1007/s00382-012-1442-9
- Montecino, V., and Lange, C. B. (2009). The Humboldt Current System: Ecosystem components and processes, fisheries, and sediment studies. *Prog. Oceanography* 83, 65–79. doi: 10.1016/j.pocan.2009.07.041
- Murray, R. J., and Simmonds, I. (1991). A numerical scheme for tracking cyclone centres from digital data. *Aust. meteorological magazine* 39, 155–166.
- Murtagh, F., and Legendre, P. (2014). Ward's hierarchical agglomerative clustering method: which algorithms implement Ward's criterion? *J. classification* 31, 274–295. doi: 10.1007/s00357-014-9161-z
- Naik, D., and Shah, P. (2014). A review on image segmentation clustering algorithms. *Int. J. Comput. Sci. Inform. Technol.* 5, 3289–3293.
- Nakaoka, S.-I., Telszewski, M., Nojiri, Y., Yasunaka, S., Miyazaki, C., Mukai, H., et al. (2013). Estimating temporal and spatial variation of ocean surface pCO₂ in the North Pacific using a self-organizing map neural network technique. *Biogeosciences* 10, 6093–6106. doi: 10.5194/bg-10-6093-2013
- Napierala, M. A. (2012). What is the bonferroni correction? *Aaos Now*, 40–41.

- Narayan, N., Paul, A., Multiza, S., and Schulz, M. (2010). Trends in coastal upwelling intensity during the late 20th century. *Ocean Sci.* 6, 815–823. doi: 10.5194/os-6-815-2010
- Nielsen, F., and Nielsen, F. (2016). Hierarchical clustering. *Introduction to HPC MPI Data Sci.*, 195–211. doi: 10.1007/978-3-319-21903-5
- North, G. R. (1984). Empirical orthogonal functions and normal modes. *J. Atmospheric Sci.* 41, 879–887. doi: 10.1175/1520-0469(1984)041<0879: EOFANM>2.0.CO;2
- Oerder, V., Colas, F., Echevin, V., Codron, F., Tam, J., and Belmadani, A. (2015). Peru-Chile upwelling dynamics under climate change. *J. Geophysical Research: Oceans* 120, 1152–1172. doi: 10.1002/2014JC010299
- Oyarzun, D., and Brierley, C. M. (2019). The future of coastal upwelling in the Humboldt current from model projections. *Climate dynamics* 52, 599–615. doi: 10.1007/s00382-018-4158-7
- Patti, B., Guisande, C., Riveiro, I., Thejll, P., Cuttitta, A., Bonanno, A., et al. (2010). Effect of atmospheric CO₂ and solar activity on wind regime and water column stability in the major global upwelling areas. *Estuarine Coast. Shelf Sci.* 88, 45–52. doi: 10.1016/j.ecss.2010.03.004
- Perneger, T. V. (1998). What's wrong with Bonferroni adjustments. *Bmj* 316, 1236–1238. doi: 10.1136/bmj.316.7139.1236
- Polonsky, A. B., and Serebrennikov, A. N. (2020). On the change in the sea surface temperature in the Benguela upwelling region: Part II. Long-term tendencies. *Izvestiya Atmospheric Oceanic Phys.* 56, 970–978. doi: 10.1134/S0001433820090200
- Pozo Buil, M., Jacox, M. G., Fiechter, J., Alexander, M. A., Bograd, S. J., Curchitser, E. N., et al. (2021). A dynamically downscaled ensemble of future projections for the California current system. *Front. Mar. Sci.* 8, 612874. doi: 10.3389/fmars.2021.612874
- Qian, Y., Jackson, C., Giorgi, F., Booth, B., Duan, Q., Forest, C., et al. (2016). Uncertainty quantification in climate modeling and projection. *Bull. Am. Meteorological Soc.* 97, 821–824. doi: 10.1175/BAMS-D-15-00297.1
- Reboita, M. S., Ambrizzi, T., Silva, B. A., Pinheiro, R. F., and Da Rocha, R. P. (2019). The South Atlantic subtropical anticyclone: present and future climate. *Front. Earth Sci.* 7, 8. doi: 10.3389/feart.2019.00008
- Renault, L., Dewitte, B., Falvey, M., Garreaud, R., Echevin, V., and Bonjean, F. (2009). Impact of atmospheric coastal jet off central Chile on sea surface temperature from satellite observations, (2000–2007). *J. Geophysical Research: Oceans* 114, C08006. doi: 10.1029/2008JC005083
- Richardson, A. J., Risien, C., and Shillington, F. A. (2003). Using self-organizing maps to identify patterns in satellite imagery. *Prog. Oceanography* 59, 223–239. doi: 10.1016/j.pocan.2003.07.006
- Richter, I., Xie, S.-P., Wittenberg, A. T., and Masumoto, Y. (2012). Tropical Atlantic biases and their relation to surface wind stress and terrestrial precipitation. *Climate dynamics* 38, 985–1001. doi: 10.1007/s00382-011-1038-9
- Rixen, T., Lahajnar, N., Lamont, T., Koppelman, R., Martin, B., Van Beusekom, J. E., et al. (2021). Oxygen and nutrient trapping in the southern Benguela upwelling system. *Front. Mar. Sci.* 8, 730591. doi: 10.3389/fmars.2021.730591
- Riyu, L. (2002). Indices of the summertime western North Pacific subtropical high. *Adv. Atmospheric Sci.* 19, 1004–1028. doi: 10.1007/s00376-002-0061-5
- Rykaczewski, R. R., Dunne, J. P., Sydeman, W. J., Garcia-Reyes, M., Black, B. A., and Bograd, S. J. (2015). Poleward displacement of coastal upwelling-favorable winds in the ocean's eastern boundary currents through the 21st century. *Geophysical Res. Lett.* 42, 6424–6431. doi: 10.1002/2015GL064694
- Saji, N. H., Goswami, B. N., Vinayachandran, P. N., and Yamagata, T. (1999). A dipole mode in the tropical Indian Ocean. *Nature* 401, 360–363. doi: 10.1038/43854
- Sambe, B., Tandstad, M., Caramelo, A. M., and Brown, B. E. (2016). Variations in productivity of the Canary Current Large Marine Ecosystem and their effects on small pelagic fish stocks. *Environ. Dev.* 17, 105–117. doi: 10.1016/j.envdev.2015.11.012
- Santos, F., Gomez-Gesteira, M., Decastro, M., and Alvarez, I. (2012). Differences in coastal and oceanic SST trends due to the strengthening of coastal upwelling along the Benguela current system. *Continental Shelf Res.* 34, 79–86. doi: 10.1016/j.csr.2011.12.004
- Saraceno, M., Provost, C., and Lebbah, M. (2006). Biophysical regions identification using an artificial neural network: A case study in the South Western Atlantic. *Adv. Space Res.* 37, 793–805. doi: 10.1016/j.asr.2005.11.005
- Schlegel, R. W., and Smit, A. J. (2018). heatwaveR: A central algorithm for the detection of heatwaves and cold-spells. *J. Open Source Software* 3, 821. doi: 10.21105/joss.00821
- Schmidt, D. F., Amaya, D. J., Grise, K. M., and Miller, A. J. (2020). Impacts of shifting subtropical highs on the California Current and Canary Current systems. *Geophysical Res. Lett.* 47, e2020GL088996. doi: 10.1029/2020GL088996
- Schroeder, I. D., Black, B. A., Sydeman, W. J., Bograd, S. J., Hazen, E. L., Santora, J. A., et al. (2013). The North Pacific High and wintertime pre-conditioning of California current productivity. *Geophysical Res. Lett.* 40, 541–546. doi: 10.1002/grl.50100
- Seabra, R., Varela, R., Santos, A. M., Gómez-Gesteira, M., Meneghesso, C., Wethey, D. S., et al. (2019). Reduced nearshore warming associated with eastern boundary upwelling systems. *Front. Mar. Sci.* 6, 104. doi: 10.3389/fmars.2019.00104
- Seager, R., Murtugudde, R., Naik, N., Clement, A., Gordon, N., and Miller, J. (2003). Air-sea interaction and the seasonal cycle of the subtropical anticyclones. *J. Climate* 16, 1948–1966. doi: 10.1175/1520-0442(2003)016<1948:AIATSC>2.0.CO;2
- Small, R. J., Curchitser, E., Hedstrom, K., Kauffman, B., and Large, W. G. (2015). The Benguela upwelling system: Quantifying the sensitivity to resolution and coastal wind representation in a global climate model. *J. Climate* 28, 9409–9432. doi: 10.1175/JCLI-D-15-0192.1
- Sobarzo, M., Figueroa, M., and Djurfeldt, L. (2001). Upwelling of subsurface water into the rim of the Biobio submarine canyon as a response to surface winds. *Continental Shelf Res.* 21, 279–299. doi: 10.1016/S0278-4343(00)00082-0
- Sobarzo, M., Saldias, G. S., Tapia, F. J., Bravo, L., Moffat, C., and Largier, J. L. (2016). On subsurface cooling associated with the Biobio River Canyon (Chile). *J. Geophysical Research: Oceans* 121, 4568–4584. doi: 10.1002/2016JC011796
- Song, F., Leung, L. R., Lu, J., and Dong, L. (2018). Future changes in seasonality of the North Pacific and North Atlantic subtropical highs. *Geophysical Res. Lett.* 45, 11,959–11,968. doi: 10.1029/2018GL079940
- Sonnemwald, M., Lguensat, R., Jones, D. C., Dueben, P. D., Brajard, J., and Balaji, V. (2021). Bridging observations, theory and numerical simulation of the ocean using machine learning. *Environ. Res. Lett.* 16, 073008. doi: 10.1088/1748-9326/ac0eb0
- Sperling, F. N., Washington, R., and Whittaker, R. J. (2004). Future climate change of the subtropical North Atlantic: implications for the cloud forests of Tenerife. *Climatic Change* 65, 103–123. doi: 10.1023/B:CLIM.0000037488.33377.bf
- Stewart, R. H. (2008). Introduction to Physical Oceanography. *Texas A & M University*, 121–275.
- Sun, Y. (2000). On quantization error of self-organizing map network. *Neurocomputing* 34, 169–193. doi: 10.1016/S0925-2312(00)00292-7
- Sverdrup, H. U. (1947). Wind-driven currents in a baroclinic ocean; with application to the equatorial currents of the eastern Pacific. *Proc. Natl. Acad. Sci.* 33, 318–326. doi: 10.1073/pnas.33.11.318
- Sydeman, W. J., Garcia-Reyes, M., Schoeman, D. S., Rykaczewski, R. R., Thompson, S. A., Black, B. A., et al. (2014). Climate change and wind intensification in coastal upwelling ecosystems. *Science* 345, 77–80. doi: 10.1126/science.1251635
- Sylla, A., Sanchez Gomez, E., Mignot, J., and López-Parages, J. (2022). Impact of increased resolution on the representation of the Canary upwelling system in climate models. *Geoscientific Model. Dev.* 15, 8245–8267. doi: 10.5194/gmd-15-8245-2022
- Taboada, F. G., Stock, C. A., Griffies, S. M., Dunne, J., John, J. G., Small, R. J., et al. (2019). Surface winds from atmospheric reanalysis lead to contrasting oceanic forcing and coastal upwelling patterns. *Ocean Model.* 133, 79–111. doi: 10.1016/j.ocemod.2018.11.003
- Thiel, M., Castilla, J. C., Fernández, M., and Navarrete, S. (2007). The Humboldt current system of northern and central Chile. In: R. N. Gibson, R. J. A. Atkinson and J. D. Gordon. *Oceanography and Marine Biology: An annual review*. (CRC press). 45, pp. 195–345. doi: 10.1201/9781420050943
- Tim, N., Zorita, E., Hünicke, B., Yi, X., and Emeis, K.-C. (2016). The importance of external climate forcing for the variability and trends of coastal upwelling in past and future climate. *Ocean Sci.* 12, 807–823. doi: 10.5194/os-12-807-2016
- Tokina, H., and Xie, S.-P. (2011). Wave- and anemometer-based sea surface wind (WASWind) for climate change analysis. *J. Climate* 24, 267–285. doi: 10.1175/2010JCLI3789.1
- Vallis, G. K. (1986). El Niño: A chaotic dynamical system? *Science* 232, 243–245. doi: 10.1126/science.232.4747.243
- Varela, R., Alvarez, I., Santos, F., DeCastro, M., and Gómez-Gesteira, M. (2015). Has upwelling strengthened along worldwide coasts over 1982–2010? *Sci. Rep.* 5, 1–15. doi: 10.1038/srep10016
- Varela, R., DeCastro, M., Rodriguez-Diaz, L., Dias, J. M., and Gómez-Gesteira, M. (2022). Examining the ability of CMIP6 models to reproduce the upwelling SST imprint in the eastern boundary upwelling systems. *J. Mar. Sci. Eng.* 10 (12), 1970. doi: 10.3390/jmse10121970
- Varela, R., Lima, F. P., Seabra, R., Meneghesso, C., and Gómez-Gesteira, M. (2018). Coastal warming and wind-driven upwelling: a global analysis. *Sci. Total Environ.* 639, 1501–1511. doi: 10.1016/j.scitotenv.2018.05.273
- Vesanto, J., and Alhoniemi, E. (2000). Clustering of the self-organizing map. *IEEE Trans. Neural Networks* 11, 586–600. doi: 10.1109/72.846731
- Wagner, C. H. (1982). Simpson's paradox in real life. *Am. Statistician* 36, 46–48. doi: 10.1080/00031305.1982.10482778
- Wang, D., Gouhier, T. C., Menge, B. A., and Ganguly, A. R. (2015). Intensification and spatial homogenization of coastal upwelling under climate change. *Nature* 518, 390–394. doi: 10.1038/nature14235
- Weidberg, N., Ospina-Alvarez, A., Bonicelli, J., Barahona, M., Aiken, C. M., Broitman, B. R., et al. (2020). Spatial shifts in productivity of the coastal ocean over the past two decades induced by migration of the Pacific Anticyclone and Bakun's effect in the Humboldt Upwelling Ecosystem. *Global Planetary Change* 193, 103259. doi: 10.1016/j.gloplacha.2020.103259
- Xian, T., Xia, J., Wei, W., Zhang, Z., Wang, R., Wang, L.-P., et al. (2021). Is hadley cell expanding? *Atmosphere* 12 (12), 1699. doi: 10.3390/atmos12121699
- Yang, H., Lohmann, G., Krebs-Kanzow, U., Ionita, M., Shi, X., Sidorenko, D., et al. (2020). Poleward shift of the major ocean gyres detected in a warming climate. *Geophysical Res. Lett.* 47, e2019GL085868. doi: 10.1029/2019GL085868

Yang, H., Lu, J., Wang, Q., Shi, X., and Lohmann, G. (2022). Decoding the dynamics of poleward shifting climate zones using aqua-planet model simulations. *Climate Dynamics* 58, 3513–3526. doi: 10.1007/s00382-021-06112-0

Yari, S., Mohrholz, V., and Bordbar, M. H. (2023). Wind variability across the North Humboldt Upwelling System. *Front. Mar. Sci.* 10, 1087980. doi: 10.3389/fmars.2023.1087980

Zhou, W., Leung, L. R., Song, F., and Lu, J. (2021). Future changes in the Great Plains low-level jet governed by seasonally dependent pattern changes in the North Atlantic subtropical high. *Geophysical Res. Lett.* 48, e2020GL090356. doi: 10.1029/2020GL090356

Zilli, M. T., and Carvalho, L. M. (2021). Detection and attribution of precipitation trends associated with the poleward shift of the South Atlantic Convergence Zone using CMIP5 simulations. *Int. J. Climatology* 41, 3085–3106. doi: 10.1002/joc.7007

4.2 **Capítulo 2:** "Evolución temporal y espacial de la surgencia costera en sistemas EBUS bajo escenarios climáticos históricos y futuros (1982-2050)". Los resultados del manuscrito que se presenta a continuación corresponden al objetivo específico 2 de la tesis.

Resumen

Comprender los cambios futuros en la Temperatura Superficial del Mar (TSM) es de vital relevancia debido a las profundas implicaciones en ecosistemas marinos como los Sistemas de Afloramiento de Borde Oriental (EBUS). El experimento HighResMIP de CMIP6 surge como una herramienta fundamental para esta tarea, siendo el único con resoluciones oceánicas de hasta ~10 km. Por lo tanto, este estudio evalúa el desempeño de 6 modelos del experimento HighResMIP para determinar su desempeño en reproducir la firma de TSM de los eventos de surgencia. Los resultados muestran que la mayoría de los modelos sobreestiman la TSM, y que el modelo HadGEM-GC-31-HH destaca como el de mejor desempeño, en parte debido a su mayor resolución horizontal. Utilizando este modelo, se proyectaron las características de los eventos de surgencia para el período 2015-2050. El hallazgo más robusto es una disminución estadísticamente significativa en la frecuencia y duración de los eventos en los cuatro EBUS, mientras que los cambios en su intensidad son espacialmente heterogéneos. En conjunto, estos resultados sugieren una transición fundamental

hacia un régimen de afloramiento futuro más intermitente y esporádico. Estas conclusiones, no obstante, se derivan de un análisis en centros de surgencia específicos y deben considerarse a la luz de las incertidumbres asociadas a los sesgos inherentes del modelo en la franja costera.

Introducción

Desde hace más de un siglo, debido a los efectos del cambio climático, los océanos del mundo se han estado calentando, generando fenómenos extremos más frecuentes (Chen et al., 2011; Cheng et al., 2019; Roemmich et al., 2012) , que conducen a un aumento en la intensidad y duración de eventos extremos como las olas de calor marinas (Oliver et al., 2018), los eventos de precipitación intensa (O’Gorman, 2015), las sequías (Mukherjee et al., 2018), el aumento del nivel del mar (Hauer et al., 2020), entre otros (Pörtner et al., 2019). Estos eventos podrían tener un gran impacto en los sistemas de surgencia de borde oriental (en adelante EBUS) (Pauly & Christensen, 1995). Por lo tanto, comprender la dinámica y los cambios potenciales en los patrones de TSM y viento en estos sistemas es importante para el bienestar ecológico y económico de las comunidades que habitan estas zonas costeras (Large & Danabasoglu, 2006).

Los modelos climáticos son una de las herramientas más importantes para estudiar y predecir los impactos futuros del cambio climático, incluida la temperatura superficial del mar (TSM) (Shukla et al., 2019). Estos modelos

poseen la capacidad de abordar la escasez de observaciones disponibles y dilucidar la evolución potencial de diversas variables geofísicas bajo diferentes Trayectorias Socioeconómicas Compartidas (SSPs, por sus siglas en inglés) con un forzamiento radiativo que oscila entre 1.9 y 8.5 Wm⁻² para finales del siglo XXI (Bindoff et al., 2022).

A lo largo de su existencia, el Panel Intergubernamental sobre el Cambio Climático (IPCC) ha coordinado seis fases del Proyecto de Intercomparación de Modelos Acoplados (CMIP). Estas fases sucesivas comparten el objetivo general de profundizar en las trayectorias históricas, actuales y futuras del clima. Se ha demostrado que los resultados actuales de CMIP6 presentan varias mejoras en términos de resolución espacial y esquemas de parametrización mejorados para representar mejor los procesos físicos en comparación con los resultados de CMIP5 (Eyring et al., 2016; Taylor et al., 2012) y han mostrado un mejor desempeño en la reproducción de fenómenos extremos (Chen et al., 2020). Sin embargo, varios estudios han demostrado que los GCMs de CMIP6 han presentado dificultades para reproducir el comportamiento de la TSM costera, mostrando una clara sobreestimación para la mayoría de los EBUS, con la excepción del sistema de borde oriental de Canarias (Varela et al., 2022).

Uno de los mayores desafíos de los modelos del CMIP6 es la resolución horizontal, que causa una subestimación de las anomalías de TSM en regiones ricas en remolinos (Pilo et al., 2019) y una sobreestimación en las regiones de

afloramiento cercanas a la costa, asociada con dificultades para reproducir de manera realista la influencia de la impronta del afloramiento en la TSM (Varela et al., 2022).

Para abordar esta limitación, en 2020 se propuso un nuevo experimento denominado Proyecto de Intercomparación de Modelos de Alta Resolución (en adelante HighResMIP), que, siendo parte de CMIP6, es una opción ideal para investigar los patrones de TSM, entre otros factores (Eyring et al., 2016). El HighResMIP fue diseñado con dos objetivos principales: (a) realizar investigaciones a múltiples resoluciones horizontales para abordar algunas de las cuestiones más apremiantes sobre el cambio climático regional y (b) proporcionar proyecciones más fiables para una mejor planificación y estrategia frente al riesgo climático en las próximas décadas. Este experimento se presenta como una oportunidad para evaluar el desempeño de los modelos climáticos y su sensibilidad a la resolución horizontal de la atmósfera y el océano (Haarsma et al., 2016a).

Aunque numerosos estudios a escala global han evaluado los impactos de la resolución (Haarsma et al., 2016a; Liang-Liang et al., 2022; Moreno-Chamarro et al., 2021; Roberts et al., 2020; Squintu et al., 2021), los beneficios potenciales de usar modelos globales de alta resolución en los EBUS permanecen inexplorados, con solo un estudio que proporciona resultados sobre el desempeño de los modelos CMIP6 en los EBUS (Varela et al., 2022). Por lo tanto,

surge la necesidad de validar estos hallazgos previos utilizando metodologías alternativas para determinar su fiabilidad. Explorar esto podría optimizar la selección de modelos para evaluar cambios futuros en estas regiones.

¿Son los modelos HighResMIP CMIP6 herramientas fiables para la evaluación de los cambios de TSM en los EBUS?. ¿Cómo podría cambiar la surgencia en los EBUS en el futuro (2014-2050) bajo un escenario de alta emisión radiativa? representan las preguntas de investigación en este capítulo. Para responder a estas preguntas, se evaluaron 5 modelos con énfasis en la TSM del experimento HighResMIP (Haarsma et al., 2016). Luego de identificar el mejor modelo se analizó la intensidad, duración y frecuencia de eventos de surgencia a lo largo de los principales centros dentro de cada uno de los EBUS.

Data

Se seleccionaron cinco Modelos de Circulación General (GCMs) del proyecto de intercomparación CMIP6-HighResMIP (Tabla 2) utilizando la simulación hist-1950 descrita en detalle por Haarsma et al. (2016a). La descripción de los datos y los modelos se obtuvo del Programa para el Diagnóstico e Intercomparación de Modelos Climáticos (PCMDI) (<https://pcmdi.llnl.gov/CMIP6/>). Los datos diarios de TSM y viento de los modelos se descargaron de la Earth System Grid Federation (<https://esgf-node.llnl.gov/projects/cmip6/>).

Tabla 2. Modelos HighResMip utilizados para este estudio.

Modelo	Instituto	Resolución atmosferica (km)	Resolución oceanica (km)	Referencias
EC-Earth3P-HR	SHMI, KNMI, BSC, CNR y otros 23	~50	~25	(Haarsma et al., 2016a)
HadGEM3- GC31-HH	Met Office Hadley Centre	~25	~10	(Roberts et al., 2019)
CNRM-CM6-1- HR	Centre National de Recherches Météorologiques	~25	~25	(Saint-Martin et al., 2021)
CMCC-CM2- HR4	Centro Euro- Mediterraneo sui Cambiamenti Climatici	~50	~25	(Roberts et al., 2020)
CMCC-CM2- VHR4	Centro Euro- Mediterraneo sui Cambiamenti Climatici	~25	~25	(Cherchi et al., 2019)

La TSM de los modelos CMIP6 de alta resolución que utilizan la simulación hist-1950 se comparó con dos productos diferentes para evaluar el estado climático actual (1982-2014): a) observaciones del conjunto de datos de alta resolución (~25 km) Optimum Interpolation Sea Surface Temperature V2 de la Administración Nacional Oceánica y Atmosférica (NOAA OISSTV2, en adelante OISST) (Huang et al., 2021) y b) datos del Espectro radiómetro de Imágenes de Resolución Moderada (en adelante MODIS) con resolución diaria y 4 km de resolución espacial del Grupo de Procesamiento de Biología Oceánica (OBPG) de la NASA, disponibles gratuitamente a través del Laboratorio de Propulsión a Chorro de la NASA, Centro de Datos Activos Distribuidos de Oceanografía Física (PO.DACC) en el siguiente sitio: <https://podaac.jpl.nasa.gov>. Solo se seleccionaron imágenes nocturnas para evitar el efecto del intenso calentamiento

diurno, que puede ser muy importante en algunas regiones durante la primavera y el verano (Deschamps & Frouin, 1984; Minnett et al., 2019).

El experimento hist-1950 fue seleccionado ya que es el único que pertenece al experimento HighResMIP con acoplamiento diario entre el océano y la atmósfera y resoluciones estándar altas en la atmósfera, de entre 25 a 50 km, y en el océano, ≤ 25 km (Haarsma et al., 2016b).

Los datos OISST se han utilizado previamente para describir las condiciones del comportamiento de la TSM en diferentes regiones y para validar distintos modelos oceánicos (Goddard et al., 2013; Lee & Park, 2020; Marullo et al., 2007). Además, el conjunto de datos MODIS se ha utilizado en diferentes estudios para evaluar el rendimiento de la TSM en diversas regiones (Haines et al., 2007; Kilpatrick et al., 2015) y ha demostrado tener una precisión estimada de la TSM oceánica global de ~ 0.07 °C (Minnett et al., 2019).

Para este estudio, el análisis se dividió en dos periodos distintos, de acuerdo con el protocolo experimental de HighResMIP (Haarsma et al., 2016b): la simulación histórica (hist-1950) y las proyecciones futuras (*highres-future*). El análisis histórico se acotó al periodo 1982-2014 por dos razones. Primero, el año 2014 marca punto final de la simulación hist-1950. Segundo y más importante, no es válido combinar la simulación histórica con las proyecciones futuras (*highres-future*, 2015-2050) en una serie continua, ya que representan experimentos con

forzamientos y propósitos diferentes. Por lo tanto, para mantener la integridad del análisis histórico, el periodo de estudio histórico no puede extenderse más allá de 2014. El inicio de 1982, se debe a disponibilidad del conjunto de datos OISST, mientras que la comparación con MODIS se realizó en el periodo de superposición 2002-2014.

Para las proyecciones futuras se utilizó el experimento highres-future (2015-2050) de HighResMIP, el cual emplea el mismo forzamiento que el escenario socio económico SSP5-8.5 de CMIP6. A pesar de sus diferencias, ambos marcos experimentales utilizan este escenario como forzante, el cual representa una trayectoria de desarrollo basada en combustibles fósiles, con un rápido crecimiento económico y políticas de mitigación limitadas (Gidden et al., 2019). Dicha trayectoria conduce a emisiones de gases de efecto invernadero muy elevadas, alcanzando un forzamiento radiativo de 8.5 Wm^{-2} para el año 2100 respecto a los niveles preindustriales.

Sin embargo, la finalidad científica de usar este escenario extremo difiere entre ambos proyectos (MIPs). En HighResMIP, el SSP5-8.5 funciona como una potente "prueba de estrés" para la física de los modelos. Un forzamiento de gran magnitud provoca una respuesta más robusta y nítida del sistema climático, haciendo más evidentes las diferencias entre simulaciones de alta y baja resolución y facilitando su diagnóstico. En cambio, en ScenarioMIP, este

escenario actúa como el límite superior o el "peor caso" plausible dentro de un abanico de futuros alternativos. Su inclusión es fundamental para la evaluación de riesgos, pues permite analizar las consecuencias de un futuro con emisiones sin mitigar y establece el marco de referencia extremo contra el cual se contrastan escenarios más optimistas, como el SSP1-2.6 o SSP1-1.9.

Métodos

Los datos de todos los modelos, MODIS y OISST, incluida la media del Multimodelo-ensamble (en adelante MMM) calculada a partir de todos los modelos, fueron interpolados a una malla común de $0.25^\circ \times 0.25^\circ$ utilizando una combinación de los algoritmos bilineal y conservativo, ya que ambos son monotónicos (es decir, no crearán nuevos máximos/mínimos como lo hace el método bilineal), estos algoritmos ya han sido implementados en algunos estudios previos (Kim et al., 2019; Shchepetkin & McWilliams, 2009).

Se analizaron los datos de SST y viento de los principales EBUS (Figura 1, pp. 30), incluyendo los sistemas de borde oriental de California (CalCS) localizado entre $130-110^\circ\text{W}$ y $20-50^\circ\text{N}$ al oeste de América del Norte, Humboldt (HumCS) entre $85-65^\circ\text{W}$ y $0-54^\circ\text{S}$ al oeste de América del Sur, Benguela (BenCS) entre $5-25^\circ\text{E}$ y $10-40^\circ\text{S}$ al suroeste de África y de Canarias (CanCS) entre $25-5^\circ\text{W}$ y $15-45^\circ\text{N}$ al noroeste de África y la Península Ibérica. Los límites espaciales de latitud y longitud son similares a los descritos por Wang et al. (2015).

El grado de correspondencia de los modelos se evaluó en una primera etapa utilizando diagramas de Taylor. Este método utiliza tres estadísticas diferentes: el coeficiente de correlación (CORR), la desviación estándar (STD) y la raíz del error cuadrático medio (RMSE), comparando los modelos y los conjuntos de datos de referencia. Este enfoque se ha utilizado como un método estándar para la evaluación de modelos climáticos, ya que es capaz de analizar los patrones espaciotemporales (Taylor, 2001).

Sin embargo, los diagramas de Taylor no proporcionan una perspectiva completa sobre el sesgo, ya que las medias de los campos se restan antes de calcular las estadísticas de segundo orden. Por lo tanto, añadimos otras dos métricas: la Eficiencia de Nash-Sutcliffe (NSE) (McCuen et al., 2006) y el Índice de Concordancia (IA) (Willmott et al., 1985). La estadística NSE se define en la ecuación (3).

$$NSE = 1 - \frac{\sum_{i=1}^n (y_i^{obs} - y_i^{sim})^2}{\sum_{i=1}^n (y_i^{obs} - \bar{y})^2} \quad (3)$$

Donde y_i^{obs} representa la i-ésima observación, y_i^{sim} la i-ésimo valor simulado (modelo) y $\bar{y}$ la media observada para la TSM. Los modelos insesgados arrojan puntuaciones NSE entre 0 y 1, mientras que aquellos con un sesgo significativo tienden a puntuar negativamente ($NSE < -1$). Una puntuación NSE cercana a 1 indica una fuerte concordancia entre el modelo y las observaciones, mientras que

una puntuación cercana a 0 o incluso negativa sugiere lo contrario. La interpretación de las puntuaciones NSE se detalla en Ritter & Muñoz-Carpena (2013).

El índice de similitud (IA, por sus siglas en inglés) se define como:

$$IA = 1 - \frac{\sum_{i=1}^n (O_i - F_i)^2}{\sum_{i=1}^n (|O_i - \bar{O}| + |F_i - \bar{O}|)} \quad (4)$$

Donde O corresponde a las observaciones y F las predicciones.

Además de los diagramas de Taylor, también se representaron las características espaciales de los errores de sesgo del modelo para cada estación. Los comportamientos espaciales de NSE, IA y CORR se omitieron por tres razones: a) debido a que el NSE se basa en las diferencias al cuadrado entre los valores observados y los predichos, lo que conduce a una sobreestimación pronunciada de las diferencias más grandes (Krause et al., 2005), b) el IA muestra sensibilidad a los valores atípicos espaciales (Willmott et al., 1985) y c) si hay autocorrelación espacial en los datos, esto conducirá a una correlación espacial de los residuos; por ejemplo, los residuos positivos tenderán a ocurrir juntos (Dubin, 1992).

Para evaluar el desempeño general de los modelos, con base en las cinco métricas recién descritas (STD, CORR, RMSE, NSE e IA) se otorgó a todas el mismo peso. Para cada métrica, los modelos se clasificaron en una escala ordinal del 1 (mejor) al 5 (peor), incluyendo la MMM. Posteriormente, se sumaron estos

cinco valores de desempeño. Cuanto menor es el “valor de desempeño agregado”, mejor es el comportamiento del modelo (ranking).

Tras evaluar el desempeño de los modelos, seleccionamos el modelo óptimo (con la puntuación de "desempeño agregado" más baja) para un análisis comparativo con el conjunto de datos MODIS durante el período de 2002 a 2014. La resolución horizontal de MODIS se interpoló a la malla del mejor modelo utilizando la misma metodología que para el conjunto de datos OISST, evitando así cualquier extrapolación. Por lo tanto, se implementó la misma metodología de comparación para cada estación y sistema analizado.

Una vez seleccionado el modelo con el desempeño más robusto, se analizaron las proyecciones futuras (2015-2050) del afloramiento costero bajo el escenario highres-future (SSP5-8.5). El análisis se centró en los principales centros de surgencia de cada sistema de borde oriental (EBUS), previamente definidos (Capítulo 1). Para cada centro, los eventos de surgencia se identificaron aplicando la metodología ya descrita (Capítulo 1).

Para cuantificar la variabilidad, se calcularon series de tiempo de la frecuencia, duración e intensidad de los eventos a dos escalas temporales. A nivel interanual, se determinaron las tendencias a largo plazo para cada núcleo individualmente y para cada EBUS de forma agregada. A nivel estacional, se caracterizó el ciclo

anual y su evolución mediante climatologías mensuales y mapas de calor (*heatmaps*), permitiendo así identificar posibles cambios en la estacionalidad.

Resultados y discusión

a) Evaluación de TSM en el período 1982-2014 y comparación con los modelos

El desempeño diario de la TSM en los EBUS de los modelos CMIP6 HighResMIP se evalúa frente al conjunto de datos OISST utilizando Diagramas de Taylor (Figura 7). Se observan resultados consistentes en los sistemas HumCS, CalCS y CanCS con un buen grado de correspondencia, ya que los rangos de las estadísticas son de 0.92 a 0.98 para CORR, de 0.23 a 0.40 °C para RMSE y de 0.85 a 1.12 °C para la desviación estándar (STD). Por el contrario, el sistema BenCS exhibe el peor desempeño, con los valores de CORR más bajos, que van de 0.87 a 0.92, y los valores más altos de RMSE (STD), entre 0.41 a 0.62 (0.97 a 1.32) °C (Tabla 3).

Los modelos HadGEM3-GC31-HH y MMM mostraron un muy buen desempeño, con un CORR que oscila entre 0.89 y 0.97, un RMSE entre 0.28 y 0.44 y una STD < 0.98, con resultados similares en todos los sistemas (puntuaciones P_T entre 7 y 9).

El rango de las otras dos estadísticas es mayor, con valores de IA entre 0.81 y 0.97 y de NSE entre 0.04 y 0.89, siendo el modelo CMCC-CM2-HR4 el que exhibe la mayor falta de correspondencia (valores de P_T más grandes) para HumCS, CalCS y CanCS (Tabla 4). Además, el modelo CMCC-CM2-HR4 ocupa el último lugar con respecto a la estación o el sistema analizado.

Además, complementamos el análisis utilizando datos de la plataforma continental (área comprendida entre la costa y la isóbata de 200 m) dentro de cada sistema EBUS (no se muestra). De manera similar a los resultados obtenidos utilizando todo el dominio, los sistemas HumCS, CalCS y CanCS superaron al sistema BenCS, con valores de CORR que oscilaron entre 0.81 y 0.97, RMSE de 0.30 a 0.61 °C y STD de 0.82 a 1.17 °C. En contraste, BenCS mostró valores de NSE negativos (hasta -2.23 para CMCC-CM2-HR4), una STD más alta (1.11 a 1.30 °C) y un RMSE mayor (0.53 a 1.47 °C), junto con valores más bajos de correlación (≤ 0.89) e IA (≤ 0.93). Cabe mencionar que la interpretación de los coeficientes de correlación anteriormente mencionados debe hacerse con cautela ya que parte significativa de esta correspondencia se atribuye a la capacidad de los modelos para reproducir el ciclo estacional, el cual usualmente es la señal de mayor amplitud, algo que se ha documentado previamente (Wilks, 2011). Es por eso que es preferible usar las otras métricas como RMSE, STR, IA y NSE para tener una mejor idea del desempeño de los modelos.

Todas las métricas mostraron una dispersión más amplia dentro de la plataforma continental en comparación con los resultados generales del sistema (no se muestra). Estos resultados son esperados e ilustran que los modelos CMIP6 presentan dificultades para reproducir adecuadamente la impronta en la TSM causada por la surgencia cerca de la costa, como lo han mencionado estudios previos (Eyring et al., 2016; Varela et al., 2022).




Figura 7. Diagramas de Taylor que muestran el desempeño de los modelos CMIP6 HighResMIP y de la MMM frente al conjunto de datos OISST para el período 1982-2014. Los diagramas ilustran el CORR, el RMSE y la STD de la TSM diaria dentro de los EBUS. Las líneas discontinuas azules indican valores de correlación de 0.8 y 0.99, mientras que los círculos concéntricos grises representan el RMSE cada 0.2 unidades.

Tabla 3. Evaluación del desempeño de los modelos CMIP6 HighResMIP. Métricas de evaluación incluyen la desviación estándar (STD), el coeficiente de correlación (CORR), la raíz del error cuadrático medio (RMSE), la Eficiencia de Nash-Sutcliffe (NSE) y el índice de concordancia (IA). El sufijo 'P' indica la clasificación del desempeño de 1 (Mejor) a 5 (Peor). P_T representa el “valor de desempeño agregado” descrito en la sección 3 (Métodos); cuanto más bajo, mejor es el ranking. Las puntuaciones mínimas de P_T para cada sistema se indican en verde claro.

Sistema	Modelo	STD	P_{STD}	CORR	P_{CORR}	RMSE	P_{RMSE}	NSE	P_{NSE}	IA	P_{IA}	P_T
HumCS	CMCC-CM2-HR4	1.08	5	0.94	5	0.39	6	0.64	6	0.92	6	28
	CMCC-CM2-VHR4	1.03	2	0.93	6	0.31	4	0.82	2	0.95	4	18
	CNRM-CM6-1-HR	1.10	6	0.95	3	0.32	5	0.74	5	0.94	5	24
	EC-Earth3P-HR	1.05	4	0.94	4	0.29	3	0.79	4	0.95	3	18
	HadGEM3-GC31-HH	0.98	1	0.97	2	0.28	2	0.89	1	0.96	2	8
	MMM	1.04	3	0.98	1	0.23	1	0.80	3	0.97	1	9
BenCS	CMCC-CM2-HR4	1.09	4	0.87	6	0.58	5	0.04	6	0.81	6	27
	CMCC-CM2-VHR4	1.06	2	0.89	3	0.56	3	0.43	3	0.87	4	15
	CNRM-CM6-1-HR	1.32	6	0.88	4	0.62	6	0.41	4	0.89	3	23
	EC-Earth3P-HR	1.11	5	0.88	5	0.57	4	0.36	5	0.86	5	24
	HadGEM3-GC31-HH	0.97	1	0.89	2	0.44	2	0.66	1	0.92	1	7
	MMM	1.06	3	0.92	1	0.41	1	0.65	2	0.92	2	9
CalCS	CMCC-CM2-HR4	1.04	5	0.95	4	0.32	2	0.68	6	0.93	6	23
	CMCC-CM2-VHR4	1.03	4	0.95	3	0.33	4	0.87	2	0.97	2	15
	CNRM-CM6-1-HR	1.00	2	0.93	5	0.38	5	0.77	4	0.94	5	21
	EC-Earth3P-HR	1.07	6	0.93	6	0.39	6	0.76	5	0.94	4	27
	HadGEM3-GC31-HH	0.98	1	0.95	2	0.33	3	0.88	1	0.97	1	8
	MMM	1.01	3	0.96	1	0.28	1	0.86	3	0.96	3	11
CanCS	CMCC-CM2-HR4	0.87	2	0.92	6	0.40	6	0.72	5	0.91	6	25
	CMCC-CM2-VHR4	0.85	1	0.93	5	0.39	4	0.75	4	0.92	5	19
	CNRM-CM6-1-HR	1.12	6	0.94	4	0.39	5	0.67	6	0.93	4	25
	EC-Earth3P-HR	1.06	5	0.94	3	0.37	3	0.79	3	0.95	3	17
	HadGEM3-GC31-HH	0.94	3	0.95	2	0.32	2	0.87	1	0.96	1	9
	MMM	0.94	4	0.96	1	0.29	1	0.79	2	0.95	2	10

Además de la evaluación de las estadísticas espaciales medias de los EBUS, evaluamos el comportamiento espacial del error de sesgo en comparación con el conjunto de datos de referencia OISST (Figura 8) utilizando el modelo con el mejor desempeño (HadGEM-GC31-HH). Tanto los sistemas HumCS como BenCS muestran patrones de sesgo de TSM similares, con una sobreestimación de 1 a 3 °C hacia el ecuador durante las estaciones de primavera y verano, particularmente pronunciada en BenCS durante la primavera (> 2 °C). Por el contrario, en otoño e invierno, hay una subestimación de 0.5 a 1.5 °C, que aumenta en zonas oceánicas. Además, el CanCS mostró un patrón de subestimación consistente de entre 0.5 y 2.5 °C, independientemente de la estación considerada, con un considerable sesgo negativo en las estaciones de otoño y verano hacia el ecuador.

Por el contrario, en el CalCS se observa una sobreestimación de entre 0.5 y 1.5 °C en todas las estaciones, con valores más altos durante las estaciones de verano y otoño (> 0.8 °C). Sin embargo, se puede observar un mejor desempeño en invierno y primavera.

También se compararon los resultados de otros modelos incluyendo todo el dominio (EC-Earth3P-HR, CNRM-CM6-1-HR, CMCC-CM2-HR4 y CMCC-CM2-VHR4) (resultados no incluidos aquí). Con desempeños significativamente deficientes en los otros modelos evaluados, con sesgos positivos constantes entre 2 y 6 °C en los sistemas HumCS, CalCS y BenCS y, por el contrario, una

subestimación en el sistema BenCS. Se obtuvieron resultados similares al comparar el caso de la plataforma continental (no se muestra). Estos resultados son similares a los obtenidos por Varela, et al. (2022) donde el uso de 23 modelos GCM reveló una tendencia de la mayoría de los modelos a sobreestimar la TSM cerca de la costa en comparación con NOAA OISST v2 ($> 4^{\circ}\text{C}$).

A partir de estos resultados, podemos concluir que el modelo HadGEM3-GC31-HH destaca como el más competente en la reproducción del comportamiento de la TSM en todos los EBUS, obteniendo el mejor desempeño en las cinco métricas estadísticas evaluadas (Tabla 3), y el menor error de sesgo espacial (Figura 8). Esto concuerda con y amplía los resultados del estudio de Varela et al. (2022), donde identificaron a los modelos de la familia HadGEM3-GC31 como los de mejor desempeño para los sistemas de CanCS, HumCS y CalCS. Sin embargo, nuestra evaluación difiere y ofrece una nueva perspectiva sobre el sistema BenCS. Mientras Varela et al. (2022) no encontraron un modelo suficientemente bueno para reproducir la surgencia en dicha región, los resultados obtenidos posicionan a HadGEM3-GC-31-HH como una buena alternativa a pesar de su sobre estimación estacional hacia el ecuador. Dos posibles razones que podrían explicar esta discrepancia son: a) en primer lugar, la interpolación utilizada, ya que el método bilineal podría inducir un sesgo en contraste con el uso de un enfoque combinado que incluye algoritmos conservativos (Farrell et al., 2009) y b) en segundo lugar, el RMSE y el sesgo no son suficientes para proporcionar

una comparación completa, ya que solo reflejan desviaciones sistemáticas de los valores medios y no capturan los cambios potenciales en los patrones espaciotemporales (Wilks, 2019).




Figura 8. Sesgo espacial de la TSM para el período 1982-2014 del modelo con mejor desempeño (la puntuación P_T más baja), HadGEM3-GC31-HH. Los datos están organizados en filas designadas para HumCS (primera fila), BenCS (segunda fila), CalCS (tercera fila) y CanCS (cuarta fila). Las columnas representan las estaciones de año.

b) Comparación de MODIS TSM con modelos para el periodo 2002-2014.

El desempeño diario de la TSM en los EBUS del mejor modelo (HadGEM3-GC31-HH) también se evaluó frente al conjunto de datos MODIS utilizando Diagramas de Taylor (Figura 9). Los hallazgos consistentes indican que la estación de invierno presenta un mejor desempeño, mientras que la estación de verano obtiene los peores resultados (puntuaciones P_T más altas, Tabla 4). Un patrón de contraste es evidente en el sistema BenCS, que exhibe el peor desempeño entre todos los EBUS (Figura 9), con puntuaciones P_T (> 11 , Tabla 4) que superan las puntuaciones de HumCS, CalCS y CanCS.

Las estadísticas medidas oscilan entre 0.82 y 0.97 para CORR, entre 0.25 y 0.71 °C para RMSE y entre 0.80 y 1.10 °C para la desviación estándar normalizada (STD). BenCS mostró el RMSE más alto (hasta 0.71 en verano) y los valores de correlación más bajos (< 0.87 con respecto a la estación analizada) (Tabla 4).

El rango de las otras dos estadísticas es similar, con valores de IA entre 0.71 y 0.97 y de NSE entre 0.45 y 0.88, con la mayor falta de correspondencia en BenCS (puntuaciones de IA y NSE más pequeñas con valores de P_T más grandes).




Figura 9. Diagramas de Taylor que muestran el desempeño del modelo CMIP6 HadGEM3-GC31-HH frente al conjunto de datos MODIS para el período 2002-2014. Los diagramas ilustran el CORR, el RMSE y la STD de la TSM diaria dentro de los EBUS. Las líneas discontinuas azules indican valores de correlación de 0.8 y 0.99, mientras que los círculos concéntricos grises representan el RMSE cada 0.2 unidades. Cada color representa las diferentes estaciones y el gris claro considera todo el período de tiempo.

Tabla 4. Evaluación estacional del desempeño del modelo HadGEM3-GC31-HH en las diferentes regiones de los EBUS. Las métricas de evaluación incluyen la desviación estándar normalizada (STD), el coeficiente de correlación (CORR), la raíz del error cuadrático medio (RMSE), la Eficiencia de Nash-Sutcliffe (NSE) y el índice de concordancia (IA). El sufijo 'P' indica la clasificación del desempeño de 1 (Mejor) a 5 (Peor). P_T representa el “valor de desempeño agregado” descrito en la sección 3 (Métodos); cuanto más bajo, mejor es el ranking. Las puntuaciones mínimas de P_T para cada sistema se indican en verde claro.

Sistema	Modelo	STD	P_{STD}	CORR	P_{CORR}	RMSE	P_{RMSE}	NSE	P_{NSE}	IA	P_{IA}	P_T
HumCS	Summer	1.05	5	0.95	5	0.35	4	0.64	4	0.82	4	22
	Autumn	0.96	2	0.96	3	0.36	5	0.71	2	0.73	5	17
	Winter	0.94	1	0.97	1	0.26	2	0.73	1	0.85	2	7
	Spring	1.01	4	0.97	2	0.25	1	0.68	3	0.83	3	13
	All seasons	0.97	3	0.96	4	0.29	3	0.61	5	0.89	1	16
BenCS	Summer	1.05	4	0.83	3	0.71	5	0.61	3	0.81	4	19
	Autumn	0.93	1	0.86	2	0.58	2	0.66	1	0.80	5	11
	Winter	0.94	2	0.82	4	0.60	3	0.56	4	0.91	3	16
	Spring	1.10	5	0.82	5	0.64	4	0.55	5	0.94	1	20
	All seasons	0.94	3	0.87	1	0.53	1	0.62	2	0.93	2	9
CalCS	Summer	1.03	5	0.91	5	0.47	5	0.45	5	0.76	4	24
	Autumn	0.99	3	0.93	4	0.44	4	0.60	4	0.71	5	20
	Winter	0.91	2	0.95	1	0.33	1	0.74	1	0.92	1	6
	Spring	0.90	1	0.94	2	0.34	2	0.70	3	0.87	3	11
	All seasons	0.99	4	0.94	3	0.37	3	0.72	2	0.92	2	14
CanCS	Summer	0.89	5	0.84	5	0.60	5	0.56	5	0.80	5	25
	Autumn	0.80	1	0.88	4	0.49	4	0.72	3	0.84	4	16
	Winter	0.81	2	0.93	2	0.39	2	0.88	1	0.97	1	8
	Spring	0.85	3	0.94	1	0.37	1	0.67	4	0.92	3	12
	All seasons	0.87	4	0.93	3	0.39	3	0.87	2	0.95	2	14

De manera similar a la comparación realizada con MODIS, evaluamos el sesgo espacial del modelo con mejor desempeño (HadGEM3-GC31-HH) frente al conjunto de datos MODIS, pero utilizando una escala espacial (~10 km) en el rango temporal de 2002 a 2014.

De forma similar a la comparación con OISST, HumCS y BenCS mostraron un comportamiento similar, con una sobreestimación que oscila entre 1 y 3 °C hacia el ecuador durante las estaciones de primavera y verano, con una mayor falta de correspondencia en el primer caso (> 2.5 °C). Por el contrario, se puede observar una subestimación que va de 0.5 a 1.5 °C en las estaciones de otoño e invierno, aumentando el sesgo mar adentro. Además, CanCS muestra consistentemente un patrón de subestimación de 0.5 a 2.5 °C, independientemente de la estación analizada, siendo notable en las estaciones de verano y otoño hacia el ecuador.

El sistema CalCS, de manera similar a la comparación con OISST, mostró una sobreestimación que oscila entre 0.3 y 1.2 °C en todas las estaciones, con valores más altos durante el otoño (> 0.7 °C).

Además, se observa un patrón interesante cuando comparamos los sistemas en ambos hemisferios para las estaciones de primavera y verano. Por ejemplo, en el Hemisferio Sur (HumCS y BenCS, Figura 10), hay una sobreestimación hacia el ecuador, mientras que en los sistemas del Hemisferio Norte (CalCS y CanCS), el patrón inverso es evidente (Figura 10).

La estación de invierno demuestra el mejor desempeño con el menor sesgo absoluto ($< |1.1\text{ }^{\circ}\text{C}|$) entre todos los sistemas ($< |2.4|^{\circ}\text{C}$ en primavera) con respecto a la estación analizada. Asimismo, existe un mayor alta correlación (0.73) en el patrón espacial del sesgo en los sistemas del Hemisferio Sur (HumCS y BenCS) durante la primavera. En contraste, los sistemas del Hemisferio Norte (CalCS y CanCS) exhiben el mejor desempeño durante el verano y el otoño, presentando un comportamiento espacial distinto.

Varios estudios han destacado el progreso en los modelos CMIP6 en comparación con versiones anteriores para reproducir la TSM, reproduciendo el sesgo de la TSM alrededor del Pacífico ecuatorial (Song et al., 2020; Wang et al., 2022) y el Atlántico (Richter & Tokinaga, 2020). Aunque existen problemas relacionados con el sesgo en la representación de la TSM cerca de la costa, con una sobreestimación por parte de la mayoría de los modelos, la mejora en la resolución ha demostrado que puede manejar estas fuentes de error, mostrando mejores resultados que sus predecesores de baja resolución (Sylla et al., 2022). Además, contrariamente a los resultados obtenidos por Varela et al. (2022a), encontramos diferencias importantes al considerar el desempeño estacional, de forma similar a los resultados obtenidos por Wang et al. (2022), con un mayor sesgo en verano y primavera. Adicionalmente, todos los modelos tienden a sobreestimar la TSM con una mayor falta de desempeño cerca de la costa (Liu et al., 2022). Sin embargo, el modelo HadGEM3-GC31-HH mostró un patrón

opuesto, lo cual es un patrón interesante e incluso podría ser una buena aproximación, ya que se ha demostrado que la TSM de nivel 4 (L4) teledetectada tiende a subestimar la huella térmica del afloramiento costero (Meneghesso et al., 2020).




Figura 10. Estructura espacial del sesgo para la TSM en el período 2002-2014, obtenido del modelo con el mejor desempeño (menor puntaje PT), HadGEM3-GC31-HH (Tabla 2). Los datos se organizan en filas designadas para HumCS (primera fila), BenCS (segunda fila), CalCS (tercera fila) y CanCS (cuarta fila). Las columnas representan las estaciones del año.

c) Proyecciones del experimento HighResMIP en centros de surgencia

Una vez establecido el desempeño del modelo HadGEM3-GC31-HH, se procedió a analizar las proyecciones futuras (2015-2050) de las características de surgencia en los cuatro EBUS, centrándose en su intensidad, frecuencia y duración (Figura 11). En cuanto a la intensidad media anual del afloramiento (Figura 11a), los resultados no muestran tendencias estadísticamente significativas en ninguno de los sistemas, con valores p que oscilan entre 0.061 y 0.501. Esto sugiere que, a pesar de la alta variabilidad interanual, no se proyecta un cambio sistemático en la anomalía de temperatura asociada a los eventos de surgencia individuales.

En marcado contraste, el análisis revela un cambio robusto y consistente en la naturaleza temporal de los eventos de surgencia. Se proyecta una disminución estadísticamente significativa ($p < 0.03$) tanto en la frecuencia anual (Figura 11b) como en la duración media (Figura 11c) de los eventos en todos los EBUS analizados. La reducción en la frecuencia es particularmente pronunciada en los sistemas de Benguela, Canarias y Humboldt, con tendencias entre -18.68 y -13.03 eventos por década, respectivamente ($p < 0.001$). De manera similar, la duración de los eventos también muestra una tendencia negativa significativa en todos los sistemas, destacando nuevamente los mismos sistemas, con reducciones entre -0.45 y -0.38 días por década, respectivamente ($p < 0.001$). En

conjunto, estos resultados sugieren que, si bien la fuerza de los eventos individuales de afloramiento podría no cambiar de manera apreciable, el régimen de surgencia en su conjunto tendería hacia un estado más intermitente y esporádico, caracterizado por eventos menos frecuentes y más breves.




Figura 11. Series temporales anuales de las métricas de surgencia proyectadas (2015-2050) en los cuatro EBUS. Los paneles muestran **(a)** la anomalía de intensidad, **(b)** la frecuencia de eventos y **(c)** la duración media. Las líneas sólidas representan las tendencias lineales; su pendiente y significancia se muestran en la leyenda (* indica $p < 0.05$).

Para el caso del sistema de Humboldt al analizar la estructura temporal a nivel mensual e interanual de las métricas de surgencia (Figura 12), se observa que hay un acoplamiento entre las tres métricas, con una fase de surgencia más intensa (anomalías $< -1.5^{\circ}\text{C}$), frecuente (> 4 eventos/mes) y duradera (> 5 días) durante la primavera y el verano austral. La evolución interanual mensual, sin embargo, muestra que este patrón estacional se ve alterado a lo largo del período de proyección. Particularmente en la frecuencia de eventos (Figura 12E), se observa una transición visualmente clara desde un régimen de alta frecuencia en los primeros ~ 15 años (predominio de colores cálidos) hacia un régimen de baja frecuencia en la última década, caracterizado por un aumento notable de meses con muy pocos o ningún evento de surgencia (colores oscuros y negros). Una tendencia similar, aunque menos pronunciada, es visible en la duración (Figura 12F).

Al analizar el comportamiento individual de los centros de surgencia se observa una heterogeneidad espacial significativa en la respuesta del sistema (Figura 13). La tendencia agregada de una intensidad sin cambios significativos oculta una respuesta latitudinal diferenciada: mientras que los centros de surgencia del norte y centro no muestran cambios, los centros más al sur, Coquimbo y Concepción, proyectan un debilitamiento estadísticamente significativo del afloramiento (pendientes de $+0.13/\text{década}$ y $+0.10/\text{década}$, respectivamente). De manera similar, la robusta disminución en la frecuencia de eventos es impulsada

predominantemente por la porción central y sur del sistema (desde Mejillones hacia el sur), donde todos los centros muestran una reducción estadísticamente significativa ($p < 0.005$). En contraste, los centros cercanos al ecuador (Chimbote, Callao) no presentan una tendencia clara. Finalmente, la reducción en la duración de los eventos también está espacialmente concentrada, siendo únicamente significativa en los mismos centros del sur, Coquimbo y Concepción.




Figura 12. Estructura mensual e interanual de las métricas de surgencia en el sistema de Humboldt (2015-2050). Fila superior: Resumen mensual climatológico para (A) Intensidad media (°C), (B) Frecuencia (eventos/mes), y (C) Duración media (días). Para el panel (B), el promedio se calcula sobre los meses con frecuencia mayor a cero. Fila inferior: Evolución interanual mensual de (D) Intensidad, (E) Frecuencia, y (F) Duración. En el panel (E), los meses en negro indican una frecuencia de cero eventos.

Humboldt Current System: Station-wise Annual Metrics




Figura 13. Métricas anuales de surgencia por centro de afloramiento en el sistema de Humboldt (2015-2050). Cada fila representa un centro de surgencia individual, ordenado de norte (arriba) a sur (abajo). Las columnas muestran las series temporales anuales y las tendencias lineales para **(A)** Intensidad media (°C), **(B)** Frecuencia de eventos, y **(C)** Duración media (días). Las pendientes (por década) y los valores p se indican en cada panel. El asterisco (*) denota tendencias estadísticamente significativas ($p < 0.05$).

Para el caso de California (Figura 14). La climatología mensual muestra una temporada de surgencia principal bien definida durante la primavera y verano del hemisferio norte (Marzo-Agosto), cuando la intensidad es máxima (anomalías < -1.8 °C) y la duración de los eventos es considerable. Interesantemente, la frecuencia presenta un patrón bimodal, con un pico principal en primavera (marzo) y uno secundario a principios de invierno (diciembre). La evolución interanual expone una clara degradación de este patrón estacional. Los mapas de calor de intensidad (Figura 14D) y de frecuencia (Figura 164), ilustran una pérdida de actividad a lo largo del tiempo. Los años posteriores a 2035 muestran una reducción en la intensidad durante la temporada alta y, sobre todo, un drástico incremento en la cantidad de meses con baja o nula frecuencia de eventos (colores oscuros y negros), interrumpiendo la consistencia de la temporada de surgencia.

La descomposición de estas tendencias a nivel de los centros de surgencia individuales nuevamente descubre una importante heterogeneidad espacial (Figura 15). Un hallazgo clave es que la tendencia agregada de debilitamiento en la intensidad, que era solo marginalmente significativa para el sistema en su conjunto ($p=0.061$), se manifiesta como una tendencia robusta y estadísticamente significativa ($p \leq 0.005$) en los tres centros de surgencia más hacia al norte (Pt. Arena, Pt. Reyes, Pt. Año Nuevo). En cuanto a la frecuencia, la disminución general del sistema se confirma localmente, siendo

134

California Current System: Station-wise Annual Metrics




Figura 15. Métricas anuales de surgencia por centro de afloramiento en el sistema de California (2015-2050). Cada fila representa un centro de surgencia individual, ordenado de norte (arriba) a sur (abajo). Las columnas muestran las series temporales anuales y las tendencias lineales para **(A)** Intensidad media (°C), **(B)** Frecuencia de eventos, y **(C)** Duración media (días). Las pendientes (por década) y los valores p se indican en cada panel. El asterisco (*) denota tendencias estadísticamente significativas ($p < 0.05$).

Para el caso de Benguela, la climatología mensual de las métricas establece una temporada de surgencia principal durante el otoño, invierno y primavera austral (Abril-Noviembre), periodo en el cual la surgencia es más intensa, frecuente y de mayor duración. Sin embargo, los mapas de evolución interanual demuestran una

alteración sistemática de este ciclo. El cambio más drástico se observa en la frecuencia de los eventos (Figura 16E), donde se evidencia una transición inequívoca desde un estado de alta actividad en los primeros 15 años del análisis hacia un estado de muy baja actividad en la última década, con un notable aumento de meses con una frecuencia de eventos mínima o nula (representados en negro), similar a los casos anteriores.

Al igual que en los casos previos hay una disminución de la frecuencia ($p \leq 0.001$) en casi todos los centros a lo largo de la costa, desde Cape Frio hasta Saint Helena Bay. Por otro lado, la intensidad del afloramiento muestra una respuesta espacialmente focalizada; aunque a nivel agregado la tendencia no era significativa, el análisis local revela un debilitamiento estadísticamente significativo ($p < 0.001$) en el núcleo central del sistema (Luderitz y Namaqualand). Finalmente, la reducción en la duración de los eventos también presenta heterogeneidad, siendo significativa en los extremos norte (Cape Frio, Walvis Bay) y sur (Saint Helena Bay, Cape Town) del sistema, pero no en su porción central.




Figura 16. Estructura mensual e interanual de las métricas de surgencia en el sistema de Benguela (2015-2050). Fila superior: Resumen mensual climatológico para (A) Intensidad media (°C), (B) Frecuencia (eventos/mes), y (C) Duración media (días). Para el panel (B), el promedio se calcula sobre los meses con frecuencia mayor a cero. Fila inferior: Evolución interanual mensual de (D) Intensidad, (E) Frecuencia, y (F) Duración. En el panel (E), los meses en negro indican una frecuencia de cero eventos.

Benguela Current System: Station-wise Annual Metrics




Figura 17. Métricas anuales de surgencia por centro de afloramiento en el sistema de Benguela (2015-2050). Cada fila representa un centro de surgencia individual, ordenado de norte (arriba) a sur (abajo). Las columnas muestran las series temporales anuales y las tendencias lineales para **(A)** Intensidad media (°C), **(B)** Frecuencia de eventos, y **(C)** Duración media (días). Las pendientes (por década) y los valores p se indican en cada panel. El asterisco (*) denota tendencias estadísticamente significativas ($p < 0.05$).

Finalmente, para el sistema de Canarias (Figura 18), la climatología mensual de métricas se caracteriza por una temporada de máxima intensidad en verano (Junio-Septiembre), mientras que la frecuencia de eventos muestra un patrón bimodal con picos en primavera e invierno. La proyección a largo plazo, visualizada en los mapas de calor, indica un cambio fundamental en este régimen. Si bien la intensidad no muestra una tendencia clara (Figura 18D), la frecuencia de eventos sufre un descenso significativo (Figura 18E). El sistema transita desde un estado de alta frecuencia casi perenne en la primera década, a un estado post-2030 dominado por meses con una actividad de surgencia mínima o completamente ausente.

Al desglosar los resultados por centros de surgencia (Figura 19), se observa que la intensidad se mantiene notablemente estable, sin ninguna tendencia estadísticamente significativa en ninguno de los cinco centros analizados, lo que corrobora el resultado agregado. La disminución de la frecuencia es similar a lo observado en otros sistemas ($p < 0.001$). Por su parte, la reducción en la duración de los eventos, aunque significativa a nivel agregado, muestra una firma espacial más heterogénea, siendo estadísticamente significativa solo en los flancos norte (Blanes) y sur (St. Vincent) del sistema.




Figura 18. Estructura mensual e interanual de las métricas de surgencia en el sistema de Canarias (2015-2050). Fila superior: Resumen mensual climatológico para (A) Intensidad media ($^{\circ}\text{C}$), (B) Frecuencia (eventos/mes), y (C) Duración media (días). Para el panel (B), el promedio se calcula sobre los meses con frecuencia mayor a cero. Fila inferior: Evolución interanual mensual de (D) Intensidad, (E) Frecuencia, y (F) Duración. En el panel (E), los meses en negro indican una frecuencia de cero eventos.

Canary-Iberian System: Station-wise Annual Metrics




Figura 19. Métricas anuales de surgencia por centro de afloramiento en el sistema de Canarias (2015-2050). Cada fila representa un centro de surgencia individual, ordenado de norte (arriba) a sur (abajo). Las columnas muestran las series temporales anuales y las tendencias lineales para **(A)** Intensidad media (°C), **(B)** Frecuencia de eventos, y **(C)** Duración media (días). Las pendientes (por década) y los valores p se indican en cada panel. El asterisco (*) denota tendencias estadísticamente significativas ($p < 0.05$).

Conclusiones

Se seleccionaron 5 modelos GCM del experimento CMIP6 (HighResMIP) para evaluar su desempeño en la reproducción de la TSM a través de los EBUS, utilizando datos observacionales y satelitales en dos períodos diferentes, 1982-2014 y 2002-2014, respectivamente. Los resultados indican que la mayoría de los modelos tienden a sobreestimar la TSM, con un mayor sesgo cerca de la costa. Los mejores resultados se obtuvieron para HumCS y CalCS. Además, el aumento de la resolución horizontal parece ser un factor importante en el desempeño, reduciendo las métricas de error. Adicionalmente, aunque los EBUS son regiones similares, el desempeño parece verse afectado por el área de estudio seleccionada. El modelo HadGEM-GC31-HH destaca como el mejor modelo, con la resolución más alta. BenCS y CalCS mostraron una considerable falta de desempeño hacia el ecuador.

En cuanto a las proyecciones futuras (2015-2050) en los centros de surgencia analizados, se proyecta una disminución estadísticamente significativa en la frecuencia y duración de los eventos de afloramiento en los cuatro EBUS, siendo el sistema de Canarias el que experimenta la reducción más drástica. En contraste, los cambios en la intensidad son espacialmente heterogéneos, con un debilitamiento significativo solo en subregiones específicas (como el núcleo de Benguela o el sur de Humboldt), y una estabilidad general en otras. Estos

hallazgos, que sugieren un cambio fundamental hacia un régimen de surgencia más intermitente y esporádico, no necesariamente contradicen las proyecciones de consenso del CMIP que apuntan a cambios "moderados" en los vientos favorables a la surgencia. Nuestros resultados, basados en la respuesta de la TSM, podrían estar reflejando cambios más sutiles en la persistencia o variabilidad del viento, o incluso respuestas oceánicas como un aumento de la estratificación, que no son capturados por el análisis del viento promedio. No obstante, es crucial interpretar estas proyecciones con cautela. El análisis se centra en puntos costeros específicos donde los modelos, como se demostró anteriormente, presentan sesgos. Por lo tanto, si bien la señal de cambio es fuerte, la magnitud precisa de esta transformación en la dinámica de surgencia costera debe considerarse con la incertidumbre inherente al modelo en estas complejas zonas de transición.

4.3 Capítulo 3: " Pronóstico de la intensidad de la surgencia en la costa del Pacífico Suroriental mediante inteligencia artificial". Artículo científico enviado a la revista "Journal of Computational Science" el 20/10/2025. Los resultados de este manuscrito responden a al objetivo específico 3 de la tesis.

Resumen

Los Sistemas de Surgencia en las Bordes Orientales (EBUS, por sus siglas en inglés) cubren menos del 1 % de la superficie oceánica, pero se encuentran entre los ecosistemas marinos más productivos biológicamente a nivel mundial, sosteniendo hasta el 20 % de las capturas pesqueras del mundo. Esta importancia ecológica y económica es especialmente marcada en el Sistema de la Corriente de Humboldt (HCS), una de las regiones EBUS más productivas. Este estudio introduce un enfoque novedoso de aprendizaje profundo (*deep learning*) para pronosticar la temperatura superficial del mar (SST, por sus siglas en inglés) y evaluar los eventos de afloramiento. Empleamos varios modelos de aprendizaje profundo entrenados a múltiples resoluciones espaciales (5, 12.5 y 25 km), utilizando datos que abarcan desde 1993 hasta 2023. El modelo UNET emergió como la mejor arquitectura. El desempeño del modelo fue robusto en diferentes horizontes de pronóstico, con valores medios de RMSE (raíz del error cuadrático medio) $<0.4^{\circ}$ C para pronósticos con 7 días de antelación. Para cuantificar la intensidad del afloramiento, desarrollamos una versión modificada del algoritmo STSEC, un método de agrupamiento (*clustering*) espacial autoajutable que segmenta las imágenes de SST, delimitando las regiones de afloramiento según su similitud y coherencia espacial. El método se integró con los pronósticos para generar un índice de afloramiento espacial, que caracteriza cuantitativamente la intensidad del afloramiento correspondiente a cada región de agrupamiento identificada. Este índice se validó frente a eventos de

afloramiento observados, mostrando una fuerte correlación y similitud estructural con los patrones de TSM observados. Además, exploramos la aplicación de Modelos de Lenguaje Grandes (LLM), como Chronos y Lag-Llama, para pronósticos puntuales de SST. El modelo Chronos superó en rendimiento a la arquitectura Lag-Llama, con métricas de error $<5\%$ en predicciones semanales. Nuestros hallazgos destacan el potencial de las técnicas de aprendizaje profundo (DL), particularmente la arquitectura U-Net y el modelo Chronos, para el pronóstico operativo de la SST y las dinámicas de afloramiento en el sur del HCS.

Forecasting Upwelling Intensity in the Southeastern Pacific Coast using Artificial Intelligence

David F. Bustos Usta^{a,b*}; Diego A. Narváez^{b,c}; Boris Dewitte^{c,d,e,f}; Fabián Tapia^{b,c}; Mabel Vidal^{g,h}

^a Programa de Postgrado en Oceanografía, Departamento de Oceanografía, Facultad de Ciencias Naturales y Oceanográficas, Universidad de Concepción, Concepción, Chile; davidbustos@udec.cl

^b Departamento de Oceanografía, Facultad de Ciencias Naturales y Oceanográficas, Universidad de Concepción, Concepción, Chile; diegonarvaez@udec.cl, ftapiaj@udec.cl.

^c Centro de Investigación Oceanográfica COPAS Coastal, Universidad de Concepción, Concepción, Chile; diegonarvaez@udec.cl, ftapiaj@udec.cl.

^d Centro de Estudios Avanzados en Zonas Áridas (CEAZA), Coquimbo, Chile; boris.dewitte@ceaza.cl.

^e Centro de Ecología y Gestión Sostenible de Islas Oceánicas (ESMOI), Departamento de Biología Marina, Facultad de Ciencias del Mar, Universidad Católica del Norte, Antofagasta, Chile; boris.dewitte@ceaza.cl.

^f Clima, Medio Ambiente, Acoplamientos e Incertidumbres (CECI), Universidad de Toulouse, Centre Européen de Recherche et de Formation Avancée en Calcul Scientifique (CERFACS)/ Centre National de la Recherche Scientifique (CNRS), Toulouse, France; boris.dewitte@ceaza.cl.

^g Departamento de Ingeniería Informática y Ciencias de la Computación, Universidad de Concepción, Concepción, Chile; mabvidal@udec.cl.

^h ANID–Millenium Science Initiative Program–Millenium Nucleus in Data Science for Plant Resilience (Phytolearning), Chile.

* Correspondence autor

Highlights

- U-Net architecture excels for 7-day spatial SST forecasts in the HCS (RMSE < 0.47°C).
- A novel upwelling index developed via modified STSEC accurately segments observed events.
- Novel application of LLMs shows the Chronos model excels for point SST time-series forecasts (<5% error).

Abstract

The EBUS cover <1% of the ocean surface but are among the most biologically productive marine ecosystems globally, supporting up to 20% of the world's fisheries catches. This ecological and economic significance is particularly pronounced in the Humboldt Current System (HCS), one of the most productive EBUS regions. This study introduces a novel deep learning approach to forecast sea surface temperature (SST) and assess upwelling events. We employed several deep learning models trained at multiple spatial resolutions (5, 12.5 and 25 km) using data spanning from 1993 to 2023. The UNET model emerged as the best architecture. The model's performance was robust across different forecast horizons, with mean RMSE values <0.4° C for 7-day lead-time forecasts. To quantify upwelling intensity, we developed a modified version of the STSEC algorithm, a self-tuning spatial clustering method that segments SST images delineating upwelling regions based on similarity and spatial coherence. The method was integrated with the forecasts to generate a spatially upwelling index, which quantitatively characterizes the upwelling intensity corresponding to each identified cluster region. This index was validated against observed upwelling events, showing strong correlation and structural similarity with observed SST patterns. Additionally, we explored the application of Large Language Models, such as Chronos and Lag-Llama, for point-wise SST forecasts. The Chronos model outperformed the Lag-Llama architecture, with error metrics <5% over

weekly based predictions. Our findings highlight the potential of DL techniques, particularly the U-Net architecture and Chronos model, for operational forecasting of SST and upwelling dynamics in the southern HCS.

Keywords: EBUS; Upwelling index; Deep Learning; Sea Surface Temperature; Large Language Models (LLMs)

1. Introduction

Forecasting weather and sea conditions on short (hours) and mid (weeks) timescales is essential for many human activities on the coast, including port operations [1], shipping [2], fishing [3], coastal defense [4], and tourism [1,5,6]. Ocean forecasting remains less advanced than atmospheric forecasting, primarily because of its perceived lower immediate relevance to daily human activities. The complexity arises from sparse observational data, and the intricate interplay of currents, waves, and temperature. Consequently, ocean predictions are less precise than weather forecasts, particularly over extended periods. While atmospheric models achieve reliable forecasts several days in advance [7,8], ocean forecasts are generally more accurate only on shorter timescales [9], despite the fact that ocean circulation adjusts more slowly than the atmosphere.

The evolution of ocean forecasting frameworks began with wind-wave models, pioneered by Sverdrup and Munk in 1947 [10], and progressed to storm surge predictions through shallow-water equations [11]. The first 3D ocean current forecast model, developed by Robinson [12], demonstrated successful mesoscale predictions on temporal scales of days to weeks and spatial scales spanning tens to hundreds of kilometres, paving the way for regional systems and global models. Advances in assimilating satellite altimetry with U.S. Navy GEOSAT [13], deriving vertical temperature and salinity profiles from observed sea surface heights and temperatures [14–17].

The term “operational” was only introduced in the 2000s, referring to models and forecasts used to support resource management [18,19]. These are characterized by (1) adherence to established methodologies and best practices, (2) regular application in decision-making, (3) reliance on recent, quality-controlled and accessible data, (4) provision of actionable insights, and (5) ideally, evaluation of trade-offs across ecological, socio-economic, and policy objectives [9].

The first operational forecast, FOAM [20], paved the way for subsequent systems such as Mercator [21] and BLUElink [18], which achieved higher resolutions through advances in computational cost and data assimilation techniques [22,23], including ensemble methods and Kalman filters [24]. Subsequent developments led to a global expansion of operational ocean forecasting systems, each tailored

to regional and coastal dynamics. The Mediterranean Forecasting System [25] and the Black Sea forecasting initiatives [26] marked early advances in the 2000s, followed by the of NOAA's HYCOM-based Real-Time Forecast System (RTOFS) [27]. The 2010s saw the emergence of Brazil's CHM-HYCOM+RODAS [28], Korea's KOOFS [29], and Japan's JCOPE-FGO [30], which extended coverage to eddy-resolving global scales. The Copernicus Marine Service in 2015 further enhanced European forecasting capabilities [31], while China's MaCOM in 2024 [32] introduced mass-conserving circulation models. These systems continue to improve predictive skill through model advancements and enhanced data assimilation, while also extending forecast horizons via regional high-resolution coupled ocean–atmosphere models, such as the IGP RESM-COW v1 developed in Peru for coastal El Niño forecasting [28].

Despite recent advances in operational ocean forecasting, key limitations remain. Data scarcity, particularly in deep and remote regions, restricts assimilation quality, leading to uncertainties in predictions. In addition, model biases, errors in parameterisations, the complexity of ocean–atmosphere interactions, and natural variability associated with mesoscale ocean dynamics further challenge forecast accuracy [1,33].

In this study, we use a practical application of ocean forecasting to coastal upwelling, which is a multifaceted challenge due to non-linear interactions

between bathymetry, wind stress, Coriolis force and coastal topography, among other factors [34,35]. Coastal upwelling sustains 20% of global fisheries [36], mainly within Eastern Boundary Upwelling Systems (EBUS): California, Humboldt, Canary, and Benguela. The Humboldt Current System (HCS) is among the most productive, exceeding $300 \text{ C/m}^2/\text{yr}$ [37], which makes it the focus of this study. Forecasting upwelling is important due to its ecological, economic, and climatic importance [38]. Upwelling regions, especially EBUS, are among the most productive marine ecosystems, sustaining diverse marine life and significantly contributing to global fisheries [37,39].

Recent analyses of historical data (1993–2019) reveal that upwelling events within the HCS have become longer during spring and more intense in summer, likely in response to long-term climate variability. These changes align with a poleward shift of the South Pacific Subtropical High, which has intensified upwelling-favourable winds and caused significant sea surface temperature decreases, especially at higher latitudes within the system [40]. Given the crucial role that the frequency, intensity, and duration of upwelling events play in regional biogeochemistry, fisheries sustainability, and food security, this evolving variability underscores the pressing need for accurate quantification and forecasting of upwelling dynamics.

Accurate forecasts enable sustainable resource management, mitigate overfishing risks, and improve food security. Besides, upwelling regulates coastal weather, sea surface temperatures, and carbon fluxes, playing a critical role in climate change dynamics. Some studies have attempted to address the challenge of upwelling forecasting using diverse approaches, such as Ekman theory for seasonal forecasting [41,42], regional physical models that incorporate data assimilation techniques [43], thermal gradients combined with regime-specific models to predict offshore wind speed and power on synoptic scales [44], and deep learning models for predicting SST fields [45]. Despite decades of advancement and more than 30 years of accumulated expertise in oceanography, most forecasting frameworks for coastal upwelling remain constrained by their reliance on monthly timescales and deterministic methodologies. Such approaches consistently underestimate the inherently nonlinear and rapidly evolving nature of upwelling dynamics. Notably, ensemble-based and probabilistic forecasting methods are seldom employed, and high-resolution, fully coupled ocean–atmosphere models are rarely leveraged. Consequently, critical phenomena—including abrupt regime shifts and forecast uncertainty—often go unresolved, limiting the effectiveness of these systems for real-time management and early warning applications [46].

2. Material and methods

2.1. Study Area

We focus on the Humboldt Current System (hereinafter, HCS) off the west coast of South America (approximately 82–70° W, 19–41° S) (Figure 1), with regions delineated according to previous studies [47]. It is important to note that the HCS encompasses multiple subregions, including the Southern Humboldt Current System (SHCS), which is particularly relevant to Peru and northern Chilean coastal dynamics. The HCS is globally recognized as one of the most productive marine ecosystems and serves as a prototypical Eastern Boundary Upwelling System (EBUS) [48,49]. Driven by persistent, wind-induced coastal upwelling, the system delivers cold, nutrient-rich waters to the surface, sustaining intense primary productivity and supporting some of the world's largest fisheries. This region accounts for almost 10–20% of the global marine fish catch while comprising less than 1% of the world's ocean surface area [39,48]. Upwelling in the HCS exhibits substantial spatial and temporal variability, with peak intensity typically during austral spring and summer. This variability is modulated by alongshore wind strength and large-scale climate drivers, particularly the El Niño Southern Oscillation (ENSO) [39,50–52].




Fig. 1. Geographic locations and bathymetry for the HCS considered in this study. Data retrieved from GEBCO [53].

2.2. Data collection

In this study different remote sensing datasets were used. (1) Sea surface temperature (SST) was obtained from the Multi-scale Ultra-high Resolution (MUR), with spatial resolution of $0.01^\circ \times 0.01^\circ$ (1 km) and daily resolution from 1 June 2002 to 31 December 2023 [54]. (2) The Met Office originally developed the Operational Sea Surface Temperature and Sea Ice Analysis (OSTIA), with spatial resolution of $0.05^\circ \times 0.05^\circ$ (5km) and daily resolution from 30 September 1981 to 3 July 2025 [55]. (3) The C3S global Sea Surface and Sea Ice Temperature (C3S), with spatial resolution of $0.05^\circ \times 0.05^\circ$ (5km) and daily resolution from 31 August 1981 to 30 December 2024 [56]. (4) Atmospheric data such as air temperature (AT), shortwave radiation (QSW), sea level pressure (SLP), and northward wind component at 10m (V10) were obtained from the ERA5 atmospheric reanalysis from ECMWF at $0.25^\circ \times 0.25^\circ$ (25km) resolution from 1993 to 2023 [57]. (5) Wind data were obtained from the hourly Global Ocean Sea Surface Wind and Stress dataset (WIND_GLOB), with a $0.125^\circ \times 0.125^\circ$ (12.5km) resolution available from 31 May 1994 to 21 August 2024 [58]. Additionally, to validate MUR results, we used the (6) Moderate Resolution Imaging Spectroradiometer (MODIS) [59], using daily 4 km day-and-night gridded (L3) global NASA skin SST data from 3 July 2002 to 31 December 2023 [60]. The validation was performed using Taylor diagrams and spatial comparison maps.

2.3. Optimal Model Configuration

The Optimal Model Configuration (OMC) consisted of evaluating the predictive skill based on a combination of five daily-mean input variables (SST, SLP, QSW, AT and V10), three spatial resolutions (5, 12.5 and 25 km), and five deep learning architectures (ConvLSTM, 3D-CNN-LSTM, IRSTN, TCN and U-Net) that produced the best forecast performance using Root Mean Squared Error (RMSE) as the baseline metric. First, based on data availability, different experiments were performed permuting among variables and spatial resolution (Section 2.3.1), then for the same experiments, different deep learning models were used to find the most suitable architecture to forecast the sea surface temperature (Section 2.3.2). To standardize temporal resolutions between datasets, the analysis period was restricted from 1 June 2002 to 31 December 2023 (7884 samples). Data were split into 70% (5850 days) for model training, including cross-validation (a technique in which training data is split into several parts to test the model on different subsets, helping to check how well it will perform on new unseen data [61], and 30% (2034 days) for predictive performance testing. Each experiment consisted of using the 7 days before to forecast the following 7 days, and the performance (using the RMSE error metric) was estimated for each day at each grid point.

2.3.1. Variables and experiments

Three experimental spatial resolutions were selected to determine the OMC, 25km, 12.5km and 5km. The 25km scale included SST, AT, QSW, SLP, and V from ERA5 (81.50–69.75° W, 39.75–20.00° S; blue box, Figure 1), with 16 variable permutations tested using SST as dependent variable (Table 1). The 12.5km scale using SST and V10 (80.06–70.19° W, 38.94–21.06° S; purple box, Figure 1), yielding two combinations. The 5km scale involved a single configuration using MUR SST data (74.01–70.24° W, 38.8–22.17° S; red box, Figure 1). Finally, we conducted four additional experiments with combining DL models with Large Language Models (LLMs) using MUR SST data to analyze key upwelling centres (point forecasting, using the nearest available node MUR data): Mejillones (71.07–70.28° W, 24.50–22.50° S; green), Coquimbo (72.06–71.27° W, 30.48–28.73° S; yellow), Valparaíso (72.21–71.42° W, 33.96–32.21° S; firebrick), and Concepción (73.37–72.58° W, 37.25–35.50° S; cyan box) (not shown).

The experimental domains were defined based on three key considerations. First, memory alignment was optimized using powers of 2 (e.g., 8, 16, 32), enhancing GPU memory access efficiency [62,63]. Second, vectorization was implemented to enable efficient GPU data processing in chunks of 4, 8, or 16 elements [62]. Finally, pooling errors were mitigated by avoiding fractional dimensions in pooling layers, achieved using power-of-2 domain sizes [63].

Table 1. Summary of model configurations for SST predictions. Each combination (C1–C19) specifies the dependent variable (SST) and its relationship to predictor variables, including SLP, QSW, AT, and V10. The spatial resolution of the input data ranges from 25 km to 5 km, as indicated in the third column. Data sources for each combination in the fourth column.

Combination	Variables	Resolution	Data sources
C1	$SST \sim f(SST)$	25km	MUR
C2	$SST \sim f(SLP)$	25km	MUR, ERA5
C3	$SST \sim f(QSW)$	25km	MUR, ERA5
C4	$SST \sim f(AT)$	25km	MUR, ERA5
C5	$SST \sim f(V10)$	25km	MUR, WIND_GLOB
C6	$SST \sim f(SLP, AT)$	25km	MUR, ERA5
C7	$SST \sim f(AT, V10)$	25km	MUR, WIND_GLOB, ERA5
C8	$SST \sim f(SLP, QSW)$	25km	MUR, ERA5
C9	$SST \sim f(SLP, V10)$	25km	MUR, ERA5, WIND_GLOB
C10	$SST \sim f(QSW, V10)$	25km	MUR, ERA5, WIND_GLOB
C11	$SST \sim f(QSW, AT)$	25km	MUR, ERA5
C12	$SST \sim f(SLP, QSW, AT)$	25km	MUR, ERA5
C13	$SST \sim f(SLP, QSW, V10)$	25km	MUR, ERA5, WIND_GLOB
C14	$SST \sim f(SLP, AT, V10)$	25km	MUR, ERA5, WIND_GLOB
C15	$SST \sim f(AT, QSW, V10)$	25km	MUR, ERA5, WIND_GLOB
C16	$SST \sim f(SLP, QSW, AT, V10)$	25km	MUR, ERA5, WIND_GLOB
C17	$SST \sim f(SST)$	12.5km	MUR
C18	$SST \sim f(V10)$	12.5km	MUR, WIND_GLOB
C19	$SST \sim f(SST)$	5km	MUR

2.3.2. Deep learning forecasting models for 2D fields

Deep Learning (DL) techniques encompass a wide array of methodologies suitable for use in ocean forecasting models, from simpler approaches based on classical Artificial Neural Networks for time series prediction [64,65], to more advanced architectures such as: Long Short-Term Memory (LSTM) networks [66], Convolutional Neural Networks (CNN) [67], Recurrent Neural Networks (RNN) [68], and hybrid approaches such as Convolutional Long Short-Term Memory

networks (ConvLSTM) [69] or Transformer models [70]. Furthermore, U-shaped encoder-decoder network architectures (U-Net) [71] and Gated Recurrent Units (GRUs) [71] have previously been used for distinct but complementary tasks in predicting sea surface temperature (SST). U-Nets are primarily applied for spatial forecasting, predicting entire 2D fields of SST by capturing complex spatial patterns, while GRUs are leveraged for time-series forecasting, predicting SST changes at specific, individual locations by learning long-term temporal dependencies. Among all variants presented, alternatives such as U-Net and U-Net-LSTM convolutional encoder-decoder neural networks have demonstrated superior predictive performance with fewer parameters compared to other DL architectures [72], particularly for tasks involving the forecasting of 2D spatial fields. Their strength lies in their ability to efficiently capture and reconstruct complex spatial patterns and multi-scale features, making them highly effective for applications like predicting sea surface temperature or sea level anomaly maps.

Five different DL techniques were evaluated at the four experimental scales described in the previous section (section 2.3.1): 1) ConvLSTM as the foundational recurrent model capable of preserving spatial structure in grid-like data [73], 2) 3D-CNN-LSTM to evaluate a decoupled approach, where 3D convolutions first extract short-term motion features before an LSTM models longer-term temporal patterns [74], 3) IRSTN to assess the model's ability to

capture the non-local, long-range dependencies characteristic of large-scale ocean dynamics, a known limitation for other models [75], 4) TCN for its efficiency and ability to capture long-range temporal patterns using non-recurrent dilated convolutions [76], and 5) U-Net for its proven excellence in reconstructing detailed, multi-scale spatial fields, a critical requirement for predicting 2D ocean maps [77]. Detailed descriptions of these models and their mathematical operations are provided in Figure S1 (Supplementary Material).

The models were trained using the Adam Optimizer with mean squared error (MSE) as the loss function and mean absolute error (MAE) as the error metric [78,79]. Two additional metrics assessed model performance: Root Mean Squared Error (RMSE) and Median Absolute Error (MED). Early stopping was applied with a patience of 5 epochs—where an epoch refers to one complete pass through the entire training dataset—restoring the best weights upon performance stagnation [80,81]. The training dataset was shuffled with a buffer size of 1024 and batched into groups of 32 samples, with the same configuration applied to the validation datasets. Training lasted for 60 epochs. Each model used a 7-day context window to forecast 7 days ahead, identified as the optimal configuration compared to 14- and 21-day lag settings (not shown).

2.4. Upwelling Index

Upwelling events during the study period were identified following the methodology proposed by [40] that builds on previous work by [82]. To derive the upwelling index, we first remove the dominant north-south temperature gradient from the SST fields using the *grdtrend* tool from Generic Mapping Tools (GMT) [83], thus isolating mesoscale variability relevant to upwelling fluctuations. Noise reduction was achieved through a sliding window average (window size $W=5$), enhancing the visibility of upwelling signals. To further accentuate the east-west SST gradient, which is critical for detecting coastal upwelling, we normalized SST values along transects perpendicular to the coastline, a step that also mitigates the risk of over-segmentation in subsequent unsupervised classification. The segmentation of the upwelling regions was then performed using the Spatio-Temporal Seeded Edge Clustering algorithm (STSEC) [84,85], as detailed in the supplementary material (Appendix A). For each extracted region, we computed metrics such as area (in mi^2) and average SST (in $^{\circ}\text{C}$). Finally, the upwelling intensity was classified using SST deciles from the extracted region, with decile 1 corresponding to the highest SST and decile 10 to the lowest, providing a quantitative index of upwelling intensity and spatial extent. A schematic representation of these steps is provided in Figure 2.




Fig. 2. Processing pipeline for coastal upwelling detection from SST dataset, illustrating the transformation sequence from the used SST product through North-South gradient removal, East-West gradient enhancement, STSEC segmentation, to final upwelling index derivation.

Index performance was validated using all upwelling event days from the spring and summer seasons in the test dataset (between 2019-09-07 and 2023-12-31). This evaluation involved comparing predicted SST fields with observed values. A suite of metrics was used to assess both correlation and topological (geometry and structure) discrepancies. Classical metrics, such as correlation (CORR) and the F1 score (F1), quantified the degree of alignment in the deciles. To evaluate topological variations, three metrics were applied: the structural similarity index (SMI), which examines distributional differences in terms of mean and variance [86]; the Jaccard Index (JI), which measures the proportion of predicted nodes that overlap with the observed upwelling geometries [87]; and the percentage difference (DIF %), which calculates the fraction of nodes absent from the predicted matrix relative to the observed matrix. Further details are provided in the supplementary material (Appendix B).

2.5. Time series forecasting

A different approach was used to generate one-dimensional forecasts when only a single point time series was available: two Large Language Models (LLMs): Chronos and Lag-Llama models were used for each upwelling centre selected (see Section 2.3.1). Chronos leverages existing language model architectures, such as the Google Text-to-Text Transfer Transformer (T5), for time series forecasting without requiring domain-specific adjustments [88]. Several architectures are available for this model, including the Tiny, Mini, Small, Base, and Large versions. Notably, superior results were achieved with the Large version, which is expected given its larger number of parameters. Lag-Llama, on the other hand, serves as a foundational model for univariate probabilistic forecasting, trained on a diverse set of time series data [89] (detailed description supplementary material, Appendix C).

Unlike the spatial forecasting setup described in earlier sections, where different grid points were tested for each upwelling region, this 1D approach is specifically designed to work with a single location. This choice is deliberate, since both Chronos and Lag-Llama are inherently tailored for single-point forecasting, avoiding the need to evaluate multiple spatial inputs.

For each upwelling center (Mejillones, Coquimbo, Valparaíso and Concepción), the two models were trained using MUR SST data from the nearest coordinates (Figure 1), taking advantage of the full temporal record. Validation was performed using a rolling daily window, continuously updated throughout the testing phase, following the same approach as [90]. The primary objective of this implementation was to evaluate the efficacy of these innovative models in forecasting geophysical time series such as SST.

3. Results

To identify the most suitable SST product for our analysis, the MUR, OSTIA, and C3S datasets were validated against MODIS satellite data using Taylor diagrams for seasonal and daytime and nighttime orbits in the coastal ocean (shoreward of the 200 m isobath) (Figure 3) and using the entire domain (Figure S2, supplementary material). Taylor's diagrams were performed only for the coastal ocean (shoreward of the 200m isobath) as the differences became more pronounced in this area than in the open ocean. For the 3 products, nighttime consistently outperformed daytime orbits, as evidenced by higher correlation coefficients and lower centred RMSEs (e.g., Figure 3, panels D–F vs. A–C). The daytime RMSEs for MUR ranged between 0.26 and 0.32, while OSTIA and C3S exceeded 0.35 during JJA and SON (Figure 3, A–C). At night, MUR exhibited the

most consistent accuracy across seasons (RMSE: 0.26–0.28), with OSTIA and C3S showing greater seasonal variability (Figure 3, D–F).




Fig. 3. Taylor diagrams evaluating the seasonal performance of daily MUR, OSTIA, and C3S SST products against MODIS reference data within HCS coastal zone (shoreward of the 200m isobath). The top row (A–C) shows validation for daytime data, while the bottom row (D–F) corresponds to nighttime data for the period June 2002–December 2023. Each colored point represents a different season. The diagram quantifies the statistical agreement through the correlation coefficient (azimuthal angle), the centered Root Mean Square Error (gray dashed arcs), and the normalized standard deviation (radial distance from the origin). Blue dotted lines represent the 0.75 and 0.99 correlation values and gray concentric circles represent the Root Mean Square Error (RMSE).

To complement the seasonal averaged statistics from Taylor Diagrams, we performed a spatial analysis of the validation metrics to identify regional patterns of agreement and error for each SST product. The results reveal not only similar differences in performance between daytime and nighttime, but also spatially along and across coastal areas (Figures 4 and 5). During daytime, all products exhibit significant spatial heterogeneity, decreasing the performance of the 3 products toward the coast, showing a distinct band of high RMSE (>0.7 °C) adjacent to the coastline, which intensifies and widens during the austral summer and autumn (DJF, MAM) (Figure 4).

During night-time orbits, all products show a marked increase in correlation and a decrease in RMSE across the domain (Figure 5). The MUR dataset demonstrates a remarkable improvement, with higher correlations in both the offshore and coastal zones, and lower RMSE values compared to daytime results (Figure 5 M-P). In contrast, while OSTIA and C3S also show improvement at night, both retain a persistent signature of elevated RMSE and lower correlation along the immediate coastal zone (Figure 5, Q-X). Correlations for MUR and C3S are generally high (>0.9) offshore the 200m isobath (Figures S3 and S4, supplementary material). Based on the previous results, MUR data is used in the following analysis to perform the forecasting and calculate the upwelling indices.




Fig. 4. Seasonal (Near coast using the 200 m isobath) correlation coefficients (A-D) and root mean square error (E-H) between MODIS Daytime and MUR sea surface temperature datasets for SON, DJF, MAM, and JJA seasons along the continental margin (June 1, 2002, to December 31, 2023).




Fig. 5. Seasonal (Near coast) correlation coefficients (A-D) and root mean square error (E-H) between MODIS Nighttime and MUR sea surface temperature datasets for SON, DJF, MAM, and JJA seasons along the continental margin (June 1, 2002, to December 31, 2023).

3.1. Forecasting variables and models performance

We conducted a comparative analysis of 95 experiments (19 configurations $\times$ 5 models) to identify the optimal architecture (OMC). The models were ranked using the Root Mean Square Error (RMSE), selected as the primary metric because it penalizes significant errors and comprehensively captures both systematic (bias) and random (variance) error components. The U-Net architecture consistently produced the lowest RMSE, demonstrating superior overall performance, and was therefore selected for all subsequent analyses (Figure S5, supplementary material). The optimal configuration was C17 (RMSE range between 0.457 and 0.471, significantly different from other configurations, as shown by the Friedman test, $p_v < 0.05$). This combination is represented by the simulation $SST \sim f(SST)$ at a resolution of 12.5 km (Table 1). The predictive skill of the operational model (OMC; C17) from day 1 (D1) to day 7 (D7) was evaluated under two distinct scenarios: the whole validation period and days exclusively characterized by coastal upwelling. The results for both assessments, based on multiple performance metrics, are detailed in the supplementary material (Tables S1-S2; Figures S6-S7, respectively).

Model C17's error, measured by RMSE (Figure S5, supplementary material), increased systematically and consistently with forecast lead time. For example, the mean RMSE rose from 0.378°C on day 1 (D1) to 0.381°C on day 7 (D7), as

shown in (Tables S1-S2, supplementary material). When only days with upwelling were used, RMSE began lower, at 0.333 °C on D1, rising to 0.384 °C on D7. The standard deviation was also higher during days with only upwelling events, ranging from 0.068 °C to 0.091 °C, compared to 0.061–0.063 °C on all days. Furthermore, the error variability during upwelling events reached 1.09 °C on day 7, in contrast to a maximum of 0.43 °C on all days. This trend was consistent with other metrics (Tables S1-S2, supplementary material). Spatially, the most significant errors were observed between 36 °S and 39 °S, probably due to the complex coastal morphology and null boundary conditions that complicate the convolutional operations of the algorithm. However, in the larger domain, the model's performance is stable, with RMSE values below 0.4 °C in most cases.

3.2. Upwelling index performance

The evaluation of the upwelling index was carried out for the testing period from 2019 to 2023 (30% of the total data, including all the days where at least one upwelling occurs, section 2.4). The evaluations consisted of comparing geometrically the index obtained using the SST forecast with MUR SST using several statistical metrics described in Section 2.4 (Figure 6, see Appendix B for details). The Pearson coefficient (CORR) indicates strong correlation between predictions and reference MUR data, ranging from 0.60 (the lowest in summer 2022) to 0.99 (spring 2019) (Figure 6A). The Structural Similarity Index (SMI)

varies between 0.67 (spring 2021) and 0.99 (summer 2021) (Figure 6B). The Jaccard Index (JI), reflecting segmentation quality (how well a predicted region matches the actual reference region, the real SST values from MUR), spans Jaccard 0.41 to 1.0, with good performance ($JI > 0.7$, and lower variability) observed in summer 2020 and 2022 (Figure 6C). The F1 score offers a single metric that balances precision (the accuracy of the predictions) with recall (the completeness of the predictions), achieving a high average of 0.87 but dipping to 0.55 (Figure 6D). The Percentage Difference (DIF%) ranges from 0% to 34.8% in spring 2019 (Figure 6E). Overall, the model demonstrates stable performance over the five-year evaluation period, and the Percentage Difference remains low, generally under 15%, underscoring the model's reliability. Minor seasonal variability is apparent, with performance metrics consistently improving in summer compared to the preceding spring. For instance, the widest performance range occurred in Spring 2019, where the Percentage Difference spanned from 0% to 34.8% (Figure 6E).




Fig. 6. Boxplots of upwelling index metrics across spring and summer seasons during the test period (2019–2023), showing distributions of Pearson correlation (A), structural similarity index (B), Jaccard index (C), F1 score (D), and percentage difference (E). Metrics are aggregated seasonally to evaluate the performance and consistency of the index over time.

We analyze two upwelling events to assess the spatial performance of the model for the highest upwelling intensity and for the longest upwelling event (Table 2). For the highest intensity case, MUR data shows cold waters along the coast between 39-27 °S, Concepción, Valparaíso y Coquimbo upwelling centers (Figure

7A-D). During this event, temperatures drop almost 2 °C from climatological values (Figure 7E-F). The spatial pattern of the upwelling index has some similarities, especially on the first day of the forecast (Figure 7I-7M).

Table 2. Summary of upwelling events analyzed, including their geographic location, mean intensity, duration, and date range.

Event	Lat (°S)	Lon (°W)	Mean Intensity (°C)	Duration (Days)	Start Date	End Date
Higher Intensity	-71.6875	-30.8125	-1.9734	4	2021-11-16	2021-11-19
Longest	-71.6875	-30.8125	-1.5061	7	2021-02-20	2021-01-26
Event A	-72.8125	-36.4375	-1.6020	5	2022-10-30	2022-11-03
Event B	-71.8125	-33.8125	-1.3837	5	2021-11-28	2021-11-02
Event C	-70.3125	-30.9375	-1.3861	3	2022-01-25	2022-02-28
Event D	-70.1875	-30.5625	-0.8033	6	2022-02-23	2022-02-28

The SMI index begins with a high value of 0.91 ($p_v < 0.05$) on the first day of the forecast, accurately capturing most of the structure of the MUR data. However, as the forecast horizon expands, the SMI gradually decreases to 0.68 ($p_v < 0.05$) on the final day analyzed (day 4). A similar trend is observed for the CORR metric, which starts at 0.93 ($p_v < 0.05$) and decreases to 0.89 ($p_v < 0.05$) (Figure 7M-P). In contrast, the JI and F1 scores do not exhibit a clear pattern between the onset and offset of the event. In contrast, as expected, the DIF% increases with the forecast horizon, starting at 5.67% on the first day and increasing to 24.7% on the last day. Overall, these results suggest that the upwelling index calculated by the model effectively captures this event, correctly identifying at least 7 out of 10 nodes ($\text{DIF\%} < 30\%$) in terms of intensity. Regarding the cover area metric, the first and last days exhibit similar values, with differences ranging from 2.93% to

9.83%. However, notable discrepancies are observed between days 2 and 3 of the event. Furthermore, the mean SST under the upwelling event consistently underestimates the observed values, showing lower variability (13.42–13.85°C, Figure 7M-P, AVG SST metric) compared to the observed range (13.86–14.40°C, Figure 7I-L, AVG SST metric).




Fig. 7. Most intense upwelling event (16–19 Nov 2021). First row (A–D): MUR SST data. Second row (E–H): SST anomalies relative to daily climatology using a trimmed mean at 10%. Third row (I–L): Index derived from observed data. Fourth row (M–P): Index based on SST predictions (leadtime d=0); CORR, JI, CORR, and DIF (%) (fourth row, upper left) calculated by comparing model outputs to observed data (third row). Upwelling index values are scaled by deciles relative to historical values considering only nodes with upwelling events.

For the case of the upwelling with the longest duration (Figure 8), the SMI index increased from 0.9 on the first day of the forecast horizon to approximately 0.96 on the last day. The DIF % did not show a consistent trend, starting at 2.2% ($p_v < 0.05$) on the first day, reaching a peak between the fifth and sixth days at 8.56% and 6.78% ($p_v < 0.05$), respectively, and declining to about 0.68% ($p_v < 0.05$) by the last day. The correlation (CORR) improved steadily from 0.87 ($p_v < 0.05$) to 0.95 ($p_v < 0.05$), while the JI index increased from 0.65 ($p_v < 0.05$) to 0.89 ($p_v < 0.05$) over the same period. Similarly, the F1 score increased from 0.79 ($p_v < 0.05$) initially to 0.94 ($p_v < 0.05$) on the last day. Compared to the previous case, the cover area metrics demonstrate improved results, with discrepancies ranging from 2.10% (5th day) to 29.05% (1st day). Similarly to the previous case, the average SST values are consistently lower, but with greater variability (16.14–16.65°C) compared to the observed values (16.92–17.17°C).




Fig. 8. Longest upwelling event (20–26 Jan 2022). First row (A–G): MUR SST data. Second row (H–N): SST anomalies relative to daily climatology using a trimmed mean at 10%. Third row (O–U): Index derived from observed data. Fourth row (V–ZB): Index based on SST predictions (leadtime d=0); CORR, JI, CORR, and DIF (%) (fourth row, upper left) calculated by comparing model outputs to observed data (third row). Upwelling index values are scaled by deciles relative to historical values considering only nodes with upwelling events.

3.3. Time series forecasting

In contrast to the two-dimensional (2D) spatial forecasting previously discussed (C17), a one-dimensional (1D) approach was implemented to generate high-resolution temporal predictions at discrete coastal locations using a transformer-based LLM architecture. Comparative evaluation revealed that the Chronos model consistently outperformed the Lag Llama architecture across all analysed locations, achieving a two- to threefold reduction in error metrics (data not shown). Performance assessments were conducted for forecast horizons extending to 30 days with daily updates, enabling robust validation against satellite observations (Figure S13, supplementary material).

Using SST anomalies Fig 9A-D the Chronos model demonstrates good short-term predictive skill using SST anomalies, with Pearson correlation coefficients exceeding 0.9 at 1-day lead times across all coastal sites (Figure 9A'-D'). Forecast accuracy degrades systematically with increasing lead time, maintaining useful predictive skill ($\text{CORR} > 0.4$) up to 14 days before approaching the correlation threshold of practical utility. RMSE errors exhibit a corresponding increase from approximately 0.2 °C at 1-day forecasts up to 1.6 °C at 28-day horizons (e.g. Mejillones).

SST Forecast Performance Analysis - Chronos Large Model (2020)

Time Series and Performance Metrics for Intraseasonal Anomalies




Fig. 9. Chronos large language model performance for SST forecasting across multiple locations (see Figure 1). (A-D), Time series comparisons between observed MUR satellite data (blue solid line) and Chronos forecasts at 1-day (orange), 7-day (green), 14-day (red), and 21-day (purple) lead times for 2020. (A'-D'), Quantitative performance metrics showing Pearson correlation coefficients (blue circles, left y-axis) and root-mean-square error (orange squares, right y-axis) as functions of forecast lead time for each location. Horizontal dashed line at correlation = 0 indicates the threshold for useful predictive skill. All metrics are calculated for detrended sea surface temperature anomalies to isolate intraseasonal variability signals.

When we use the SST values for the evaluation, the temporal evolution of forecast skill demonstrates the Chronos model's capacity to systematically outperform

persistence-based forecasting across all lead times and coastal locations (Figure S14, supplementary material). While persistence correlations decline rapidly from initial values of ~ 0.95 at 1-day lead to below 0.8 by 14-21 days, the transformer model maintains consistently higher skill throughout the forecast horizon. The superior performance reflects the model's ability to learn complex temporal dependencies beyond simple lag relationships, particularly evident in its capacity to anticipate seasonal transition periods when persistence forecasting fails entirely.

4. Discussion

Deep learning models have previously been used to predict SST in various contexts, employing both machine learning [91–93] and deep learning techniques [73–77]. However, to our knowledge, there are no previous studies on this topic within the SHCS. Furthermore, this work introduces novel approaches by leveraging Large Language Models (LLMs) such as Chronos and Lag-Llama for univariate SST forecasting — a methodology that, to date, has not been explored in the context of oceanographic time series prediction. Our results indicate that the U-Net-adapted model outperformed other spatio-temporal architectures, including ConvLSTM, 3D-CNN-LSTM, TCN, and IRSTN, with RMSE error metrics ranging from 0.20 to 0.75 °C. The error metrics obtained in this study are comparable to those reported in other applications of deep learning models. For

instance, in the South China Sea, a hybrid model combining EOFs with LSTM and GRU achieved an RMSE of approximately 0.48 °C for a forecast horizon of 5–50 days [94]. Similarly, in the same region, a 3DCBAM-ConvLSTM model applied to a coarser grid (0.25° x 0.25°) for short-term forecasts yielded RMSE values around 0.35 °C [69]. In the East China Sea and Yellow Sea, an integrated Deep Gated Recurrent Unit and Convolutional Neural Network (DGCnetwork) achieved an RMSE of ~0.36 °C at a 1D scale [95]. Around the Korean Peninsula, an LSTM-based model produced R^2 , RMSE, and MAPE values of 0.985 °C, 0.14 °C, and 0.38% for 1-day forecasts, and 0.574 °C, 0.74 °C, and 2.26% for 7-day forecasts [96]. No prior studies have applied deep learning for sub seasonal SST forecasting within the southern HCS. However, the RMSE values of our best-performing model (C17, Figure S5, supplementary material), ranging from 0.457 to 0.471 °C, are consistent with the error metrics reported in other regional studies, including the South China Sea (~0.48 °C, [94]), East China Sea and Yellow Sea (~0.36 °C, [95]), and Korean Peninsula (0.14–0.74 °C depending on forecast horizon [96]).

The integration of advanced deep learning architectures with satellite-derived SST data underscores a transformative step forward in operational forecasting of coastal upwelling dynamics in the HCS. Among the five models assessed, the UNET architecture emerged as the most robust, achieving mean RMSE values below 0.47°C over 7-day forecast horizons. It's ability to resolve fine-scale spatial

features while maintaining computational efficiency offers a critical advantage for resource-limited forecasting systems, surpassing ConvLSTM and 3D-CNN-LSTM models.

As expected, predictions nearshore exhibited higher errors, likely due to sharp gradients induced by boundary conditions, which challenge neural network learning despite the application of techniques such as gradient smoothing and variable masking. This increased error near the boundaries aligns with the findings of [97], who demonstrated that the accuracy and stability of recurrent neural networks are highly sensitive to how boundary conditions are implemented. They emphasize that improper handling of these conditions often leads to significant degradation in prediction performance, especially near domain edges. Thus, accurate modelling of boundary conditions is crucial for improving forecast reliability. Nonetheless, the results demonstrate remarkable predictability. This issue could be addressed using high-resolution dynamical model datasets at various resolutions to train a neural network. This would allow us to investigate how the representation of upwelling coastal dynamics could impact the model structure and the resulting forecast. However, this is beyond the scope of the current study.

The combination of deep learning techniques with the proposed modified SSTE method offers a promising approach to develop operational upwelling indices that

can be easily used by industries such as fisheries. Upwelling is fundamentally a three-dimensional, non-linear process driven by complex interactions among wind forcing, coastal topography, and stratification [98]. Commonly used indices such as the Coastal Upwelling Transport Index (CUTI) and the Bakun Upwelling Transport Index (BEUTI) [99], while theoretically robust in quantifying upwelling-favorable wind forcing, often fail to capture local variability and submesoscale features critical to ecosystem dynamics [100]. Furthermore, these indices are limited by their reliance on coarse resolution wind fields and simplified assumptions about the upwelling process, which can lead to inaccuracies in spatial and temporal representation of upwelling intensity [101]. The proposed integration of deep learning with SSTECH overcomes several of these limitations by effectively assimilating sparse observations and non-linear relationships.

By leveraging deep neural networks trained on a combination of remotely sensed data, in situ measurements, and modelled outputs, the modified SSTECH algorithm can identify latent patterns and complex dependencies in the spatiotemporal structure of upwelling events. This data-driven approach enables the capture of fine-scale variability and transient features that are typically missed by traditional indices, improving the fidelity and responsiveness of operational upwelling metrics. Furthermore, the model's ability to interpolate and extrapolate in regions with limited data coverage enhances its utility for real-time applications in fisheries management and ecosystem monitoring.

Validation against observed events demonstrated strong spatial agreement ($\text{CORR} > 0.89$) and geometric accuracy ($\text{JI} > 0.65$), with the index resolving 70–95% of the upwelling signature topology across a range of events. By delivering spatially explicit, daily resolved intensity metrics, this index overcomes traditional Ekman transport indices' limitations and provides critical tools for fisheries management and biogeochemical monitoring.

Our findings demonstrate that the SSTE algorithm serves as an effective indicator of upwelling, with discrepancies lower than 35% in the geometric topology of upwelling events compared to the observed values. By refining the generation of frontlines, issues such as over segmentation can be mitigated. These techniques represent valuable tools for further exploration in the context of upwelling dynamics.

The application of transformer models to forecast SST time series in this region reflects the growing utility of this architecture across various domains. In other regions, transformer-based models have achieved notable advances in image recognition [102], super-resolution [103], and SST prediction [70,86,104]. Specifically, for SST prediction, studies have reported error metrics over the 1982–2019 period, with testing between 2014 and 2016 in the East China Sea using a coarser grid resolution (25km). These studies achieved a 7-day-ahead

MAPE of approximately 2.18% [104]. Our results show MAPE values ranging from 1.39% to 1.61% at day 1, increasing moderately but remaining below 6% at day 21, which, despite being somewhat higher than coarser-scale studies, convincingly demonstrate the Chronos Large transformer model's robust skill and reliable performance in capturing complex, high-resolution SST variability in HCS. It should be noted that upwelling variability in this region is influenced by large-scale climatic patterns, including fluctuations of the South Pacific Anticyclone and teleconnections from the tropical Pacific such as the Madden-Julian Oscillation (MJO) [105]. Expanding the model's spatial domain to encompass these broader forcing regions holds potential to further improve forecast skill at longer lead times.

5. Conclusions

This study introduces a new framework for SST prediction and upwelling characterization within the SHCS. Among the evaluated models, the U-Net architecture emerges as the premier framework, balancing high spatial resolution and computational efficiency to achieve mean RMSE values below 0.47°C over weekly forecast horizons. This capacity to resolve fine-scale coastal features is essential for deploying forecasting systems in resource-constrained operational settings.

The proposed integration of U-Net with a modified SSTE algorithm yields a novel spatially explicit upwelling intensity index. Validation against observed data indicates that this index captures 70–95% of the front topology and provides a critical tool for ecological forecasting and fisheries management, overcoming intrinsic limitations in traditional Ekman transport-based indices.

Moreover, the LLM Chronos transformer model offers a compelling complementary approach for near real-time SST forecasting at coastal stations, maintaining mean prediction errors under 5% over one-week intervals. This highlights the value of transformer architectures for assimilating complex oceanic spatiotemporal patterns efficiently.

Together, these methodological innovations establish a new paradigm for coastal ocean forecasting in EBUS, combining the interpretive power of deep learning with rigorous physical understanding. In the future, hybrid frameworks that combine data-driven learning with mechanistic models hold great promise for further enhancing forecast skill, particularly in the resolution of coastal nearshore processes.

CRedit authorship contribution statement

David Bustos: Conceptualization, Methodology, Software, Investigation, Formal Analysis, Validation, Data curation, Writing—original draft preparation, Writing – review

& editing, Visualization, Funding acquisition. **Diego Narváez:** Methodology, Validation, Investigation, Writing—original draft preparation, Review and editing, Supervision, Project administration, Funding acquisition. **Boris Dewitte:** Writing – review & editing. **Fabián Tapia:** Writing – review & editing. **Mabel Vidal:** Writing – review & editing.

Declaration of Competing Interest

The authors declare that they have no known competing financial interests or personal relationships that could have appeared to influence the work reported in this paper.

Acknowledgments

David Bustos acknowledges support from ANID scholarship Doctorado Nacional 2021-21210079. Diego Narváez, Fabián Tapia and Boris Dewitte are partially funded by COPAS Coastal ANID FB210021; BD acknowledges support from ANID (Concurso de Fortalecimiento al Desarrollo Científico de Centros Regionales 2020-R20F0008-CEAZA, Fondecyt Regular N°1231174).

References

- [1] V.H. Kourafalou, P. De Mey, J. Staneva, N. Ayoub, A. Barth, Y. Chao, M. Cirano, J. Fiechter, M. Herzfeld, A. Kurapov, Coastal Ocean Forecasting: science foundation and user benefits, *Journal of Operational Oceanography* 8 (2015) s147–s167.
- [2] L. Na, W. Hui, L. Tiejun, Z. Ziqing, Review and prospect of global operational ocean forecasting, *Advances in Earth Science* 33 (2018) 131–140.
- [3] J. Finnis, J.W. Shewmake, B. Neis, D. Telford, Marine forecasting and fishing safety: improving the fit between forecasts and harvester needs, *Journal of Agromedicine* 24 (2019) 324–332.
- [4] W. Burnett, S. Harper, R. Preller, G. Jacobs, K. LaCroix, Overview of operational ocean forecasting in the US Navy: Past, present, and future, *Oceanography* 27 (2014) 24–31.
- [5] N. Pinardi, J. Woods, *Ocean forecasting: conceptual basis and applications*, Springer Science & Business Media, 2002.
- [6] J. Veitch, E. Alvarez-Fanjul, A. Capet, S. Ciliberti, M. Cirano, E. Clementi, F. Davidson, G. el Sarafy, G. Franz, P. Hogan, A description of Ocean Forecasting Applications around the Globe, *State of the Planet Discussions* 2024 (2024) 1–44.
- [7] P. Bauer, A. Thorpe, G. Brunet, The quiet revolution of numerical weather prediction, *Nature* 525 (2015) 47–55.
- [8] E. Kalnay, S.J. Lord, R.D. McPherson, Maturity of operational numerical weather prediction: Medium range, *Bulletin of the American Meteorological Society* 79 (1998) 2753–2770.

- [9] J.S. Link, S. Thur, G. Matlock, M. Grasso, Why we need weather forecast analogues for marine ecosystems, *ICES Journal of Marine Science* 80 (2023) 2087–2098.
- [10] H.U. Sverdrup, W.H. Munk, Wind, sea and swell: Theory of relations for forecasting, Hydrographic Office, 1947.
- [11] R.A. Flather, A.M. Davies, Note on a preliminary scheme for storm surge prediction using numerical models, *Quarterly Journal of the Royal Meteorological Society* 102 (1976) 123–132.
- [12] A.R. Robinson, J.A. Carton, C.N.K. Mooers, L.J. Walstad, E.F. Carter, M.M. Rienecker, J.A. Smith, W.G. Leslie, A real-time dynamical forecast of ocean synoptic/mesoscale eddies, *Nature* 309 (1984) 781–783.
- [13] D.R. McConathy, C.C. Kilgus, The Navy GEOSAT mission: an overview, *Johns Hopkins APL Technical Digest* 8 (1987) 170–175.
- [14] P.W. DeWitt, Model decomposition of the monthly Gulf stream/Kuroshio temperature fields, *NOO Tech. Rep.* 298 (1987).
- [15] M.R. Carnes, J.L. Mitchell, P.W. de Witt, Synthetic temperature profiles derived from Geosat altimetry: Comparison with air-dropped expendable bathythermograph profiles, *Journal of Geophysical Research: Oceans* 95 (1990) 17979–17992.
- [16] M. Cooper, K. Haines, Altimetric assimilation with water property conservation, *Journal of Geophysical Research: Oceans* 101 (1996) 1059–1077.
- [17] P. De Mey, A.R. Robinson, Assimilation of altimeter eddy fields in a limited-area quasi-geostrophic model, *American Meteorological Society*, 1987.
- [18] A. Schiller, N. Smith, BLUElink: Large-to-coastal scale operational oceanography in the southern hemisphere, in: *Ocean Weather Forecasting: An Integrated View of Oceanography*, Springer, 2006: pp. 427–439.
- [19] F. Davidson, A. Alvera-Azcárate, A. Barth, G.B. Brassington, E.P. Chassignet, E. Clementi, P. De Mey-Frémaux, P. Divakaran, C. Harris, F. Hernandez, Synergies in operational oceanography: the intrinsic need for sustained ocean observations, *Frontiers in Marine Science* 6 (2019) 450.
- [20] M.J. Bell, R.M. Forbes, A. Hines, Assessment of the FOAM global data assimilation system for real-time operational ocean forecasting, *Journal of Marine Systems* 25 (2000) 1–22.
- [21] P. Bahurel, M.P. Team, MERCATOR OCEAN global to regional ocean monitoring and forecasting, in: *Ocean Weather Forecasting: An Integrated View of Oceanography*, Springer, 2006: pp. 381–395.
- [22] A. Barbosa Aguiar, M.J. Bell, E. Blockley, D. Calvert, R. Crocker, G. Inverarity, R. King, D.J. Lea, J. Maksymczuk, M.J. Martin, The Met Office Forecast Ocean Assimilation Model (FOAM) using a 1/12-degree grid for global forecasts, *Quarterly Journal of the Royal Meteorological Society* 150 (2024) 3827–3852.
- [23] G.B. Brassington, T. Pugh, C. Spillman, E. Schulz, H. Beggs, A. Schiller, P.R. Oke, BLUElink> Development of operational oceanography and servicing in Australia, *Journal of Research and Practice in Information Technology* 39 (2007) 151–164.
- [24] G. Evensen, The ensemble Kalman filter: Theoretical formulation and practical implementation, *Ocean Dynamics* 53 (2003) 343–367.

- [25] G. Coppini, E. Clementi, G. Cossarini, S. Salon, G. Korres, M. Ravdas, R. Lecci, J. Pistoia, A.C. Goglio, M. Drudi, The mediterranean forecasting system—part 1: evolution and performance, *Ocean Science* 19 (2023) 1483–1516.
- [26] A.I. Kubryakov, G.K. Korotaev, V.L. Dorofeev, Y.B. Ratner, A. Palazov, N. Valchev, V. Malciu, R. Mateescu, T. Oguz, Black Sea coastal forecasting system, *Ocean Science* 8 (2012) 183–196.
- [27] E.P. Chassignet, H.E. Hurlburt, O.M. Smedstad, G.R. Halliwell, P.J. Hogan, A.J. Wallcraft, R. Bleck, Ocean prediction with the hybrid coordinate ocean model (HYCOM), in: *Ocean Weather Forecasting: An Integrated View of Oceanography*, Springer, 2006: pp. 413–426.
- [28] M. Cirano, E. Alvarez-Fanjul, A. Capet, S. Ciliberti, E. Clementi, B. Dewitte, M. Dinápoli, G. El Serafy, P. Hogan, S. Joseph, A description of existing Operational Ocean Forecasting Services around the Globe, *State of the Planet Discussions* 2024 (2024) 1–44.
- [29] K.-H. Kim, P.-S. Shim, S. Shin, An alternative bilinear interpolation method between spherical grids, *Atmosphere* 10 (2019) 123.
- [30] S. Kido, M. Nonaka, Y. Miyazawa, JCOPE-FGO: an eddy-resolving quasi-global ocean reanalysis product, *Ocean Dynamics* 72 (2022) 599–619.
- [31] P.Y. Le Traon, A. Reppucci, E. Alvarez Fanjul, L. Aouf, A. Behrens, M. Belmonte, A. Bentamy, L. Bertino, V.E. Brando, M.B. Kreiner, From observation to information and users: The Copernicus Marine Service perspective, *Frontiers in Marine Science* 6 (2019) 234.
- [32] B. Feng, Z. Wang, Y. Zhang, L. Wan, Numerical simulation of the Northwest Pacific based on the MaCOM, in: *Journal of Physics: Conference Series*, IOP Publishing, 2024: p. 012029.
- [33] F. Hernandez, G. Smith, K. Baetens, G. Cossarini, I. Garcia-Hermosa, M. Drévillon, J. Maksymczuk, A. Melet, C. Régnier, K. von Schuckmann, Measuring Performances, Skill and Accuracy in Operational Oceanography: New Challenges and Approaches., (2018).
- [34] M. Orlić, G.B. Paklar, T. Džoić, P.L. Jelić, I. Međugorac, H. Mihanović, S. Muslim, M. Pasarić, Z. Pasarić, A. Stanešić, Wind-driven upwelling in the Adriatic Sea: Coastal vs. open-sea processes, *Progress in Oceanography* 234 (2025) 103470.
- [35] J. Li, F. Zhai, C. Liu, Y. Gu, P. Li, G. Ye, Wind-driven coastal upwelling causes synoptic-to-intraseasonal variations in tidal temperature variability near a strong shelf front in the northern South China Sea in summer, *Frontiers in Marine Science* 12 (2025) 1553764.
- [36] D. Pauly, V. Christensen, Primary production required to sustain global fisheries, *Nature* 374 (1995) 255–257.
- [37] J. Kämpf, P. Chapman, *Upwelling systems of the world*, Springer, 2016.
- [38] B. Fox-Kemper, Ocean, cryosphere and sea level change, in: *AGU Fall Meeting Abstracts*, 2021: pp. U13B-09.
- [39] P. Fréon, M. Barange, J. Arístegui, Eastern boundary upwelling ecosystems: integrative and comparative approaches, Elsevier, 2009.

- [40] D.F. Bustos, D.A. Narváez, B. Dewitte, V. Oerder, M. Vidal, F. Tapia, Revisiting historical trends in the Eastern Boundary Upwelling Systems with a machine learning method, *Frontiers in Marine Science* 11 (2024) 1446766.
- [41] D.J. Amaya, M.G. Jacox, M.A. Alexander, S.J. Bograd, L. Jia, Seasonal upwelling forecasts in the California Current System, *Geophysical Research Letters* 51 (2024) e2024GL111083.
- [42] P. Roiha, A. Westerlund, N. Haavisto, Forecasting upwelling events with monthly ensembles for the eastern coast of the Gulf of Bothnia in the Baltic Sea, *Journal of Operational Oceanography* 9 (2016) 115–125.
- [43] S.A. Siedlecki, I.C. Kaplan, A.J. Hermann, T.T. Nguyen, N.A. Bond, J.A. Newton, G.D. Williams, W.T. Peterson, S.R. Alin, R.A. Feely, Experiments with seasonal forecasts of ocean conditions for the northern region of the California Current upwelling system, *Scientific Reports* 6 (2016) 27203.
- [44] F. Ye, T. Miles, A.A. Ezzat, Improved spatio-temporal offshore wind forecasting with coastal upwelling information, *Applied Energy* 380 (2025) 125010.
- [45] M. Snoussi, A. Tamim, S. El Fellah, L. Koutti, Spatiotemporal prediction of monthly coastal upwelling scenario in SST fields using deep-learning-based models, *IEEE Geoscience and Remote Sensing Letters* 21 (2024) 1–5.
- [46] R.M. Ponte, M. Carson, M. Cirano, C.M. Domingues, S. Jevrejeva, M. Marcos, G. Mitchum, R.S.W. Van De Wal, P.L. Woodworth, M. Ablain, Towards comprehensive observing and modeling systems for monitoring and predicting regional to coastal sea level, *Frontiers in Marine Science* 6 (2019) 437.
- [47] D. Wang, T.C. Gouhier, B.A. Menge, A.R. Ganguly, Intensification and spatial homogenization of coastal upwelling under climate change, *Nature* 518 (2015) 390–394.
- [48] F.P. Chavez, M. Messié, A comparison of eastern boundary upwelling ecosystems, *Progress in Oceanography* 83 (2009) 80–96.
- [49] R.T. Barber, Coastal upwelling ecosystems, *Analysis of Marine Ecosystems* (1981) 31–68.
- [50] A. Montecinos, F. Gomez, ENSO modulation of the upwelling season off southern-central Chile, *Geophysical Research Letters* 37 (2010).
- [51] W. Cai, M.J. McPhaden, A.M. Grimm, R.R. Rodrigues, A.S. Taschetto, R.D. Garreaud, B. Dewitte, G. Poveda, Y.-G. Ham, A. Santoso, Climate impacts of the El Niño–southern oscillation on South America, *Nature Reviews Earth & Environment* 1 (2020) 215–231.
- [52] C.M. Amos, R.M. Castelao, Influence of the El Niño–Southern Oscillation on SST fronts along the west coasts of North and South America, *Journal of Geophysical Research: Oceans* 127 (2022) e2022JC018479.
- [53] B. Dorschel, L. Hehemann, S. Viquerat, F. Warnke, S. Dreutter, Y.S. Tenberge, D. Accettella, L. An, F. Barrios, E. Bazhenova, The international bathymetric chart of the southern ocean version 2, *Scientific Data* 9 (2022) 275.
- [54] T.M. Chin, J. Vazquez-Cuervo, E.M. Armstrong, A multi-scale high-resolution analysis of global sea surface temperature, *Remote Sensing of Environment* 200 (2017) 154–169.

- [55] C.J. Donlon, M. Martin, J. Stark, J. Roberts-Jones, E. Fiedler, W. Wimmer, The operational sea surface temperature and sea ice analysis (OSTIA) system, *Remote Sensing of Environment* 116 (2012) 140–158.
- [56] C.J. Merchant, O. Embury, C.E. Bulgin, T. Block, G.K. Corlett, E. Fiedler, S.A. Good, J. Mittaz, N.A. Rayner, D. Berry, Satellite-based time-series of sea-surface temperature since 1981 for climate applications, *Scientific Data* 6 (2019) 223.
- [57] H. Hersbach, B. Bell, P. Berrisford, S. Hirahara, A. Horányi, J. Muñoz-Sabater, J. Nicolas, C. Peubey, R. Radu, D. Schepers, The ERA5 global reanalysis, *Quarterly Journal of the Royal Meteorological Society* 146 (2020) 1999–2049.
- [58] Copernicus, Global Ocean Hourly Sea Surface Wind and Stress from Scatterometer and Model, (2024). <https://doi.org/10.48670/moi-00305>.
- [59] V.V. Salomonson, W.L. Barnes, P.W. Maymon, H.E. Montgomery, H. Ostrow, MODIS: Advanced facility instrument for studies of the Earth as a system, *IEEE Transactions on Geoscience and Remote Sensing* 27 (1989) 145–153.
- [60] P.A. Hubanks, M.D. King, S. Platnick, R. Pincus, MODIS atmosphere L3 gridded product algorithm theoretical basis document, ATBD Reference Number: ATBD-MOD-30 30 (2008) 96.
- [61] M. Bhagat, B. Bakariya, A comprehensive review of cross-validation techniques in machine learning, *IJSAT-International Journal on Science and Technology* 16 (2025).
- [62] N. Shawki, R.R. Nunez, I. Obeid, J. Picone, On automating hyperparameter optimization for deep learning applications, in: 2021 IEEE Signal Processing in Medicine and Biology Symposium (SPMB), IEEE, 2021: pp. 1–7.
- [63] J.O. Donoghue, M. Roantree, A framework for selecting deep learning hyperparameters, in: *British International Conference on Databases*, Springer, 2015: pp. 120–132.
- [64] K. Patil, M.C. Deo, Prediction of daily sea surface temperature using efficient neural networks, *Ocean Dynamics* 67 (2017) 357–368.
- [65] J. Taylor, M. Feng, A deep learning model for forecasting global monthly mean sea surface temperature anomalies, *Frontiers in Climate* 4 (2022) 932932.
- [66] J. Choi, S.-W. Son, J. Lu, S.-K. Min, Further observational evidence of Hadley cell widening in the Southern Hemisphere, *Geophysical Research Letters* 41 (2014) 2590–2597.
- [67] L. Wei, L. Guan, Seven-day sea surface temperature prediction using a 3DConv-LSTM model, *Frontiers in Marine Science* 9 (2022) 905848.
- [68] T. Song, J. Jiang, W. Li, D. Xu, A deep learning method with merged LSTM neural networks for SSHA prediction, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 13 (2020) 2853–2860.
- [69] T. Fei, B. Huang, X. Wang, J. Zhu, Y. Chen, H. Wang, W. Zhang, A hybrid deep learning model for the bias correction of sst numerical forecast products using satellite data, *Remote Sensing* 14 (2022) 1339.
- [70] Y. Fu, J. Song, J. Guo, Y. Fu, Y. Cai, Prediction and analysis of sea surface temperature based on LSTM-transformer model, *Regional Studies in Marine Science* 78 (2024) 103726.

- [71] J. Ren, C. Wang, L. Sun, B. Huang, D. Zhang, J. Mu, J. Wu, Prediction of sea surface temperature using U-Net based model, *Remote Sensing* 16 (2024) 1205.
- [72] P.R. Larraondo, L.J. Renzullo, I. Inza, J.A. Lozano, A data-driven approach to precipitation parameterizations using convolutional encoder-decoder neural networks, *arXiv Preprint arXiv:1903.10274* (2019).
- [73] X. Shi, Z. Chen, H. Wang, D.-Y. Yeung, W.-K. Wong, W. Woo, Convolutional LSTM network: A machine learning approach for precipitation nowcasting, *Advances in Neural Information Processing Systems* 28 (2015).
- [74] X. Wang, Z. Miao, R. Zhang, S. Hao, I3d-lstm: A new model for human action recognition, in: *IOP Conference Series: Materials Science and Engineering*, IOP Publishing, 2019: p. 032035.
- [75] T.H. Kim, M.S. Sajjadi, M. Hirsch, B. Scholkopf, Spatio-temporal transformer network for video restoration, in: *Proceedings of the European Conference on Computer Vision (ECCV)*, 2018: pp. 106–122.
- [76] M. Liu, A. Zeng, Z. Xu, Q. Lai, Q. Xu, Time series is a special sequence: Forecasting with sample convolution and interaction, *arXiv Preprint arXiv:2106.09305* 1 (2021).
- [77] O. Ronneberger, P. Fischer, T. Brox, U-net: Convolutional networks for biomedical image segmentation, in: *International Conference on Medical Image Computing and Computer-Assisted Intervention*, Springer, 2015: pp. 234–241.
- [78] K.D.B.J. Adam, A method for stochastic optimization, *arXiv Preprint arXiv:1412.6980* 1412 (2014).
- [79] A. Ziat, E. Delasalles, L. Denoyer, P. Gallinari, Spatio-temporal neural networks for space-time series forecasting and relations discovery, in: *2017 IEEE International Conference on Data Mining (ICDM)*, IEEE, 2017: pp. 705–714.
- [80] M.V. Ferro, Y.D. Mosquera, F.J.R. Pena, V.M.D. Bilbao, Early stopping by correlating online indicators in neural networks, *Neural Networks* 159 (2023) 109–124.
- [81] B.M. Hussein, S.M. Shareef, An empirical study on the correlation between early stopping patience and epochs in deep learning, in: *ITM Web of Conferences*, EDP Sciences, 2024: p. 01003.
- [82] A. Abrahams, R.W. Schlegel, A.J. Smit, Variation and change of upwelling dynamics detected in the world's eastern boundary upwelling systems, *Frontiers in Marine Science* 8 (2021) 626411.
- [83] P. Wessel, J.F. Luis, L. al Uieda, R. Scharroo, F. Wobbe, W.H. Smith, D. Tian, The generic mapping tools version 6, *Geochemistry, Geophysics, Geosystems* 20 (2019) 5556–5564.
- [84] A. El Aouni, K. Daoudi, K. Minaoui, H. Yahia, Robust detection of the North-West African upwelling from SST images, *IEEE Geoscience and Remote Sensing Letters* 18 (2020) 573–576.
- [85] S. Nascimento, S. Casca, B. Mirkin, A seed expanding cluster algorithm for deriving upwelling areas on sea surface temperature images, *Computers & Geosciences* 85 (2015) 74–85.

- [86] Z. Wang, A.C. Bovik, H.R. Sheikh, E.P. Simoncelli, Image quality assessment: from error visibility to structural similarity, *IEEE Transactions on Image Processing* 13 (2004) 600–612.
- [87] R. Real, J.M. Vargas, The probabilistic basis of Jaccard's index of similarity, *Systematic Biology* 45 (1996) 380–385.
- [88] A.F. Ansari, L. Stella, C. Turkmen, X. Zhang, P. Mercado, H. Shen, O. Shchur, S.S. Rangapuram, S.P. Arango, S. Kapoor, Chronos: Learning the language of time series, *arXiv Preprint arXiv:2403.07815* (2024).
- [89] K. Rasul, A. Ashok, A.R. Williams, A. Khorasani, G. Adamopoulos, R. Bhagwatkar, M. Biloš, H. Ghonia, N. Hassen, A. Schneider, Lag-llama: Towards foundation models for time series forecasting, in: *R0-FoMo: Robustness of Few-Shot and Zero-Shot Learning in Large Foundation Models*, 2023.
- [90] D.F. Bustos Usta, L. Rodríguez-López, R.R. Torres Parra, L. Bourrel, Sea Surface Temperature Forecasting Using Foundational Models: A Novel Approach Assessed in the Caribbean Sea, *Remote Sensing* 17 (2025) 517.
- [91] S. Wolff, F. O'Donncha, B. Chen, Statistical and machine learning ensemble modelling to forecast sea surface temperature, *Journal of Marine Systems* 208 (2020) 103347.
- [92] S. Kartal, Assessment of the spatiotemporal prediction capabilities of machine learning algorithms on sea surface temperature data: A comprehensive study, *Engineering Applications of Artificial Intelligence* 118 (2023) 105675.
- [93] G. Bonino, G. Galimberti, S. Masina, R. McAdam, E. Clementi, Machine learning methods to predict sea surface temperature and marine heatwave occurrence: a case study of the Mediterranean Sea, *Ocean Science* 20 (2024) 417–432.
- [94] M. Zhang, G. Han, X. Wu, C. Li, Q. Shao, W. Li, L. Cao, X. Wang, W. Dong, Z. Ji, SST forecast skills based on hybrid deep learning models: With applications to the South China Sea, *Remote Sensing* 16 (2024) 1034.
- [95] X. Yu, S. Shi, L. Xu, Y. Liu, Q. Miao, M. Sun, A novel method for sea surface temperature prediction based on deep learning, *Mathematical Problems in Engineering* 2020 (2020) 6387173.
- [96] H.-M. Choi, M.-K. Kim, H. Yang, Deep-learning model for sea surface temperature prediction near the Korean Peninsula, *Deep Sea Research Part II: Topical Studies in Oceanography* 208 (2023) 105262.
- [97] A. Alguacil, W.G. Pinto, M. Bauerheim, M.C. Jacob, S. Moreau, Effects of boundary conditions in fully convolutional networks for learning spatio-temporal dynamics, in: *Joint European Conference on Machine Learning and Knowledge Discovery in Databases*, Springer, 2021: pp. 102–117.
- [98] D.M. Checkley Jr, J.A. Barth, Patterns and processes in the California Current System, *Progress in Oceanography* 83 (2009) 49–64.
- [99] M.G. Jacox, C.A. Edwards, E.L. Hazen, S.J. Bograd, Coastal upwelling revisited: Ekman, Bakun, and improved upwelling indices for the US West Coast, *Journal of Geophysical Research: Oceans* 123 (2018) 7332–7350.

- [100] M. García-Reyes, J. Largier, Observations of increased wind-driven coastal upwelling off central California, *Journal of Geophysical Research: Oceans* 115 (2010).
- [101] E.M. Jorgensen, E.L. Hazen, M.G. Jacox, M. Pozo Buil, I. Schroeder, S.J. Bograd, Physical and biogeochemical phenology of coastal upwelling in the California Current System, *Geophysical Research Letters* 51 (2024) e2024GL108194.
- [102] Z.-M. Chen, Q. Cui, B. Zhao, R. Song, X. Zhang, O. Yoshie, SST: Spatial and semantic transformers for multi-label image recognition, *IEEE Transactions on Image Processing* 31 (2022) 2570–2583.
- [103] R. Zou, L. Wei, L. Guan, Super resolution of satellite-derived sea surface temperature using a transformer-based model, *Remote Sensing* 15 (2023) 5376.
- [104] D. Song, S. Dai, W. Li, T. Ren, Z. Wei, A.-A. Liu, STVformer: A spatial-temporal-variable transformer with auxiliary knowledge for sea surface temperature prediction, *Applied Ocean Research* 153 (2024) 104218.
- [105] M. Vuille, R.D. Garreaud, Ocean-atmosphere interactions on interannual to decadal timescales, *Handbook of Environmental Change* 1 (2012) 471–496.

5. DISCUSIÓN

Esta tesis marca un avance en el estudio de los sistemas de surgencia de borde oriental (EBUS) al aplicar un doble enfoque de inteligencia artificial que aborda tanto el diagnóstico de patrones históricos como el pronóstico operativo. Mientras que estudios anteriores se han basado predominantemente en métodos lineales como el análisis EOF para analizar tendencias, o en modelos físicos para la predicción, este trabajo demuestra la sinergia entre dos ramas complementarias de la inteligencia artificial. Por un lado, el uso de aprendizaje no supervisado, mediante mapas auto-organizados (SOM) y clustering jerárquico (HAC), ha permitido destilar décadas de datos multivariados en patrones de variabilidad dominantes, capturando interacciones no lineales que los métodos lineales pueden pasar por alto (i.e. (Abrahams et al., 2021b; Bonino et al., 2019; García-

Reyes et al., 2015). Por otro lado, la aplicación de arquitecturas de aprendizaje profundo, (U-Net y Chronos), hasta ahora inexploradas para el pronóstico de TSM en el sistema de la Corriente de Humboldt (HCS) ha probado ser herramientas de alta eficacia, alcanzando una precisión comparable a la obtenida en otras regiones oceánicas complejas como el Mar de China meridional (Ansari et al., 2024; Fei et al., 2022, 2022; Ren et al., 2024)

Se postuló que el cambio climático afectaría los EBUS a través de un balance entre tres mecanismos: (1) la intensificación del viento por el gradiente térmico océano-tierra, (2) la migración de los vientos hacia los polos por la expansión de la Célula de Hadley, y (3) un efecto moderador debido al aumento de la estratificación oceánica. Los resultados de esta investigación confirman parcialmente esta hipótesis, validando la importancia de los mecanismos (2) y (3), mientras que refutan la preponderancia del mecanismo (1). Asimismo, se encontró que la respuesta latitudinal de los centros de surgencia es más compleja y heterogénea que la inicialmente planteada.

En línea con la evaluación de la hipótesis, el análisis histórico (1993-2019) no muestra evidencia que soporte para la hipótesis clásica de Bakun (1990), un hallazgo que corrobora estudios previos (Abrahams et al., 2021b; Rykaczewski et al., 2015). En cambio, la evidencia confirma de manera robusta el segundo mecanismo propuesto: el desplazamiento hacia los polos de los sistemas subtropicales de alta presión, consecuencia de la expansión de la Célula de

Hadley, se consolida como el principal motor de los cambios observados. Esta conclusión es crucial, pues implica que la habilidad predictiva de los modelos depende de su capacidad para capturar estas teleconexiones atmosféricas a gran escala.

Al proyectar esta dinámica hacia el futuro (2015-2050), los resultados del experimento HighResMIP revelan el papel dominante del tercer mecanismo propuesto: el aumento de la estratificación oceánica. A pesar de la influencia de los anticiclones (mecanismo 2), la proyección dominante es una disminución en la frecuencia y duración de los eventos de surgencia. Este hallazgo, que podría parecer contraintuitivo, sugiere que el calentamiento superficial actúa como un freno dinámico, dificultando que el forzamiento del viento se traduzca eficientemente en el ascenso de aguas frías (Schlaefer et al., 2025; Sousa et al., 2020). Este balance competitivo entre el forzamiento atmosférico y la resistencia oceánica genera una respuesta espacialmente heterogénea, matizando la predicción inicial de un patrón latitudinal simple y subrayando que el futuro de los EBUS debe entenderse como una interacción compleja entre múltiples forzantes.

Finalmente, la validación de la IA como herramienta de pronóstico operativo cierra el ciclo de esta investigación. El éxito de la arquitectura U-Net ($RMSE < 0.47^{\circ}C$) y del modelo Chronos ($MAPE < 6\%$ a 21 días) en el HCS representa un salto cualitativo frente a los sesgos significativos que a menudo presentan los modelos físicos en zonas costeras (Varela et al., 2022). La generación de un

índice de surgencia espacialmente explícito, que supera las limitaciones de los índices tradicionales como CUTI o BEUTI (Jacox et al., 2018), constituye una prueba de concepto para el desarrollo de productos operacionales de alto valor para la gestión de pesquerías y la monitorización del ecosistema.

6. CONCLUSIONES

En respuesta a los objetivos planteados, esta tesis ha llegado a las siguientes conclusiones principales:

1. La caracterización de los modos de variabilidad en los EBUS (1993-2019) mediante aprendizaje no supervisado (SOM-HAC) permitió identificar la variabilidad dominante de la surgencia, con eventos más prolongados y de mayor intensidad relativa durante el verano. Se concluye entonces que la variabilidad histórica de este régimen estacional esta principalmente gobernada por el desplazamiento hacia los polos de los anticiclones de alta presión. Este hallazgo refuta la hipótesis de Bakun como principal mecanismo de cambio en el periodo analizado y confirma la influencia de la circulación atmosférica a gran escala.
2. La evaluación de proyecciones climáticas (2015-2050) con el modelo HadGEM-GC31-HH bajo el escenario SSP5-8.5, revela una transición en el régimen de surgencia descrito anteriormente. Si bien la influencia atmosférica (conclusión 1) persiste, su efecto en la expresión superficial del afloramiento pareciera verse contrarrestada por la emergencia de un nuevo factor dominante: el aumento de la estratificación oceánica. Esto lleva a la conclusión de que en el futuro los centros de surgencia estarán marcados por una disminución significativa en la frecuencia y duración de los eventos, con cambios no significativos en intensidad. Este balance

entre forzantes conduciría a un régimen de surgencia más intermitente. Una vez más, es importante mencionar que el grado de confianza de estos pronósticos es de nivel medio, debido a que los modelos del CMIP6 presentan diversos sesgos cerca de la costa que hay que considerar a la hora de establecer cualquier conclusión.

3. Se ha desarrollado y validado con éxito un algoritmo de pronóstico de la TSM para el Sistema de la Corriente de Humboldt basado en arquitecturas de Deep Learning. Los modelos U-Net (para campos 2D) y Chronos (para series de tiempo) demostraron una alta precisión y habilidad predictiva en la escala sinóptica y sub-estacional, estableciendo la viabilidad de la IA para la predicción operativa en EBUS.

GLOSARIO

A

- **Anomalía:** Desviación de una variable (como la temperatura) respecto a su promedio climatológico a largo plazo. En la tesis se usa para detectar eventos extremos o tendencias de calentamiento/enfriamiento.
- **Anticiclón Subtropical (SHPS - Subtropical High-Pressure System):** Sistemas de alta presión atmosférica semi-permanentes (p. ej. Anticiclón del Pacífico Sur). Su posición e intensidad modulan los vientos favorables a la surgencia.
- **Aprendizaje Profundo (Deep Learning - DL):** Subcampo del aprendizaje automático basado en redes neuronales artificiales con múltiples capas (profundas) capaces de aprender representaciones jerárquicas de datos. Utilizado en la tesis (modelos U-Net, LSTM) para pronósticos.
- **Aprendizaje No Supervisado:** Tipo de algoritmo de IA que infiere patrones de un conjunto de datos sin etiquetas previas.
- **Argo:** Programa internacional de observación oceánica que utiliza flotadores perfiladores autónomos para medir temperatura, salinidad y corrientes en los primeros 2000 metros del océano. Usado para validación.

B

- **Batimetría:** Estudio y mapa de las profundidades del suelo oceánico.

- **BenCS (Benguela Current System):** Sistema de Corriente de Benguela. Uno de los cuatro principales EBUS, ubicado al suroeste de África.
- **BEUTI (Biologically Effective Upwelling Transport Index):** Índice de transporte de surgencia biológicamente efectivo. Estima el flujo vertical de nitratos.
- **Bias (Sesgo):** Error sistemático en los modelos climáticos o de predicción donde los valores estimados se desvían consistentemente de las observaciones (ej. sobreestimación de la TSM cerca de la costa en modelos CMIP6).
- **BMU (Best Matching Unit):** En un algoritmo SOM, es la neurona cuyo vector de pesos es más similar al vector de entrada actual.

C

- **CalCS (California Current System):** Sistema de Corriente de California. EBUS ubicado en la costa oeste de Norteamérica.
- **CanCS / C-ICS (Canary - Iberian Current System):** Sistema de Corriente de Canarias y Península Ibérica. EBUS ubicado al noroeste de África y suroeste de Europa.
- **Celdas de Hadley:** Circulación atmosférica global que transporta calor desde el ecuador hacia los subtrópicos. Su expansión debido al cambio climático se vincula al desplazamiento de los anticiclones.

- **Chronos:** Un modelo de lenguaje grande (LLM) adaptado para el pronóstico de series temporales. Utilizado en la tesis para predecir la TSM en puntos específicos.
- **Ciclo Estacional:** Variación periódica anual de las condiciones oceanográficas y atmosféricas.
- **Climatología:** Promedio a largo plazo de variables meteorológicas u oceanográficas (usualmente 30 años) usado como línea base.
- **Cluster (Agrupamiento):** Conjunto de datos que comparten características similares.
- **CMIP6 (Coupled Model Intercomparison Project Phase 6):** Sexta fase del Proyecto de Intercomparación de Modelos Acoplados del IPCC. Proporciona proyecciones climáticas globales.
- **CNN (Convolutional Neural Network):** Red Neuronal Convolucional. Tipo de red diseñada para procesar datos con estructura de rejilla (como imágenes de satélite de TSM).
- **ConvLSTM:** Arquitectura híbrida que combina redes convolucionales (para espacio) y LSTM (para tiempo), útil para predicción de video o secuencias espaciales.
- **CUTI (Coastal Upwelling Transport Index):** Índice de Transporte de Surgencia Costera. Mide el volumen de agua transportada verticalmente.

D

- **Data-Driven:** Enfoque basado en datos. Metodología científica que se basa en el análisis de grandes volúmenes de datos (usando IA) en lugar de solo modelos teóricos o físicos tradicionales.
- **Diagrama de Taylor:** Gráfico que resume estadísticamente qué tan bien coinciden los patrones espaciales de un modelo con las observaciones (usando correlación, error cuadrático medio y desviación estándar).
- **Drop-off:** Disminución de la velocidad del viento cerca de la costa, relevante para el rotacional del viento.

E

- **EBUS (Eastern Boundary Upwelling Systems):** Sistemas de Surgencia de Borde Oriental. Regiones oceánicas altamente productivas en los bordes orientales de las cuencas oceánicas (Humboldt, California, Benguela, Canarias).
- **ENSO (El Niño-Southern Oscillation):** Modo de variabilidad climática interanual que afecta significativamente a los EBUS, especialmente al sistema de Humboldt.
- **EOF (Empirical Orthogonal Functions):** Funciones Empíricas Ortogonales. Método estadístico lineal tradicional para analizar variabilidad (similar a PCA).

- **Ep (Ekman Pumping):** Abreviatura utilizada para el bombeo de Ekman.
- **ERA5:** Reanálisis atmosférico global de quinta generación del ECMWF. Provee datos históricos consistentes de la atmósfera.
- **Error de Cuantización (Quantization Error):** Métrica de desempeño en SOM que mide la distancia promedio entre los datos de entrada y sus BMUs.
- **Error Topológico:** Métrica en SOM que cuantifica qué tan bien la red preserva la estructura espacial de los datos.

F

- **Forzamiento Radiativo:** Cambio en el flujo neto de energía en la atmósfera (medido en Wm^{-2}).
- **F1 Score:** Métrica de evaluación para modelos de clasificación que combina precisión y sensibilidad.

G

- **GEBCO:** General Bathymetric Chart of the Oceans. Fuente de datos batimétricos.

H

- **HAC (Hierarchical Agglomerative Clustering):** Clustering Jerárquico Aglomerativo. Algoritmo que agrupa los nodos del SOM para reducir la redundancia y definir los modos principales de variabilidad.
- **HighResMIP:** Proyecto de Intercomparación de Modelos de Alta Resolución dentro de CMIP6. Fundamental en la tesis por ofrecer resoluciones oceánicas de ~10-50km.
- **Hindcast:** Simulación retrospectiva de condiciones pasadas utilizando un modelo numérico forzado por observaciones históricas.
- **Hist-1950:** Experimento de simulación histórica de HighResMIP (1950-2014).
- **HumCS / HCS (Humboldt Current System):** Sistema de la Corriente de Humboldt (o Perú-Chile).

I

- **IA (Inteligencia Artificial):** Campo de la informática que busca simular procesos de inteligencia humana mediante algoritmos.
- **Interpolación Bilineal:** Método matemático para estimar valores en una rejilla regular a partir de datos con diferente resolución, utilizado para estandarizar los datos de satélites y modelos.

L

- **Lag-Llama:** Modelo fundacional probabilístico para pronóstico de series temporales univariadas. Comparado con Chronos en la tesis.
- **LLM (Large Language Model):** Modelos de lenguaje grandes (ej. GPT, BERT).
- **LSTM (Long Short-Term Memory):** Tipo de red neuronal recurrente capaz de aprender dependencias a largo plazo en datos secuenciales (series de tiempo).

M

- **MHW (Marine Heatwaves):** Olas de Calor Marinas. Eventos extremos de temperatura oceánica cálida.
- **MLD (Mixed Layer Depth):** Profundidad de la Capa de Mezcla. Capa superior del océano donde temperatura y salinidad son casi uniformes.
- **MODIS:** Sensor satelital (Moderate Resolution Imaging Spectroradiometer) utilizado para obtener datos de Temperatura Superficial del Mar (TSM) y Clorofila-a.
- **MUR (Multi-scale Ultra-high Resolution):** Producto de TSM satelital de alta resolución (1 km).
- **Mw (Meridional Wind):** Componente meridional (Norte-Sur) del viento. Crucial para la surgencia en costas orientadas norte-sur.

O

- **OISST:** Optimum Interpolation Sea Surface Temperature. Producto de TSM de la NOAA que combina satélites y observaciones in-situ.
- **OSTIA:** Operational Sea Surface Temperature and Sea Ice Analysis. Producto de TSM de alta resolución.

P

- **PDO (Pacific Decadal Oscillation):** Oscilación Decadal del Pacífico. Patrón de variabilidad climática de larga duración en el Pacífico Norte.
- **Pronóstico Operacional:** Generación rutinaria y en tiempo real de predicciones sobre el estado futuro.

R

- **Reanálisis:** Método que combina modelos meteorológicos con observaciones asimiladas para crear un registro histórico consistente del clima (ej. ERA5).
- **Resolución Espacial/Temporal:** Nivel de detalle en espacio (km) y tiempo (días/horas) de los datos. La tesis enfatiza la necesidad de alta resolución para resolver la surgencia.
- **RMSE (Root Mean Square Error):** Raíz del Error Cuadrático Medio. Métrica estándar para medir el error de un modelo.

- **Rotor del Viento (Wind Stress Curl):** Medida de la rotación del viento. Su gradiente espacial induce el bombeo de Ekman (surgencia o hundimiento en mar abierto).

S

- **Surgencia Costera (Coastal Upwelling):** Ascenso de aguas profundas, frías y ricas en nutrientes hacia la superficie, impulsado por el viento y la rotación de la Tierra.
- **Silhouette Score:** Métrica para validar la consistencia dentro de los clusters generados por algoritmos de IA.
- **SOM (Self-Organizing Maps):** Mapas Auto-Organizados. Tipo de red neuronal no supervisada usada para reducir la dimensionalidad y visualizar patrones topológicos en los datos.
- **SSP5-8.5 (Shared Socioeconomic Pathway):** Escenario de altas emisiones de gases de efecto invernadero utilizado en las proyecciones futuras hasta 2100.
- **STSEC (Spatio-Temporal Seeded Edge Clustering):** Algoritmo de segmentación utilizado y modificado en la tesis para derivar un índice de surgencia espacialmente explícito.

T

- **TCN (Temporal Convolutional Network):** Red Convolutacional Temporal. Arquitectura de DL para manejo de secuencias.
- **Teleconexión:** Vínculo climático entre regiones geográficamente distantes.
- **TSM / SST:** Temperatura Superficial del Mar (Sea Surface Temperature). Variable principal analizada.

U

- **U-Net:** Arquitectura de red neuronal convolutacional en forma de U, diseñada originalmente para segmentación de imágenes biomédicas, usada en la tesis para pronosticar campos espaciales de TSM.

V

- **Validación Cruzada (Cross-validation):** Técnica estadística para evaluar la capacidad de generalización de un modelo predictivo, dividiendo los datos en subconjuntos de entrenamiento y prueba.
- **Varianza Explicada:** Proporción de la variabilidad de los datos que es capturada por un modelo matemático o estadístico.

Z

- **Zona de Mínimo Oxígeno (OMZ):** Capas de agua con muy bajo contenido de oxígeno, típicas en los EBUS debajo de la capa superficial productiva.

ANEXO A - MARCO TEÓRICO MATEMÁTICO DE LOS MODELOS DE INTELIGENCIA ARTIFICIAL APLICADOS A LA DINÁMICA DE EBUS

La dinámica de los Sistemas de Surgencia de Borde Oriental (EBUS) se rige por ecuaciones diferenciales parciales no lineales (Navier-Stokes, ecuaciones primitivas) que exhiben variabilidad en múltiples escalas espaciales y temporales. Tradicionalmente, el análisis de estos sistemas se ha basado en métodos estadísticos lineales (como EOFs). Sin embargo, la naturaleza estocástica y altamente no lineal de la interacción océano-atmósfera sugiere que los aproximadores de funciones universales, como las Redes Neuronales Artificiales (ANNs), son herramientas superiores para capturar la variabilidad oculta.

Este anexo detalla los fundamentos matemáticos de los algoritmos utilizados en esta tesis para el reconocimiento de patrones (Aprendizaje No Supervisado) y el pronóstico de campos geofísicos (Aprendizaje Profundo), justificando su idoneidad para resolver problemas oceanográficos.

Aprendizaje No Supervisado: Mapas Auto-Organizados (SOM)

El algoritmo SOM (Kohonen, 1982) se utiliza en el Capítulo 1 para reducir la dimensionalidad de los datos oceanográficos preservando su topología. A diferencia de las EOFs, que asumen ortogonalidad y estacionariedad, los SOMs permiten mapear un espacio de entrada continuo y de alta dimensión (D) a un

espacio de salida discreto y de baja dimensión (generalmente 2D), preservando las relaciones de vecindad.

Fundamento Matemático

Sea $X = \{x(t) \in \mathbb{R}^D\}$ el conjunto de vectores de entrada (e.g., campos de TSM, viento, presión). La red SOM consiste en un conjunto de neuronas organizadas en una grilla, donde cada neurona i tiene asociado un vector de pesos $w_i \in \mathbb{R}^D$.

El proceso de entrenamiento es competitivo e iterativo:

1. Competencia (Best Matching Unit - BMU): Para cada vector de entrada $x(t)$, se encuentra la neurona ganadora c cuya distancia Euclidiana es mínima:

$$c = \underset{i}{\operatorname{argmin}} ||x(t) - w_i(t)||$$

2. Adaptación (Regla de Aprendizaje): Los pesos de la neurona ganadora y sus vecinas topológicas se actualizan para acercarse al vector de entrada:

$$w_i(t) = w_i(t) + \alpha(t) \cdot h_{ci}(t) \cdot [x(t) - w_i(t)]$$

Donde $\alpha(t)$ es la tasa de aprendizaje (que decae con el tiempo) y $h_{ci}(t)$ es la función de vecindad (generalmente Gaussiana), que define el radio de influencia alrededor de la BMU:

$$h_{ci}(t) = \exp\left(-\frac{\|r_c - r_i\|^2}{2\sigma^2(t)}\right)$$

Justificación Oceanográfica

El SOM es ideal para estudiar los EBUS porque la función de vecindad $h_{ci}(t)$ asegura que patrones oceanográficos similares (p. ej. eventos de surgencia intensa vs. relajación) se mapeen en neuronas adyacentes. Esto permite visualizar el "continuo" de la evolución dinámica del sistema, capturando transiciones no lineales y asimetrías que los métodos lineales promediarían o descartarían como ruido

Aprendizaje Profundo para Pronóstico de Campos 2D: Arquitectura U-Net

En el Capítulo 3, se selecciona la arquitectura **U-Net** como el modelo óptimo (OMC) para el pronóstico espacial de TSM. Originalmente diseñada para segmentación biomédica, esta arquitectura ha demostrado ser superior a las LSTMs convencionales para problemas de dinámica de fluidos debido a su capacidad para manejar características multiescala.

Arquitectura y Formulación Matemática

La U-Net es una Red Neuronal Convolutiva (CNN) con estructura de codificador-decodificador (encoder-decoder) y conexiones residuales ("skip connections").

1. Ruta de Contracción (Encoder): Captura el contexto global mediante operaciones de convolución seguidas de max-pooling. Matemáticamente, para una capa l , la salida y^l es:

$$y^l = f(W^l * x^l + b^l)$$

Donde $*$ denota la operación de convolución, W son los filtros (kernels) que aprenden características espaciales (como gradientes de temperatura o frentes), y f es la función de activación (p. ej. ReLU). La operación de pooling reduce la dimensionalidad espacial, aumentando el campo receptivo para capturar dinámicas de gran escala

2. **Ruta de Expansión (Decoder):** Recupera la resolución espacial mediante convoluciones transpuestas ("up-convolution").
3. Conexiones de Salto (Skip Connections): Esta es la característica crítica para la arquitectura. Concatenan los mapas de características de alta resolución del encoder directamente con las capas del decoder.

$$x_{decoder}^l = [U_p(x_{decoder}^{l-1}; x_{encoder}^l)]$$

Justificación Oceanográfica

La dinámica de la surgencia costera se caracteriza por la coexistencia de procesos de gran escala (forzamiento atmosférico sinóptico) y procesos de fina escala (filamentos, remolinos de mesoescala y frentes térmicos costeros).

- El **bottleneck** (parte baja de la U) captura el forzamiento de gran escala.
- Las **skip connections** permiten que la información de alta frecuencia espacial (gradientes costeros intensos en los primeros km de la costa) fluya directamente a la salida sin perderse en la compresión. Esto explica por qué la U-Net supera a modelos como ConvLSTM en la preservación de frentes térmicos nítidos, cruciales para la definición del índice de surgencia.

Configuracion experimental e hiperparametros de modelos de Deep

Learning

Hiperparametro	Valor/Configuracion	Justificacion
Optimizador	Adam (Adaptive Moment Estimation)	Convergencia eficiente en espacios de parámetros con gradientes ruidosos típicos de datos estocásticos.
Funcion de perdida	Mean Squared Error (MSE)	Penaliza los errores grandes (outliers), forzando al modelo a ajustar los eventos extremos de TSM
Metrica de evaluacion	Root Mean squared error (RMSE)	RMSE proporciona una medida directa de la desviacion estandar del error de prediccion
Epocas (Epochs)	60	Suficiente para la convergencia sin entrar en la fase de memorizacion del ruido
Lote (Batch size)	32	Balance entre estabilidad del gradiente y uso de memoria VRAM de la GPU
Early Stopping	Patience = 5 epocas	Previene el sobreajuste (overfitting) deteniendo el entrenamiento si la perdida en la validacion no mejora
Buffer de mezcla	1024	Asegura una aleatorizacion adecuada de los datos de entrenamiento temporalmente correlacionados
Ventana de contexto	7 dias (Lag)	Determinado experimentalmente como el horizonte optimo de memoria para la escala sinoptica de la surgencia (2-6 dias)
Horizonte de pronositco	7 dias (Lead time)	Coincide con la escala temporal de la variabilidad del viento sinoptico en los EBUS

Modelos Fundacionales para series Temporales: Transformers (Chronos)

Para el pronóstico puntual (series de tiempo 1D) en el Capítulo 3, se utiliza **Chronos**, basado en la arquitectura Transformer . Esto representa un cambio de paradigma respecto a las redes recurrentes (RNN/LSTM).

Mecanismo de Auto-Atención (Self-Attention)

A diferencia de las RNN que procesan datos secuencialmente (sufriendo de desvanecimiento de gradiente en series largas), los Transformers procesan la secuencia completa en paralelo utilizando el mecanismo de atención.

La función de atención mapea una consulta (Q), claves (K) y valores (V) de la siguiente manera:

$$Attention(Q, K, V) = softmax\left(\frac{QK^T}{\sqrt{d_k}}\right) V$$

Donde los pesos de atención determinan qué parte de la serie histórica es relevante para el paso de tiempo actual, independientemente de su distancia temporal.

Justificación oceanografica

Chronos trata la serie temporal de TSM no como valores numéricos continuos, sino que los cuantiza y tokeniza, tratándolos como un problema de modelado de lenguaje.

$$P(x_{t+1}|x_{1:t}) \approx P_{LLM}(token_{t+1}|token_{1:t})$$

Esto permite al modelo aprender distribuciones de probabilidad complejas y multimodales, capturando dinámicas abruptas (como el inicio repentino de un evento de surgencia) que los modelos ARIMA o LSTMs suavizarían.

REFERENCIAS

- Abrahams, A., Schlegel, R. W., & Smit, A. J. (2021a). A novel approach to quantify metrics of upwelling intensity, frequency, and duration. *PLoS One*, 16(7), e0254026.
- Abrahams, A., Schlegel, R. W., & Smit, A. J. (2021b). Variation and change of upwelling dynamics detected in the world's eastern boundary upwelling systems. *Frontiers in Marine Science*, 8, 626411.
- Acreman, D. M., & Jeffery, C. D. (2007). The use of Argo for validation and tuning of mixed layer models. *Ocean Modelling*, 19(1-2), 53-69.
- Aguirre, C., Pizarro, Ó., Strub, P. T., Garreaud, R., & Barth, J. A. (2012). Seasonal dynamics of the near-surface alongshore flow off central Chile. *Journal of Geophysical Research: Oceans*, 117(C1).
- Aguirre, C., Rojas, M., Garreaud, R. D., & Rahn, D. A. (2019). Role of synoptic activity on projected changes in upwelling-favourable winds at the ocean's eastern boundaries. *NPJ Climate and Atmospheric Science*, 2(1), 44.
- Ansari, A. F., Stella, L., Turkmen, C., Zhang, X., Mercado, P., Shen, H., Shchur, O., Rangapuram, S. S., Arango, S. P., & Kapoor, S. (2024). Chronos: Learning the language of time series. *arXiv preprint arXiv:2403.07815*.
- Aravena, G., Broitman, B., & Stenseth, N. C. (2014). Twelve years of change in coastal upwelling along the central-northern coast of Chile: Spatially heterogeneous responses to climatic variability. *PLoS One*, 9(2), e90276.
- Arístegui, J., Barton, E. D., Álvarez-Salgado, X. A., Santos, A. M. P., Figueiras, F. G., Kifani, S., Hernández-León, S., Mason, E., Machú, E., & Demarcq, H. (2009). Sub-regional ecosystem variability in the Canary Current upwelling. *Eastern Boundary Upwelling Ecosystems: Integrative and Comparative Approaches*, 83(1), 33-48.
<https://doi.org/10.1016/j.pocean.2009.07.031>

- Arnault, S., Thiria, S., Crépon, M., & Kaly, F. (2021). A tropical Atlantic dynamics analysis by combining machine learning and satellite data. *25 Years of Progress in Radar Altimetry*, 68(2), 467-486. <https://doi.org/10.1016/j.asr.2020.09.044>
- Badran, F., Yacoub, M., & Thiria, S. (2005). Self-Organizing Maps and Unsupervised Classification. En G. Dreyfus (Ed.), *Neural Networks: Methodology and Applications* (pp. 379-442). Springer Berlin Heidelberg. https://doi.org/10.1007/3-540-28847-3_7
- Bakun, A. (1973). *Coastal upwelling indices, west coast of North America, 1946-71*.
- Bakun, A. (1990). Global climate change and intensification of coastal ocean upwelling. *Science*, 247(4939), 198-201.
- Bakun, A. (2017). Climate change and ocean deoxygenation within intensified surface-driven upwelling circulations. *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 375(2102), 20160327.
- Bakun, A., Black, B. A., Bograd, S. J., Garcia-Reyes, M., Miller, A. J., Rykaczewski, R. R., & Sydeman, W. J. (2015). Anticipated effects of climate change on coastal upwelling ecosystems. *Current Climate Change Reports*, 1(2), 85-93.
- Bakun, A., & Weeks, S. J. (2008). The marine ecosystem off Peru: What are the secrets of its fishery productivity and what might its future hold? *Progress in Oceanography*, 79(2-4), 290-299.
- Banks, C. J., Gommenginger, C. P., Srokosz, M. A., & Snaith, H. M. (2011). Validating SMOS ocean surface salinity in the Atlantic with Argo and operational ocean model data. *IEEE Transactions on Geoscience and Remote Sensing*, 50(5), 1688-1702.
- Barton, E. D., Aristegui, J., Tett, P., Cantón, M., Garcia-Braun, J., Hernández-León, S., Nykjaer, L., Almeida, C., Almunia, J., & Ballesteros, S. (1998). The transition zone of the Canary Current upwelling region. *Progress in Oceanography*, 41(4), 455-504.
- Bednaršek, N., Feely, R. A., Beck, M. W., Glippa, O., Kanerva, M., & Engström-Öst, J. (2018). El Niño-related thermal stress coupled with upwelling-related ocean acidification

- negatively impacts cellular to population-level responses in pteropods along the California current system with implications for increased bioenergetic costs. *Frontiers in Marine Science*, 5, 486.
- Belmadani, A., Echevin, V., Codron, F., Takahashi, K., & Junquas, C. (2014). What dynamics drive future wind scenarios for coastal upwelling off Peru and Chile? *Climate dynamics*, 43(7), 1893-1914.
- Benazzouz, A., Mordane, S., Orbi, A., Chagdali, M., Hilmi, K., Atillah, A., Pelegrí, J. L., & Hervé, D. (2014). An improved coastal upwelling index from sea surface temperature using satellite-based approach—The case of the Canary Current upwelling system. *Continental Shelf Research*, 34, 38-54.
- Bentamy, A., Ayina, H.-L., Queffelec, P., Croize-Fillon, D., & Kerbaol, V. (2007). Improved near real time surface wind resolution over the Mediterranean Sea. *Ocean Science*, 3(2), 259-271.
- Bindoff, N. L., Cheung, W. W., Kairo, J. G., Arístegui, J., Guinder, V. A., Hallberg, R., Hilmi, N., Jiao, N., Levin, L., & O'Donoghue, S. (2022). *Changing ocean, marine ecosystems, and dependent communities*.
- Blender, R., & Schubert-Frisius, M. (2000). Cyclone Tracking in Different Spatial and Temporal Resolutions. *Monthly Weather Review - MON WEATHER REV*, 128. [https://doi.org/10.1175/1520-0493\(2000\)128%253C0377:CTIDSA%253E2.0.CO;2](https://doi.org/10.1175/1520-0493(2000)128%253C0377:CTIDSA%253E2.0.CO;2)
- Bograd, S. J., Jacox, M. G., Hazen, E. L., Lovecchio, E., Montes, I., Pozo Buil, M., Shannon, L. J., Sydeman, W. J., & Rykaczewski, R. R. (2023). Climate change impacts on eastern boundary upwelling systems. *Annual Review of Marine Science*, 15(1), 303-328.
- Bograd, S. J., Schroeder, I. D., & Jacox, M. G. (2019). A water mass history of the Southern California current system. *Geophysical Research Letters*, 46(12), 6690-6698.

- Bonino, G., Di Lorenzo, E., Masina, S., & Iovino, D. (2019). Interannual to decadal variability within and across the major Eastern Boundary Upwelling Systems. *Scientific Reports*, 9(1), 19949.
- Brady, R. X., Alexander, M. A., Lovenduski, N. S., & Rykaczewski, R. R. (2017). Emergent anthropogenic trends in California Current upwelling. *Geophysical Research Letters*, 44(10), 5044-5052.
- Bustos, D. F., Narváez, D. A., Dewitte, B., Oerder, V., Vidal, M., & Tapia, F. (2024). Revisiting historical trends in the Eastern Boundary Upwelling Systems with a machine learning method. *Frontiers in Marine Science*, 11, 1446766.
- Bustos Usta, D. F., Rodríguez-López, L., Torres Parra, R. R., & Bourrel, L. (2025). Sea Surface Temperature Forecasting Using Foundational Models: A Novel Approach Assessed in the Caribbean Sea. *Remote Sensing*, 17(3), 517.
- Capet, X. J., Marchesiello, P., & McWilliams, J. C. (2004). Upwelling response to coastal wind profiles. *Geophysical Research Letters*, 31(13).
- Capotondi, A., Alexander, M. A., Bond, N. A., Curchitser, E. N., & Scott, J. D. (2012). Enhanced upper ocean stratification with climate change in the CMIP3 models. *Journal of Geophysical Research: Oceans*, 117(C4).
- Cervantes-Duarte, R., Prego, R., López-López, S., Aguirre-Bahena, F., & Ospina-Alvarez, N. (2013). Annual patterns of nutrients and chlorophyll in a subtropical coastal lagoon under the upwelling influence (SW of Baja-California Peninsula). *Estuarine, Coastal and Shelf Science*, 120, 54-63.
- Chaigneau, A., Eldin, G., & Dewitte, B. (2009). Eddy activity in the four major upwelling systems from satellite altimetry (1992–2007). *Progress in Oceanography*, 83(1-4), 117-123.

- Chamorro, A., Echevin, V., Dutheil, C., Tam, J., Gutiérrez, D., & Colas, F. (2021). Projection of upwelling-favorable winds in the Peruvian upwelling system under the RCP8. 5 scenario using a high-resolution regional model. *Climate Dynamics*, 57(1), 1-16.
- Chase, Z., Johnson, K. S., Elrod, V. A., Plant, J. N., Fitzwater, S. E., Pickell, L., & Sakamoto, C. M. (2005). Manganese and iron distributions off central California influenced by upwelling and shelf width. *Marine Chemistry*, 95(3), 235-254.
<https://doi.org/10.1016/j.marchem.2004.09.006>
- Chavez, F. P., & Messié, M. (2009). A comparison of eastern boundary upwelling ecosystems. *Progress in Oceanography*, 83(1-4), 80-96.
- Chen, W., Jiang, Z., & Li, L. (2011). Probabilistic projections of climate change over China under the SRES A1B scenario using 28 AOGCMs. *Journal of Climate*, 24(17), 4741-4756.
- Chen, Z., Yan, X.-H., Jo, Y.-H., Jiang, L., & Jiang, Y. (2012). A study of Benguela upwelling system using different upwelling indices derived from remotely sensed data. *Continental shelf research*, 45, 27-33.
- Chen, Zhou, T., Zhang, L., Chen, X., Zhang, W., & Jiang, J. (2020). Global land monsoon precipitation changes in CMIP6 projections. *Geophysical Research Letters*, 47(14), e2019GL086902.
- Cheng, L., Zhu, J., Abraham, J., Trenberth, K. E., Fasullo, J. T., Zhang, B., Yu, F., Wan, L., Chen, X., & Song, X. (2019). *2018 continues record global ocean warming*. Springer.
- Cherchi, A., Fogli, P. G., Lovato, T., Peano, D., Iovino, D., Gualdi, S., Masina, S., Scoccimarro, E., Materia, S., & Bellucci, A. (2019). Global mean climate and main patterns of variability in the CMCC-CM2 coupled model. *Journal of Advances in Modeling Earth Systems*, 11(1), 185-209.

- Choi, H.-M., Kim, M.-K., & Yang, H. (2023). Deep-learning model for sea surface temperature prediction near the Korean Peninsula. *Deep Sea Research Part II: Topical Studies in Oceanography*, 208, 105262.
- Choi, J., Lu, J., Son, S.-W., Frierson, D. M. W., & Yoon, J.-H. (2016). Uncertainty in future projections of the North Pacific subtropical high and its implication for California winter precipitation change. *Journal of Geophysical Research: Atmospheres*, 121(2), 795-806. <https://doi.org/10.1002/2015JD023858>
- Choi, J., Son, S.-W., Lu, J., & Min, S.-K. (2014). Further observational evidence of Hadley cell widening in the Southern Hemisphere. *Geophysical Research Letters*, 41(7), 2590-2597.
- Conejero, C., Dewitte, B., Garçon, V., Sudre, J., & Montes, I. (2020). ENSO diversity driving low-frequency change in mesoscale activity off Peru and Chile. *Scientific Reports*, 10(1), 17902.
- Cook, K. H. (2003). Role of continents in driving the Hadley cells. *Journal of the atmospheric sciences*, 60(7), 957-976.
- Cordeiro Pires, A., Nolasco, R., Rocha, A., Ramos, A. M., & Dubert, J. (2016). Climate change in the Iberian Upwelling System: A numerical study using GCM downscaling. *Climate Dynamics*, 47(1), 451-464.
- de Boyer Montégut, C., Madec, G., Fischer, A. S., Lazar, A., & Iudicone, D. (2004). Mixed layer depth over the global ocean: An examination of profile data and a profile-based climatology. *Journal of Geophysical Research: Oceans*, 109(C12).
- de Souza, J. M. A. C., Couto, P., Soutelino, R., & Roughan, M. (2021). Evaluation of four global ocean reanalysis products for New Zealand waters—A guide for regional ocean modelling. *New Zealand Journal of Marine and Freshwater Research*, 55(1), 132-155.
- deCastro, M., Gómez-Gesteira, M., Lorenzo, M. N., Alvarez, I., & Crespo, A. J. C. (2008). Influence of atmospheric modes on coastal upwelling along the western coast of the Iberian Peninsula, 1985 to 2005. *Climate Research*, 36(2), 169-179.

- Desbiolles, F., Bentamy, A., Blanke, B., Roy, C., Mestas-Nuñez, A. M., Grodsky, S. A., Herbette, S., Cambon, G., & Maes, C. (2017). Two decades [1992–2012] of surface wind analyses based on satellite scatterometer observations. *Journal of Marine Systems*, 168, 38-56.
- Deschamps, P. Y., & Frouin, R. (1984). Large diurnal heating of the sea surface observed by the HCMR experiment. *Journal of Physical Oceanography*, 14(1), 177-184.
- Diffenbaugh, N. S., Snyder, M. A., & Sloan, L. C. (2004). Could CO₂-induced land-cover feedbacks alter near-shore upwelling regimes? *Proceedings of the National Academy of Sciences*, 101(1), 27-32.
- Doan, Q.-V., Kusaka, H., Sato, T., & Chen, F. (2021). S-SOM v1.0: A structural self-organizing map algorithm for weather typing. *Geosci. Model Dev.*, 14(4), 2097-2111.
<https://doi.org/10.5194/gmd-14-2097-2021>
- Dommenget, D., & Latif, M. (2002). A cautionary note on the interpretation of EOFs. *Journal of climate*, 15(2), 216-225.
- Doney, S. C., Lima, I., Moore, J. K., Lindsay, K., Behrenfeld, M. J., Westberry, T. K., Mahowald, N., Glover, D. M., & Takahashi, T. (2009). Skill metrics for confronting global upper ocean ecosystem-biogeochemistry models against field and remote sensing data. *Journal of Marine Systems*, 76(1-2), 95-112.
- Doney, S. C., Lindsay, K., & Moore, J. K. (2003). Global ocean carbon cycle modeling. En *Ocean biogeochemistry: The role of the ocean carbon cycle in global change* (pp. 217-238). Springer.
- Donlon, C. J., Martin, M., Stark, J., Roberts-Jones, J., Fiedler, E., & Wimmer, W. (2012). The operational sea surface temperature and sea ice analysis (OSTIA) system. *Remote sensing of Environment*, 116, 140-158.

- Dorschel, B., Hehemann, L., Viquerat, S., Warnke, F., Dreutter, S., Tenberge, Y. S., Accettella, D., An, L., Barrios, F., & Bazhenova, E. (2022). The international bathymetric chart of the southern ocean version 2. *Scientific Data*, 9(1), 275.
- Dubin, R. A. (1992). Spatial autocorrelation and neighborhood quality. *Regional science and urban economics*, 22(3), 433-452.
- Echevin, V., Gévaudan, M., Espinoza-Morriberón, D., Tam, J., Aumont, O., Gutierrez, D., & Colas, F. (2020). Physical and biogeochemical impacts of RCP8. 5 scenario in the Peru upwelling system. *Biogeosciences*, 17(12), 3317-3341.
- Ekman, V. W. (1905). *On the influence of the earth's rotation on ocean-currents*.
- El Aouni, A., Daoudi, K., Minaoui, K., & Yahia, H. (2020). Robust detection of the North-West African upwelling from SST images. *IEEE Geoscience and Remote Sensing Letters*, 18(4), 573-576.
- Escofier, B., & Pagès, J. (1994). Multiple factor analysis (AFMULT package). *Computational Statistics & Data Analysis*, 18(1), 121-140. [https://doi.org/10.1016/0167-9473\(94\)90135-X](https://doi.org/10.1016/0167-9473(94)90135-X)
- Espinoza-Carreón, T. L., Strub, P. T., Beier, E., Ocampo-Torres, F., & Gaxiola-Castro, G. (2004). Seasonal and interannual variability of satellite-derived chlorophyll pigment, surface height, and temperature off Baja California. *Journal of Geophysical Research: Oceans*, 109(C3).
- Espinoza-Morriberón, D., Echevin, V., Colas, F., Tam, J., Ledesma, J., Vásquez, L., & Graco, M. (2017). Impacts of El Niño events on the Peruvian upwelling system productivity. *Journal of Geophysical Research: Oceans*, 122(7), 5423-5444.
- Eyring, V., Bony, S., Meehl, G. A., Senior, C. A., Stevens, B., Stouffer, R. J., & Taylor, K. E. (2016). Overview of the Coupled Model Intercomparison Project Phase 6 (CMIP6) experimental design and organization. *Geoscientific Model Development*, 9(5), 1937-1958.

- Farrell, P. E., Piggott, M. D., Pain, C. C., Gorman, G. J., & Wilson, C. R. (2009). Conservative interpolation between unstructured meshes via supermesh construction. *Computer methods in applied mechanics and engineering*, 198(33-36), 2632-2642.
- Fei, T., Huang, B., Wang, X., Zhu, J., Chen, Y., Wang, H., & Zhang, W. (2022). A hybrid deep learning model for the bias correction of sst numerical forecast products using satellite data. *Remote Sensing*, 14(6), 1339.
- Fielding, P. D. (1989). Carbon and nitrogen resources available to kelp bed filter feeders in an upwelling environment. *Marine Ecology Progress Series*, 55, 181-189.
- Frierson, D. M., Lu, J., & Chen, G. (2007). Width of the Hadley cell in simple and comprehensive general circulation models. *Geophysical Research Letters*, 34(18).
- Fu, Y., Song, J., Guo, J., Fu, Y., & Cai, Y. (2024). Prediction and analysis of sea surface temperature based on LSTM-transformer model. *Regional Studies in Marine Science*, 78, 103726.
- García-Reyes, M., Sydeman, W. J., Black, B. A., Rykaczewski, R. R., Schoeman, D. S., Thompson, S. A., & Bograd, S. J. (2013). Relative influence of oceanic and terrestrial pressure systems in driving upwelling-favorable winds. *Geophysical Research Letters*, 40(19), 5311-5315.
- García-Reyes, M., Sydeman, W. J., Schoeman, D. S., Rykaczewski, R. R., Black, B. A., Smit, A. J., & Bograd, S. J. (2015). Under pressure: Climate change, upwelling, and eastern boundary upwelling ecosystems. *Frontiers in Marine Science*, 2, 109.
- Garçon, V., Dewitte, B., Montes, I., & Goubanova, K. (2019). Land-sea-atmosphere interactions exacerbating ocean deoxygenation in Eastern Boundary Upwelling Systems (EBUS). *Ocean Deoxygenation: Everyone's Problem*, 155-170.
- Gelaro, R., McCarty, W., Suárez, M. J., Todling, R., Molod, A., Takacs, L., Randles, C. A., Darmenov, A., Bosilovich, M. G., & Reichle, R. (2017). The modern-era retrospective

- analysis for research and applications, version 2 (MERRA-2). *Journal of climate*, 30(14), 5419-5454.
- Gibson, P. B., Perkins-Kirkpatrick, S. E., Uotila, P., Pepler, A. S., & Alexander, L. V. (2017). On the use of self-organizing maps for studying climate extremes. *Journal of Geophysical Research: Atmospheres*, 122(7), 3891-3903. <https://doi.org/10.1002/2016JD026256>
- Gidden, M. J., Riahi, K., Smith, S. J., Fujimori, S., Luderer, G., Kriegler, E., Van Vuuren, D. P., Van Den Berg, M., Feng, L., & Klein, D. (2019). Global emissions pathways under different socioeconomic scenarios for use in CMIP6: A dataset of harmonized emissions trajectories through the end of the century. *Geoscientific model development*, 12(4), 1443-1475.
- Gilliland, J. M., & Keim, B. D. (2018). Position of the South Atlantic Anticyclone and Its Impact on Surface Conditions across Brazil. *Journal of Applied Meteorology and Climatology*, 57(3), 535-553. <https://doi.org/10.1175/JAMC-D-17-0178.1>
- Goddard, L., Kumar, A., Solomon, A., Smith, D., Boer, G., Gonzalez, P., Kharin, V., Merryfield, W., Deser, C., & Mason, S. J. (2013). A verification framework for interannual-to-decadal predictions experiments. *Climate Dynamics*, 40(1), 245-272.
- González-Nuevo, G., Gago, J., & Cabanas, J. M. (2014). Upwelling index: A powerful tool for marine research in the NW Iberian upwelling system. *Journal of Operational Oceanography*, 7(1), 47-57.
- Good, S., Fiedler, E., Mao, C., Martin, M. J., Maycock, A., Reid, R., Roberts-Jones, J., Searle, T., Waters, J., & While, J. (2020). The current configuration of the OSTIA system for operational production of foundation sea surface temperature and ice concentration analyses. *Remote Sensing*, 12(4), 720.
- Goubanova, K., Echevin, V., Dewitte, B., Codron, F., Takahashi, K., Terray, P., & Vrac, M. (2011). Statistical downscaling of sea-surface wind over the Peru–Chile upwelling

- region: Diagnosing the impact of climate change from the IPSL-CM4 model. *Climate Dynamics*, 36(7), 1365-1378.
- Grise, K. M., & Davis, S. M. (2020). Hadley cell expansion in CMIP6 models. *Atmospheric Chemistry and Physics*, 20(9), 5249-5268.
- Groom, S., Sathyendranath, S., Ban, Y., Bernard, S., Brewin, R., Brotas, V., Brockmann, C., Chauhan, P., Choi, J., & Chuprin, A. (2019). Satellite ocean colour: Current status and future perspective. *Frontiers in Marine Science*, 6, 485.
- Guo, H. (2017). Big Earth data: A new frontier in Earth and information sciences. *Big Earth Data*, 1(1-2), 4-20.
- Haarsma, R. J., Roberts, M. J., Vidale, P. L., Senior, C. A., Bellucci, A., Bao, Q., Chang, P., Corti, S., Fučkar, N. S., & Guemas, V. (2016a). High resolution model intercomparison project (HighResMIP v1. 0) for CMIP6. *Geoscientific Model Development*, 9(11), 4185-4208.
- Haarsma, R. J., Roberts, M. J., Vidale, P. L., Senior, C. A., Bellucci, A., Bao, Q., Chang, P., Corti, S., Fučkar, N. S., & Guemas, V. (2016b). High resolution model intercomparison project (HighResMIP v1. 0) for CMIP6. *Geoscientific Model Development*, 9(11), 4185-4208.
- Haines, S. L., Jedlovec, G. J., & Lazarus, S. M. (2007). A MODIS sea surface temperature composite for regional applications. *IEEE Transactions on geoscience and remote sensing*, 45(9), 2919-2927.
- Häkkinen, S. (1987). Upwelling at the ice edge: A mechanism for deep water formation? *Journal of Geophysical Research: Oceans*, 92(C5), 5031-5034.
- Halpern, D., Knox, R. A., Luther, D. S., & Philander, S. G. H. (1989). Estimates of equatorial upwelling between 140 and 110 W during 1984. *Journal of Geophysical Research: Oceans*, 94(C6), 8018-8020.

- Hannachi, A. (2006). In search of simple structures in climate: Simplifying EOFs. *International journal of climatology*.
- Hasanean, H. M. (2004). Variability of the North Atlantic subtropical high and associations with tropical sea-surface temperature. *International Journal of Climatology*, 24(8), 945-957.
<https://doi.org/10.1002/joc.1042>
- Hauer, M. E., Fussell, E., Mueller, V., Burkett, M., Call, M., Abel, K., McLeman, R., & Wrathall, D. (2020). Sea-level rise and human migration. *Nature Reviews Earth & Environment*, 1(1), 28-39.
- He, C., Wu, B., Zou, L., & Zhou, T. (2017). Responses of the summertime subtropical anticyclones to global warming. *Journal of Climate*, 30(16), 6465-6479.
- He, J., & Mahadevan, A. (2021). How the source depth of coastal upwelling relates to stratification and wind. *Journal of Geophysical Research: Oceans*, 126(12), e2021JC017621.
- Hobday, A. J., Alexander, L. V., Perkins, S. E., Smale, D. A., Straub, S. C., Oliver, E. C., Benthuisen, J. A., Burrows, M. T., Donat, M. G., & Feng, M. (2016). A hierarchical approach to defining marine heatwaves. *Progress in oceanography*, 141, 227-238.
- Hobday, A. J., Oliver, E. C., Gupta, A. S., Benthuisen, J. A., Burrows, M. T., Donat, M. G., Holbrook, N. J., Moore, P. J., Thomsen, M. S., & Wernberg, T. (2018). Categorizing and naming marine heatwaves. *Oceanography*, 31(2), 162-173.
- Holte, J., & Talley, L. (2009). A new algorithm for finding mixed layer depths with applications to Argo data and Subantarctic Mode Water formation. *Journal of Atmospheric and Oceanic Technology*, 26(9), 1920-1939.
- Howard, E. M., Frenzel, H., Kessouri, F., Renault, L., Bianchi, D., McWilliams, J. C., & Deutsch, C. (2020). Attributing causes of future climate change in the California current system with multimodel downscaling. *Global Biogeochemical Cycles*, 34(11), e2020GB006646.

- Hu, Y., Tao, L., & Liu, J. (2013). Poleward expansion of the Hadley circulation in CMIP5 simulations. *Advances in Atmospheric Sciences*, 30(3), 790-795.
- Huang, B., Liu, C., Banzon, V., Freeman, E., Graham, G., Hankins, B., Smith, T., & Zhang, H.-M. (2021). Improvements of the daily optimum interpolation sea surface temperature (DOISST) version 2.1. *Journal of Climate*, 34(8), 2923-2939.
- Huang, B., Thorne, P. W., Banzon, V. F., Boyer, T., Chepurin, G., Lawrimore, J. H., Menne, M. J., Smith, T. M., Vose, R. S., & Zhang, H.-M. (2017). Extended reconstructed sea surface temperature, version 5 (ERSSTv5): Upgrades, validations, and intercomparisons. *Journal of Climate*, 30(20), 8179-8205.
- Jacox, M. G., Bograd, S. J., Hazen, E. L., & Fiechter, J. (2015). Sensitivity of the California Current nutrient supply to wind, heat, and remote ocean forcing. *Geophysical Research Letters*, 42(14), 5950-5957.
- Jacox, M. G., & Edwards, C. A. (2011). Effects of stratification and shelf slope on nutrient supply in coastal upwelling regions. *Journal of Geophysical Research: Oceans*, 116(C3).
- Jacox, M. G., Edwards, C. A., Hazen, E. L., & Bograd, S. J. (2018). Coastal upwelling revisited: Ekman, Bakun, and improved upwelling indices for the US West Coast. *Journal of Geophysical Research: Oceans*, 123(10), 7332-7350.
- Jayne, S. R., Roemmich, D., Zilberman, N., Riser, S. C., Johnson, K. S., Johnson, G. C., & Piotrowicz, S. R. (2017). The Argo program: Present and future. *Oceanography*, 30(2), 18-28.
- Jean-Michel, L., Eric, G., Romain, B.-B., Gilles, G., Angélique, M., Marie, D., Clément, B., Mathieu, H., Olivier, L. G., & Charly, R. (2021). The Copernicus global 1/12 oceanic and sea ice GLORYS12 reanalysis. *Frontiers in Earth Science*, 9, 698876.
- Jebri, F., Srokosz, M., Jacobs, Z. L., Nencioli, F., & Popova, E. (2022). Earth Observation and Machine Learning Reveal the Dynamics of Productive Upwelling Regimes on the

- Agulhas Bank. *Frontiers in Marine Science*, Volume 9-2022.
<https://www.frontiersin.org/journals/marine-science/articles/10.3389/fmars.2022.872515>
- Johnson, G. C., McPhaden, M. J., & Firing, E. (2001). Equatorial Pacific Ocean horizontal velocity, divergence, and upwelling. *Journal of Physical Oceanography*, 31(3), 839-849.
- Jouini, M., Béranger, K., Arsouze, T., Beuvier, J., Thiria, S., Crépon, M., & Taupier-Letage, I. (2016). The Sicily Channel surface circulation revisited using a neural clustering analysis of a high-resolution simulation. *Journal of Geophysical Research: Oceans*, 121(7), 4545-4567. <https://doi.org/10.1002/2015JC011472>
- Kämpf, J., & Chapman, P. (2016a). *Upwelling systems of the world*. Springer.
<https://doi.org/10.1007/978-3-319-42524-5>
- Kämpf, J., & Chapman, P. (2016b). *Upwelling systems of the world*. Springer.
- Kent, E. C., Fangohr, S., & Berry, D. I. (2012). A comparative assessment of monthly mean wind speed products over the global ocean. *International Journal of Climatology*, 33(11).
- Kessouri, F., McWilliams, J. C., Bianchi, D., Sutula, M., Renault, L., Deutsch, C., Feely, R. A., McLaughlin, K., Ho, M., & Howard, E. M. (2021). Coastal eutrophication drives acidification, oxygen loss, and ecosystem change in a major oceanic upwelling system. *Proceedings of the National Academy of Sciences*, 118(21), e2018856118.
- Khangar, N., & Kamalja, K. (2017). Multiple Correspondence Analysis and its applications. *Electronic Journal of Applied Statistical Analysis*, 10, 432-462.
<https://doi.org/10.1285/i20705948v10n2p432>
- Kilpatrick, K. A., Podestá, G., Walsh, S., Williams, E., Halliwell, V., Szczodrak, M., Brown, O. B., Minnett, P. J., & Evans, R. (2015). A decade of sea surface temperature from MODIS. *Remote Sensing of Environment*, 165, 27-41.
- Kim, K.-H., Shim, P.-S., & Shin, S. (2019). An alternative bilinear interpolation method between spherical grids. *Atmosphere*, 10(3), 123.

- Kim, T. H., Sajjadi, M. S., Hirsch, M., & Scholkopf, B. (2018). Spatio-temporal transformer network for video restoration. *Proceedings of the European conference on computer vision (ECCV)*, 106-122.
- Kohonen, T. (1982). A simple paradigm for the self-organized formation of structured feature maps. *Competition and Cooperation in Neural Nets: Proceedings of the US-Japan Joint Seminar held at Kyoto, Japan February 15–19, 1982*, 248-266.
- Krause, P., Boyle, D. P., & Bäse, F. (2005). Comparison of different efficiency criteria for hydrological model assessment. *Advances in geosciences*, 5, 89-97.
- Lachkar, Z. (2014). Effects of upwelling increase on ocean acidification in the California and Canary Current systems. *Geophysical Research Letters*, 41(1), 90-95.
- Lambeck, K. (2005). *The Earth's variable rotation: Geophysical causes and consequences*. Cambridge University Press.
- Large, W. G., & Danabasoglu, G. (2006). Attribution and impacts of upper-ocean biases in CCSM3. *Journal of Climate*, 19(11), 2325-2346.
- Larraondo, P. R., Renzullo, L. J., Inza, I., & Lozano, J. A. (2019). A data-driven approach to precipitation parameterizations using convolutional encoder-decoder neural networks. *arXiv preprint arXiv:1903.10274*.
- Lee, E.-Y., & Park, K.-A. (2020). Validation of satellite sea surface temperatures and long-term trends in Korean coastal regions over past decades (1982–2018). *Remote Sensing*, 12(22), 3742.
- Lentz, S. J., & Chapman, D. C. (2004). The importance of nonlinear cross-shelf momentum flux during wind-driven coastal upwelling. *Journal of Physical Oceanography*, 34(11), 2444-2457.
- Letelier, J., Pizarro, O., & Nuñez, S. (2009). Seasonal variability of coastal upwelling and the upwelling front off central Chile. *Journal of Geophysical Research: Oceans*, 114(C12).

- Li, H., Kanamitsu, M., Hong, S.-Y., Yoshimura, K., Cayan, D. R., Misra, V., & Sun, L. (2014). Projected climate change scenario over California by a regional ocean–atmosphere coupled model system. *Climatic Change*, 122(4), 609-619.
- Liang-Liang, L., Jian, L., & Ru-Cong, Y. (2022). Evaluation of CMIP6 HighResMIP models in simulating precipitation over Central Asia. *Advances in Climate Change Research*, 13(1), 1-13.
- Liu, H., Song, Z., Wang, X., & Misra, V. (2022). An ocean perspective on CMIP6 climate model evaluations. *Deep Sea Research Part II: Topical Studies in Oceanography*, 201, 105120. <https://doi.org/10.1016/j.dsr2.2022.105120>
- Liu, M., Zeng, A., Xu, Z., Lai, Q., & Xu, Q. (2021). Time series is a special sequence: Forecasting with sample convolution and interaction. *arXiv preprint arXiv:2106.09305*, 1(9).
- Liu, Y., Weisberg, R. H., & He, R. (2006). Sea surface temperature patterns on the West Florida Shelf using growing hierarchical self-organizing maps. *Journal of Atmospheric and Oceanic Technology*, 23(2), 325-338.
- Lluch-Cota, S.-E. (2000). Coastal upwelling in the eastern Gulf of California. *Oceanologica Acta*, 23(6), 731-740.
- Lopes, J. F., Ferreira, J. A., Cardoso, A. C., & Rocha, A. C. (2014). Variability of temperature and chlorophyll of the Iberian Peninsula near costal ecosystem during an upwelling event for the present climate and a future climate scenario. *Journal of Marine Systems*, 129, 271-288.
- Lu, J., Vecchi, G. A., & Reichler, T. (2007). Expansion of the Hadley cell under global warming. *Geophysical Research Letters*, 34(6).
- Ma, J., & Xie, S.-P. (2013). Regional patterns of sea surface temperature change: A source of uncertainty in future projections of precipitation and atmospheric circulation. *Journal of climate*, 26(8), 2482-2501.

- Mackas, D. L., Strub, P. T., Thomas, A., Montecino, V., Robinson, A. R., & Brink, K. H. (2006). Eastern ocean boundaries pan-regional overview. *The sea*, 14, 21-59.
- Marcello, J., Hernandez-Guerra, A., Eugenio, F., & Fonte, A. (2011). Seasonal and temporal study of the northwest African upwelling system. *International Journal of Remote Sensing*, 32(7), 1843-1859.
- Marchesiello, P., & Estrade, P. (2010). *Upwelling limitation by onshore geostrophic flow*.
- Marullo, S., Buongiorno Nardelli, B., Guarracino, M., & Santoleri, R. (2007). Observing the Mediterranean Sea from space: 21 years of Pathfinder-AVHRR sea surface temperatures (1985 to 2005): Re-analysis and validation. *Ocean Science*, 3(2), 299-310.
- Masina, S., Storto, A., Ferry, N., Valdivieso, M., Haines, K., Balmaseda, M., Zuo, H., Drevillon, M., & Parent, L. (2017). An ensemble of eddy-permitting global ocean reanalyses from the MyOcean project. *Climate Dynamics*, 49(3), 813-841.
- McCuen, R. H., Knight, Z., & Cutter, A. G. (2006). Evaluation of the Nash–Sutcliffe efficiency index. *Journal of hydrologic engineering*, 11(6), 597-602.
- Mendelsohn, R., & Schwing, F. B. (2002). Common and uncommon trends in SST and wind stress in the California and Peru–Chile current systems. *Progress in Oceanography*, 53(2-4), 141-162.
- Meneghesso, C., Seabra, R., Broitman, B. R., Wethey, D. S., Burrows, M. T., Chan, B. K. K., Guy-Haim, T., Ribeiro, P. A., Rilov, G., Santos, A. M., Sousa, L. L., & Lima, F. P. (2020). Remotely-sensed L4 SST underestimates the thermal fingerprint of coastal upwelling. *Remote Sensing of Environment*, 237, 111588.
<https://doi.org/10.1016/j.rse.2019.111588>
- Milošević, D., Medeiros, A. S., Stojković Piperac, M., Cvijanović, D., Soininen, J., Milosavljević, A., & Predić, B. (2022). The application of Uniform Manifold Approximation and Projection (UMAP) for unconstrained ordination and classification

- of biological indicators in aquatic ecology. *Science of The Total Environment*, 815, 152365. <https://doi.org/10.1016/j.scitotenv.2021.152365>
- Minnett, P. J., Alvera-Azcárate, A., Chin, T. M., Corlett, G. K., Gentemann, C. L., Karagali, I., Li, X., Marsouin, A., Marullo, S., & Maturi, E. (2019). Half a century of satellite remote sensing of sea-surface temperature. *Remote Sensing of Environment*, 233, 111366.
- Miranda, P. M. A., Alves, J. M. R., & Serra, N. (2013). Climate change and upwelling: Response of Iberian upwelling to atmospheric forcing in a regional climate scenario. *Climate dynamics*, 40(11), 2813-2824.
- Montecino, H. D., Ferreira, V. G., Cuevas, A., Cabrera, L. C., Báez, J. C. S., & De Freitas, S. R. (2017). Vertical deformation and sea level changes in the coast of Chile by satellite altimetry and tide gauges. *International Journal of Remote Sensing*, 38(24), 7551-7565.
- Montecino, V., & Lange, C. B. (2009). The Humboldt Current System: Ecosystem components and processes, fisheries, and sediment studies. *Progress in Oceanography*, 83(1-4), 65-79.
- Montecinos, A., & Gomez, F. (2010). ENSO modulation of the upwelling season off southern-central Chile. *Geophysical Research Letters*, 37(2).
- Montes, I., Schneider, W., Colas, F., Blanke, B., & Echevin, V. (2011). Subsurface connections in the eastern tropical Pacific during La Niña 1999–2001 and El Niño 2002–2003. *Journal of Geophysical Research: Oceans*, 116(C12).
- Moreno-Chamarro, E., Caron, L.-P., Loosveldt Tomas, S., Gutjahr, O., Moine, M.-P., Putrasahan, D., Roberts, C. D., Roberts, M. J., Senan, R., & Terray, L. (2021). Impact of increased resolution on long-standing biases in HighResMIP-PRIMAVERA climate models. *Geoscientific Model Development Discussions*, 2021, 1-33.
- Mukherjee, S., Mishra, A., & Trenberth, K. E. (2018). Climate change and drought: A perspective on drought indices. *Current climate change reports*, 4(2), 145-163.

- Mundy, C. J., Gosselin, M., Ehn, J., Gratton, Y., Rossnagel, A., Barber, D. G., Martin, J., Tremblay, J.-É., Palmer, M., & Arrigo, K. R. (2009). Contribution of under-ice primary production to an ice-edge upwelling phytoplankton bloom in the Canadian Beaufort Sea. *Geophysical Research Letters*, 36(17).
- Muñoz-Sabater, J., Dutra, E., Agustí-Panareda, A., Albergel, C., Arduini, G., Balsamo, G., Boussetta, S., Choulga, M., Harrigan, S., & Hersbach, H. (2021). ERA5-Land: A state-of-the-art global reanalysis dataset for land applications. *Earth system science data*, 13(9), 4349-4383.
- Murphy, R. C. (1926). Oceanic and climatic phenomena along the west coast of South America during 1925. *Geographical Review*, 16(1), 26-54.
- Murray, R. J., & Simmonds, I. (1991). A numerical scheme for tracking cyclone centres from digital data. Part I: Development and operation of the scheme. *Australian Meteorological Magazine*, 39, 155-166.
- Nam, S., Kim, H.-J., & Send, U. (2011). Amplification of hypoxic and acidic events by La Niña conditions on the continental shelf off California. *Geophysical Research Letters*, 38(22).
- Narayan, N., Paul, A., Mulitza, S., & Schulz, M. (2010). Trends in coastal upwelling intensity during the late 20th century. *Ocean Science*, 6(3), 815-823.
- Nascimento, S., Casca, S., & Mirkin, B. (2015). A seed expanding cluster algorithm for deriving upwelling areas on sea surface temperature images. *Computers & Geosciences*, 85, 74-85.
- Naulita, Y., & Arhatin, R. E. (2020). Upwelling index along the South Coast of Java from satellite imagery of wind stress and sea surface temperature. *IOP Conference Series: Earth and Environmental Science*, 429(1), 012025.
- North, G. R. (1984). Empirical Orthogonal Functions and Normal Modes. *Journal of Atmospheric Sciences*, 41(5), 879-887. [https://doi.org/10.1175/1520-0469\(1984\)041%253C0879:EOFANM%253E2.0.CO;2](https://doi.org/10.1175/1520-0469(1984)041%253C0879:EOFANM%253E2.0.CO;2)

- Oerder, V., Colas, F., Echevin, V., Codron, F., Tam, J., & Belmadani, A. (2015a). Peru-Chile upwelling dynamics under climate change. *Journal of Geophysical Research: Oceans*, 120(2), 1152-1172.
- Oerder, V., Colas, F., Echevin, V., Codron, F., Tam, J., & Belmadani, A. (2015b). Peru-Chile upwelling dynamics under climate change. *Journal of Geophysical Research: Oceans*, 120(2), 1152-1172.
- O’Gorman, P. A. (2015). Precipitation extremes under climate change. *Current climate change reports*, 1(2), 49-59.
- Oliver, E. C., Donat, M. G., Burrows, M. T., Moore, P. J., Smale, D. A., Alexander, L. V., Benthuisen, J. A., Feng, M., Sen Gupta, A., & Hobday, A. J. (2018). Longer and more frequent marine heatwaves over the past century. *Nature communications*, 9(1), 1324.
- Oyarzún, D., & Brierley, C. M. (2019). The future of coastal upwelling in the Humboldt current from model projections. *Climate dynamics*, 52(1), 599-615.
- P Santos, A. M., Kazmin, A. S., & Peliz, A. (2005). *Decadal changes in the Canary upwelling system as revealed by satellite observations: Their impact on productivity*.
- Pachauri, R. K., & Reisinger, A. (2007). *Climate change 2007: Synthesis report. Contribution of working groups I, II and III to the fourth assessment report of the Intergovernmental Panel on Climate Change*. Ipcc.
- Pan, D., Gower, J. F. R., & Borstad, G. A. (1988). Seasonal variation of the surface chlorophyll distribution along the British Columbia coast as shown by CZCS satellite imagery. *Limnology and oceanography*, 33(2), 227-244.
- Parmesan, C., Morecroft, M. D., & Trisurat, Y. (2022). *Climate change 2022: Impacts, adaptation and vulnerability*. GIEC.
- Patil, K., & Deo, M. C. (2017). Prediction of daily sea surface temperature using efficient neural networks. *Ocean Dynamics*, 67(3), 357-368.

- Pauly, D., & Christensen, V. (1995). Primary production required to sustain global fisheries. *Nature*, 374(6519), 255-257.
- Pérez-Santos, I., Seguel, R., Schneider, W., Linford, P., Donoso, D., Navarro, E., Amaya-Cárcamo, C., Pinilla, E., & Daneri, G. (2019). Synoptic-scale variability of surface winds and ocean response to atmospheric forcing in the eastern austral Pacific Ocean. *Ocean Science*, 15(5), 1247-1266.
- Perruche, C. (2018). *Product User Manual for the Global Ocean Biogeochemistry Hindcast GLOBAL_REANALYSIS_BIO_001_029. Version 1.*
- Pilo, G. S., Holbrook, N. J., Kiss, A. E., & Hogg, A. M. (2019). Sensitivity of marine heatwave metrics to ocean model resolution. *Geophysical Research Letters*, 46(24), 14604-14612.
- Pitcher, G. C., Aguirre-Velarde, A., Breitburg, D., Cardich, J., Carstensen, J., Conley, D. J., Dewitte, B., Engel, A., Espinoza-Morriberón, D., & Flores, G. (2021). System controls of coastal and open ocean oxygen depletion. *Progress in Oceanography*, 197, 102613.
- PIZARRO A, O., HORMAZABAL F, S., GONZALEZ C, A., & YAÑEZ R, E. (1994). Variabilidad del viento, nivel del mar y temperatura en la costa norte de Chile. *Investigaciones marinas*, 22, 85-101.
- Polonsky, A. B., & Serebrennikov, A. N. (2021). Modified technique for calculating the parameters of climatic variability of upwelling by thermal index. *Izvestiya, Atmospheric and Oceanic Physics*, 57(9), 1137-1145.
- Pörtner, H.-O., Roberts, D. C., Masson-Delmotte, V., Zhai, P., Tignor, M., Poloczanska, E., & Weyer, N. M. (2019). The ocean and cryosphere in a changing climate. *IPCC special report on the ocean and cryosphere in a changing climate*, 1155, 10.1017.
- Pozo Buil, M., Jacox, M. G., Fiechter, J., Alexander, M. A., Bograd, S. J., Curchitser, E. N., Edwards, C. A., Rykaczewski, R. R., & Stock, C. A. (2021). A dynamically downscaled ensemble of future projections for the California current system. *Frontiers in Marine Science*, 8, 612874.

- Qian, J., Nguyen, N. P., Oya, Y., Kikugawa, G., Okabe, T., Huang, Y., & Ohuchi, F. S. (2019). Introducing self-organized maps (SOM) as a visualization tool for materials research and education. *Results in materials*, 4, 100020.
- Rasul, K., Ashok, A., Williams, A. R., Khorasani, A., Adamopoulos, G., Bhagwatkar, R., Biloš, M., Ghonia, H., Hassen, N., & Schneider, A. (2023). Lag-llama: Towards foundation models for time series forecasting. *R0-FoMo: Robustness of Few-shot and Zero-shot Learning in Large Foundation Models*.
- Real, R., & Vargas, J. M. (1996). The probabilistic basis of Jaccard's index of similarity. *Systematic biology*, 45(3), 380-385.
- Reddin, C. J., Docmac, F., O'Connor, N. E., Bothwell, J. H., & Harrod, C. (2015). Coastal upwelling drives intertidal assemblage structure and trophic ecology. *PLoS One*, 10(7), e0130789.
- Rekier, J., Chao, B. F., Chen, J., Dehant, V., Rosat, S., & Zhu, P. (2022). Earth's rotation: Observations and relation to deep interior. *Surveys in Geophysics*, 43(1), 149-175.
- Ren, J., Wang, C., Sun, L., Huang, B., Zhang, D., Mu, J., & Wu, J. (2024). Prediction of sea surface temperature using U-Net based model. *Remote Sensing*, 16(7), 1205.
- Reynolds, R. W., Smith, T. M., Liu, C., Chelton, D. B., Casey, K. S., & Schlax, M. G. (2007). Daily high-resolution-blended analyses for sea surface temperature. *Journal of climate*, 20(22), 5473-5496.
- Riahi, K., Van Vuuren, D. P., Kriegler, E., Edmonds, J., O'Neill, B. C., Fujimori, S., Bauer, N., Calvin, K., Dellink, R., & Fricko, O. (2017). The Shared Socioeconomic Pathways and their energy, land use, and greenhouse gas emissions implications: An overview. *Global environmental change*, 42, 153-168.
- Riascos, J. M., Avalos, C. M., Pacheco, A. S., & Heilmayer, O. (2012). Testing stress responses of the bivalve *Protothaca thaca* to El Niño–La Niña thermal conditions. *Marine Biology Research*, 8(7), 654-661.

- Richter, I., & Tokinaga, H. (2020). An overview of the performance of CMIP6 models in the tropical Atlantic: Mean state, variability, and remote impacts. *Climate Dynamics*, 55(9), 2579-2601. <https://doi.org/10.1007/s00382-020-05409-w>
- Ritter, A., & Muñoz-Carpena, R. (2013). Performance evaluation of hydrological models: Statistical significance for reducing subjectivity in goodness-of-fit assessments. *Journal of Hydrology*, 480, 33-45.
- Rixen, T., Lahajnar, N., Lamont, T., Koppelman, R., Martin, B., Van Beusekom, J. E., Siddiqui, C., Pillay, K., & Meiritz, L. (2021). Oxygen and nutrient trapping in the southern Benguela upwelling system. *Frontiers in Marine Science*, 8, 730591.
- Roberts, M. J., Baker, A., Blockley, E. W., Calvert, D., Coward, A., Hewitt, H. T., Jackson, L. C., Kuhlbrodt, T., Mathiot, P., & Roberts, C. D. (2019). *Description of the resolution hierarchy of the global coupled HadGEM3-GC3. 1 model as used in CMIP6 HighResMIP experiments*, *Geosci. Model Dev.*, 12, 4999–5028.
- Roberts, M. J., Camp, J., Seddon, J., Vidale, P. L., Hodges, K., Vanniere, B., Mecking, J., Haarsma, R., Bellucci, A., & Scoccimarro, E. (2020). Impact of model resolution on tropical cyclone simulation using the HighResMIP–PRIMAVERA multimodel ensemble. *Journal of Climate*, 33(7), 2557-2583.
- Roberts-Jones, J., Fiedler, E. K., & Martin, M. J. (2012). Daily, global, high-resolution SST and sea ice reanalysis for 1985–2007 using the OSTIA system. *Journal of Climate*, 25(18), 6215-6232.
- Robinson, A. R., & Brink, K. H. (2005). *The global coastal ocean: Multiscale interdisciplinary processes* (Vol. 11). Harvard University Press.
- Roemmich, D., John Gould, W., & Gilson, J. (2012). 135 years of global ocean warming between the Challenger expedition and the Argo Programme. *Nature Climate Change*, 2(6), 425-428.

- Roemmich, D., & Team, A. S. (2009). Argo: The challenge of continuing 10 years of progress. *Oceanography*, 22(3), 46-55.
- Ronneberger, O., Fischer, P., & Brox, T. (2015). U-net: Convolutional networks for biomedical image segmentation. *International Conference on Medical image computing and computer-assisted intervention*, 234-241.
- Rousseeuw, P. J. (1987). Silhouettes: A graphical aid to the interpretation and validation of cluster analysis. *Journal of Computational and Applied Mathematics*, 20, 53-65.
[https://doi.org/10.1016/0377-0427\(87\)90125-7](https://doi.org/10.1016/0377-0427(87)90125-7)
- Rykaczewski, R. R., Dunne, J. P., Sydeman, W. J., García-Reyes, M., Black, B. A., & Bograd, S. J. (2015). Poleward displacement of coastal upwelling-favorable winds in the ocean's eastern boundary currents through the 21st century. *Geophysical Research Letters*, 42(15), 6424-6431.
- Sagi, T., Lehahn, Y., & Bar, K. (2020). Artificial intelligence for ocean science data integration: Current state, gaps, and way forward. *Elem Sci Anth*, 8, 21.
- Saha, S., Moorthi, S., Pan, H.-L., Wu, X., Wang, J., Nadiga, S., Tripp, P., Kistler, R., Woollen, J., & Behringer, D. (2010). The NCEP climate forecast system reanalysis. *Bulletin of the American Meteorological Society*, 91(8), 1015-1058.
- Saha, S., Moorthi, S., Wu, X., Wang, J., Nadiga, S., Tripp, P., Behringer, D., Hou, Y.-T., Chuang, H., & Iredell, M. (2014). The NCEP climate forecast system version 2. *Journal of climate*, 27(6), 2185-2208.
- Saint-Martin, D., Geoffroy, O., Voldoire, A., Cattiaux, J., Brient, F., Chauvin, F., Chevallier, M., Colin, J., Decharme, B., & Delire, C. (2021). Tracking changes in climate sensitivity in CNRM climate models. *Journal of Advances in Modeling Earth Systems*, 13(6), e2020MS002190.
- Salcedo-Castro, J., de Camargo, R., Marone, E., & Sepúlveda, H. H. (2015). Using the mean pressure gradient and NCEP/NCAR reanalysis to estimate the strength of the South

- Atlantic Anticyclone. *Dynamics of Atmospheres and Oceans*, 71, 83-90.
<https://doi.org/10.1016/j.dynatmoce.2015.06.003>
- Saldías, G. S., Sobarzo, M., Largier, J., Moffat, C., & Letelier, R. (2012). Seasonal variability of turbid river plumes off central Chile based on high-resolution MODIS imagery. *Remote Sensing of Environment*, 123, 220-233.
- Santos, F., Gomez-Gesteira, M., Decastro, M., & Alvarez, I. (2012). Differences in coastal and oceanic SST trends due to the strengthening of coastal upwelling along the Benguela current system. *Continental Shelf Research*, 34, 79-86.
- Schlaefel, J. A., Langlais, C., Choukroun, S., Mongin, M., & Baird, M. E. (2025). The historical representation and near-future (2050) projections of the Coral Sea current system in CMIP6 HighResMIP. *Ocean Science*, 21(5), 2001-2018.
- Schroeder, I. D., Black, B. A., Sydeman, W. J., Bograd, S. J., Hazen, E. L., Santora, J. A., & Wells, B. K. (2013). The North Pacific High and wintertime pre-conditioning of California current productivity. *Geophysical Research Letters*, 40(3), 541-546.
- Schwing, F. B., & Mendelssohn, R. (1997). Increased coastal upwelling in the California Current System. *Journal of Geophysical Research: Oceans*, 102(C2), 3421-3438.
- Shchepetkin, A. F., & McWilliams, J. C. (2009). Computational kernel algorithms for fine-scale, multiprocess, longtime oceanic simulations. En *Handbook of numerical analysis* (Vol. 14, pp. 121-183). Elsevier.
- Shi, X., Chen, Z., Wang, H., Yeung, D.-Y., Wong, W.-K., & Woo, W. (2015). Convolutional LSTM network: A machine learning approach for precipitation nowcasting. *Advances in neural information processing systems*, 28.
- Shukla, P. R., Skeg, J., Buendia, E. C., Masson-Delmotte, V., Pörtner, H.-O., Roberts, D. C., Zhai, P., Slade, R., Connors, S., & Van Diemen, S. (2019). *Climate Change and Land: An IPCC special report on climate change, desertification, land degradation,*

sustainable land management, food security, and greenhouse gas fluxes in terrestrial ecosystems.

- Sinclair, M. R. (1996). A Climatology of Anticyclones and Blocking for the Southern Hemisphere. *Monthly Weather Review*, 124(2), 245-264. [https://doi.org/10.1175/1520-0493\(1996\)124%253C0245:ACOAAB%253E2.0.CO;2](https://doi.org/10.1175/1520-0493(1996)124%253C0245:ACOAAB%253E2.0.CO;2)
- Small, R. J., Curchitser, E., Hedstrom, K., Kauffman, B., & Large, W. G. (2015). The Benguela upwelling system: Quantifying the sensitivity to resolution and coastal wind representation in a global climate model. *Journal of Climate*, 28(23), 9409-9432.
- Snyder, M. A., Sloan, L. C., Diffenbaugh, N. S., & Bell, J. L. (2003). Future climate change and upwelling in the California Current. *Geophysical Research Letters*, 30(15).
- Song, T., Jiang, J., Li, W., & Xu, D. (2020). A deep learning method with merged LSTM neural networks for SSHA prediction. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 13, 2853-2860.
- Song, Z., Liu, H., & Chen, X. (2020). Eastern equatorial Pacific SST seasonal cycle in global climate models: From CMIP5 to CMIP6. *Acta Oceanologica Sinica*, 39(7), 50-60. <https://doi.org/10.1007/s13131-020-1623-z>
- Sonnewald, M., Lguensat, R., Jones, D. C., Dueben, P. D., Brajard, J., & Balaji, V. (2021). Bridging observations, theory and numerical simulation of the ocean using machine learning. *Environmental Research Letters*, 16(7), 073008.
- Sousa, F. M., Nascimento, S., Casimiro, H., & Boutov, D. (2008). Identification of upwelling areas on sea surface temperature images using fuzzy clustering. *Remote Sensing of Environment*, 112(6), 2817-2823.
- Sousa, M. C., Alvarez, I., deCastro, M., Gomez-Gesteira, M., & Dias, J. M. (2017). Seasonality of coastal upwelling trends under future warming scenarios along the southern limit of the canary upwelling system. *Progress in Oceanography*, 153, 16-23.

- Sousa, M. C., Ribeiro, A., Des, M., Gomez-Gesteira, M., deCastro, M., & Dias, J. M. (2020). NW Iberian Peninsula coastal upwelling future weakening: Competition between wind intensification and surface heating. *Science of the total environment*, 703, 134808.
- Speth, P., Detlefsen, H., & Sierts, H.-W. (1978). Meteorological influence on upwelling off Northwest Africa. *Deutsche Hydrografische Zeitschrift*, 31(3), 95-104.
- Squintu, A. A., van der Schrier, G., van den Besselaar, E., van der Linden, E., Putrasahan, D., Roberts, C., Roberts, M., Scoccimarro, E., Senan, R., & Klein Tank, A. (2021). Evaluation of trends in extreme temperatures simulated by HighResMIP models across Europe. *Climate Dynamics*, 56(7), 2389-2412.
- Stark, J. D., Donlon, C. J., Martin, M. J., & McCulloch, M. E. (2007). OSTIA: An operational, high resolution, real time, global sea surface temperature analysis system. *Oceans 2007-europe*, 1-4.
- Staten, P. W., Lu, J., Grise, K. M., Davis, S. M., & Birner, T. (2018). Re-examining tropical expansion. *Nature Climate Change*, 8(9), 768-775.
- Storto, A., & Masina, S. (2016). C-GLORSv5: An improved multipurpose global ocean eddy-permitting physical reanalysis. *Earth System Science Data*, 8(2), 679-696.
- Sun, Y. (2000). On quantization error of self-organizing map network. *Neurocomputing*, 34(1), 169-193. [https://doi.org/10.1016/S0925-2312\(00\)00292-7](https://doi.org/10.1016/S0925-2312(00)00292-7)
- Sverdrup, H. U., & Defant, A. (1937). The Cold Water Region off South West Africa. *Geographical Review*, 27(4), 695.
- Sydeman, W. J., García-Reyes, M., Schoeman, D. S., Rykaczewski, R. R., Thompson, S. A., Black, B. A., & Bograd, S. J. (2014). Climate change and wind intensification in coastal upwelling ecosystems. *Science*, 345(6192), 77-80.
- Sylla, A., Mignot, J., Capet, X., & Gaye, A. T. (2019). Weakening of the Senegalo–Mauritanian upwelling system under climate change. *Climate Dynamics*, 53(7), 4447-4473.

- Sylla, A., Sanchez Gomez, E., Mignot, J., & López-Parages, J. (2022). Impact of increased resolution on the representation of the Canary upwelling system in climate models. *Geosci. Model Dev.*, 15(22), 8245-8267. <https://doi.org/10.5194/gmd-15-8245-2022>
- Taboada, F. G., Stock, C. A., Griffies, S. M., Dunne, J., John, J. G., Small, R. J., & Tsujino, H. (2019). Surface winds from atmospheric reanalysis lead to contrasting oceanic forcing and coastal upwelling patterns. *Ocean Modelling*, 133, 79-111.
- Tapia, F. J., Navarrete, S. A., Castillo, M., Menge, B. A., Castilla, J. C., Largier, J., Wieters, E. A., Broitman, B. L., & Barth, J. A. (2009). Thermal indices of upwelling effects on inner-shelf habitats. *Progress in Oceanography*, 83(1-4), 278-287.
- Taylor, J., & Feng, M. (2022). A deep learning model for forecasting global monthly mean sea surface temperature anomalies. *Frontiers in Climate*, 4, 932932.
- Taylor, K. E. (2001). Summarizing multiple aspects of model performance in a single diagram. *Journal of geophysical research: atmospheres*, 106(D7), 7183-7192.
- Taylor, K. E., Stouffer, R. J., & Meehl, G. A. (2012). An overview of CMIP5 and the experiment design. *Bulletin of the American meteorological Society*, 93(4), 485-498.
- Terada, M., Minobe, S., & Deutsch, C. (2020). Mechanisms of future changes in equatorial upwelling: CMIP5 intermodel analysis. *Journal of Climate*, 33(2), 497-510.
- Thandlam, V., & Rahaman, H. (2019). Evaluation of surface shortwave and longwave downwelling radiations over the global tropical oceans. *SN Applied Sciences*, 1(10), 1171.
- Thiel, M., Macaya, E. C., Acuña, E., & Arntz, W. E. (2007). The humboldt current system of northern and central chile: Oceanographic processes, ecological interactions and socioeconomic feedback. *Oceanography and Marine Biology*, 45, 195-344.
- Thomas, A. C., Blanco, J. L., Carr, M. E., Strub, P. T., & Osses, J. (2001). Satellite-measured chlorophyll and temperature variability off northern Chile during the 1996–1998 La Niña and El Niño. *Journal of Geophysical Research: Oceans*, 106(C1), 899-915.

- Tim, N., Zorita, E., Hünicke, B., Yi, X., & Emeis, K.-C. (2016). The importance of external climate forcing for the variability and trends of coastal upwelling in past and future climate. *Ocean Science*, 12(3), 807-823.
- Tokinaga, H., & Xie, S.-P. (2011). Wave-and anemometer-based sea surface wind (WASWind) for climate change analysis. *Journal of Climate*, 24(1), 267-285.
- Tomczak Jr, M. (1981). Coastal upwelling systems and eastern boundary currents: A review of terminology. *Geoforum*, 12(2), 179-191.
- Varela, R., Álvarez, I., Santos, F., DeCastro, M., & Gómez-Gesteira, M. (2015). Has upwelling strengthened along worldwide coasts over 1982-2010? *Scientific reports*, 5(1), 10016.
- Varela, R., DeCastro, M., Rodríguez-Díaz, L., Dias, J. M., & Gómez-Gesteira, M. (2022). Examining the ability of CMIP6 models to reproduce the upwelling SST imprint in the eastern boundary upwelling systems. *Journal of Marine Science and Engineering*, 10(12), 1970.
- Varela, R., Lima, F. P., Seabra, R., Meneghesso, C., & Gómez-Gesteira, M. (2018). Coastal warming and wind-driven upwelling: A global analysis. *Science of the Total Environment*, 639, 1501-1511.
- Varela, R., Rodríguez-Díaz, L., De Castro, M., & Gómez-Gesteira, M. (2022). Influence of Canary upwelling system on coastal SST warming along the 21st century using CMIP6 GCMs. *Global and Planetary Change*, 208, 103692.
- Verdon, D. C., & Franks, S. W. (2006). Long-term behaviour of ENSO: Interactions with the PDO over the past 400 years inferred from paleoclimate records. *Geophysical Research Letters*, 33(6).
- von Storch, H., & Hannoschöck, G. (1985). Statistical aspects of estimated principal vectors (EOFs) based on small sample sizes. *Journal of Applied Meteorology and Climatology*, 24(7), 716-724.

- Wang, D., Gouhier, T. C., Menge, B. A., & Ganguly, A. R. (2015). Intensification and spatial homogenization of coastal upwelling under climate change. *Nature*, *518*(7539), 390-394.
- Wang, X., Miao, Z., Zhang, R., & Hao, S. (2019). I3d-lstm: A new model for human action recognition. *IOP conference series: materials science and engineering*, *569*(3), 032035.
- Wang, Y., Heywood, K. J., Stevens, D. P., & Damerell, G. M. (2022). Seasonal extrema of sea surface temperature in CMIP6 models. *Ocean Sci.*, *18*(3), 839-855.
<https://doi.org/10.5194/os-18-839-2022>
- Wang, Z., Bovik, A. C., Sheikh, H. R., & Simoncelli, E. P. (2004). Image quality assessment: From error visibility to structural similarity. *IEEE transactions on image processing*, *13*(4), 600-612.
- Watt-Meyer, O., Frierson, D., & Fu, Q. (2019). Hemispheric asymmetry of tropical expansion under CO2 forcing. *Geophysical Research Letters*, *46*(15), 9231-9240.
- Wei, L., & Guan, L. (2022). Seven-day sea surface temperature prediction using a 3DConv-LSTM model. *Frontiers in Marine Science*, *9*, 905848.
- Weidberg, N., Ospina-Alvarez, A., Bonicelli, J., Barahona, M., Aiken, C. M., Broitman, B. R., & Navarrete, S. A. (2020). Spatial shifts in productivity of the coastal ocean over the past two decades induced by migration of the Pacific Anticyclone and Bakun's effect in the Humboldt Upwelling Ecosystem. *Global and Planetary Change*, *193*, 103259.
- Wernli, H., & Schieritz, C. (2006). Surface Cyclones in the ERA-40 Dataset (1958–2001). Part I: Novel Identification Method and Global Climatology. *Journal of the Atmospheric Sciences*, *63*(10), 2486-2507. <https://doi.org/10.1175/JAS3766.1>
- Wessel, P., Luis, J. F., Uieda, L. al, Scharroo, R., Wobbe, F., Smith, W. H., & Tian, D. (2019). The generic mapping tools version 6. *Geochemistry, Geophysics, Geosystems*, *20*(11), 5556-5564.
- Wilks, D. S. (2011). *Statistical methods in the atmospheric sciences* (Vol. 100). Academic press.

- Wilks, D. S. (2019). Chapter 12—The Multivariate Normal Distribution. En D. S. Wilks (Ed.), *Statistical Methods in the Atmospheric Sciences (Fourth Edition)* (pp. 587-615). Elsevier. <https://doi.org/10.1016/B978-0-12-815823-4.00012-2>
- Willmott, C. J., Ackleson, S. G., Davis, R. E., Feddema, J. J., Klink, K. M., Legates, D. R., O'donnell, J., & Rowe, C. M. (1985). Statistics for the evaluation and comparison of models. *Journal of Geophysical Research: Oceans*, 90(C5), 8995-9005.
- Wong, A. P., Wijffels, S. E., Riser, S. C., Pouliquen, S., Hosoda, S., Roemmich, D., Gilson, J., Johnson, G. C., Martini, K., & Murphy, D. J. (2020). Argo data 1999–2019: Two million temperature-salinity profiles and subsurface velocity observations from a global array of profiling floats. *Frontiers in Marine Science*, 7, 700.
- Wooster, W. S., Bakun, A., & McLain, D. R. (1976). *The seasonal upwelling cycle along the eastern boundary of the North Atlantic*.
- Xian, T., Xia, J., Wei, W., Zhang, Z., Wang, R., Wang, L.-P., & Ma, Y.-F. (2021). Is Hadley cell expanding? *Atmosphere*, 12(12), 1699.
- Y. Aslam, N. Santhi, N. Ramasamy, & K. Ramar. (2020). A Review on Various Clustering Approaches for Image Segmentation. *2020 Fourth International Conference on Inventive Systems and Control (ICISC)*, 679-685. <https://doi.org/10.1109/ICISC47916.2020.9171125>
- Yu, L., & Weller, R. A. (2007). Objectively analyzed air–sea heat fluxes for the global ice-free oceans (1981–2005). *Bulletin of the American Meteorological Society*, 88(4), 527-540.
- Yu, X., Shi, S., Xu, L., Liu, Y., Miao, Q., & Sun, M. (2020). A novel method for sea surface temperature prediction based on deep learning. *Mathematical Problems in Engineering*, 2020(1), 6387173.
- Z. Wang & A. C. Bovik. (2009). Mean squared error: Love it or leave it? A new look at Signal Fidelity Measures. *IEEE Signal Processing Magazine*, 26(1), 98-117. <https://doi.org/10.1109/MSP.2008.930649>

- Zaytsev, O., Cervantes-Duarte, R., Montante, O., & Gallegos-Garcia, A. (2003). Coastal upwelling activity on the Pacific shelf of the Baja California Peninsula. *Journal of oceanography*, 59(4), 489-502.
- Zhou Wang, A. C. Bovik, H. R. Sheikh, & E. P. Simoncelli. (2004). Image quality assessment: From error visibility to structural similarity. *IEEE Transactions on Image Processing*, 13(4), 600-612. <https://doi.org/10.1109/TIP.2003.819861>

ANEXOS