



UNIVERSIDAD PERUANA
CAYETANO HEREDIA

**DOWNSCALING DEL VIENTO EN EL
SISTEMA DE AFLORAMIENTO
PERUANO USANDO REDES
NEURONALES: IMPACTO DEL
CAMBIO CLIMÁTICO SOBRE EL
TRANSPORTE Y BOMBEO DE
EKMAN**

TESIS PARA OPTAR EL GRADO
DE MAESTRO EN CIENCIAS DEL
MAR

VICTOR ANDRÉ RUIZ CCORI

LIMA – PERÚ

2025

ASESOR:

Dr. Adolfo Vicente Chamorro Gómez

Investigador Externo

Pontificia Universidad Católica del Perú (PUCP)

CO-ASESORES:

Dra. Sophie Giffard-Roisin

Investigadora del Instituto de Investigación para el Desarrollo de Francia (IRD)

Dr. Jorge Larry Tam Malaga

Investigador del Instituto del Mar del Perú (IMARPE)

JURADO DE TESIS

DR. FRANCOIS CHARLES COLAS

PRESIDENTE

DR. DANTE ESPINOZA MORRIBERON

VOCAL

DR. DIMITRI ALEXEY GUTIERREZ AGUILAR

SECRETARIO

DEDICATORIA:

En profundo agradecimiento a mis padres Rossy y Victor y mi hermano Fabian, quienes me han guiado hacia una cultura de estudio y trabajo. Esta tesis es el reflejo de sus enseñanzas, su ejemplo y su apoyo incondicional.

IN MEMORIAM:

En memoria de mi mamita Angelica, casi cinco años desde su partida. Por criarme, educarme y ser ejemplo de sacrificio y superación. Tus enseñanzas, historias y llamadas de atención siempre guiarán mis pasos. Me haces mucha falta.

AGRADECIMIENTOS:

Agradezco a mi asesor el Dr. Adolfo Chamorro y mis co-asesores la Dra. Sophie Giffard-Roisin y el Dr. Jorge Tam por su dirección académica durante la realización de la presente tesis.

Al Dr. François Colas y al Dr. Vincent Echevin, cuya orientación e intercambio de ideas fortalecieron la elaboración de este trabajo.

Al Laboratorio de Modelado Oceanográfico, Ecosistémico y Cambio Climático (LMOECC) del IMARPE, por facilitarme sus instalaciones y equipos; así como a sus integrantes por su retroalimentación y soporte durante el desarrollo de esta tesis.

Finalmente, expreso mi gratitud a todos los miembros de mi familia por su constante motivación y apoyo incondicional.

FUENTES DE FINANCIAMIENTO:

Este trabajo fue subvencionado por el CONCYTEC a través del programa PROCENCIA, según contrato PE501082376-2023-PROCENCIA, proyecto “Evolución futura de olas de calor e hipoxias en el mar peruano bajo escenarios regionalizados de cambio climático usando inteligencia artificial”.

DECLARACIÓN DE AUTOR			
FECHA	16	DICIEMBRE	2025
APELLIDOS Y NOMBRES DEL EGRESADO	RUIZ CCORI VICTOR ANDRÉ		
PROGRAMA DE POSGRADO	MAESTRÍA EN CIENCIAS DEL MAR		
AÑO DE INICIO DE LOS ESTUDIOS	2022		
TITULO DEL TRABAJO DE INVESTIGACIÓN DE GRADO	DOWNSCALING DEL VIENTO EN EL SISTEMA DE AFLORAMIENTO PERUANO USANDO REDES NEURONALES: IMPACTO DEL CAMBIO CLIMÁTICO SOBRE EL TRANSPORTE Y BOMBEO DE EKMAN		
MODALIDAD DE TRABAJO DE GRADO	TESIS		
Declaración del Autor El presente Trabajo de Grado es original y no es el resultado de un trabajo en colaboración con otros, excepto cuando así está citado explícitamente en el texto. No ha sido ni enviado ni sometido a evaluación para la obtención de otro grado o diploma que no sea el presente.			
Teléfono de contacto (fijo / móvil)	943735889		
E-mail	andre.ruiz.ccori@gmail.com / victor.ruiz@upch.pe		



Firma del Egresado

DNI 98986545

ÍNDICE

Resumen	
Abstract	
1. INTRODUCCIÓN	1
MARCO TEÓRICO	1
El sistema de afloramiento peruano	1
Transporte y bombeo de Ekman forzado por el viento	3
Modelado climático y <i>downscaling</i>	5
Escenarios de cambio climático	10
<i>Deep learning</i> y redes neuronales convolucionales	16
ANTECEDENTES	21
PLANTEAMIENTO DEL PROBLEMA	27
PREGUNTA CENTRAL	28
HIPÓTESIS	29
JUSTIFICACIÓN	29
2. OBJETIVOS	31
2.1. GENERAL	31
2.2. ESPECÍFICOS	31
3. METODOLOGÍA	33
3.1. DISEÑO EXPERIMENTAL	33
3.2. VARIABLES DE ESTUDIO Y BASES DE DATOS	36
3.3. DESCRIPCIÓN DE LOS MODELOS DE RED NEURONAL	39
Modelos de redes neuronales convolucionales (CNN)	39
Modelos <i>Coding-Decoding</i> (C-D)	41
3.4. PROCEDIMIENTOS Y MÉTODOS	43
a. Implementación y aplicación del modelo de redes neuronales para el <i>downscaling</i> de vientos	43
b. Reducción de escala de vientos para modelos del CMIP6 a partir de CNN	46
c. Intensidad y rotacional del viento en la costa	53
d. Transporte y bombeo de Ekman	55

4.	RESULTADOS	58
4.1.	COMPARACIÓN Y SELECCIÓN DEL MODELO DE REDES NEURONALES PARA EL <i>DOWNSCALING</i> ESTADÍSTICO DE VIENTOS	58
4.2.	PROYECCIONES DEL VIENTO EN A LA COSTA	68
a.	Proyecciones de la intensidad viento <i>alongshore</i> frente a la costa peruana	68
b.	Proyecciones del rotacional del viento frente a la costa peruana	77
4.3.	PROYECCIONES DEL TRANSPORTE Y BOMBEO DE EKMAN	84
a.	Proyecciones del transporte de Ekman frente a la costa peruana	85
b.	Proyecciones del bombeo de Ekman frente a la costa peruana	96
5.	DISCUSIONES	106
5.1.	SOBRE LA ARQUITECTURA DE LA RED NEURONAL	106
5.2.	SOBRE LA ELECCIÓN DE PREDICTORES	107
5.3.	IMPACTO DEL CAMBIO CLIMÁTICO SOBRE EL AFLORAMIENTO COSTERO	110
5.4.	INFLUECIA DE LA TENDENCIA DE LOS MODELOS GLOBALES	118
5.5.	LIMITACIONES	127
6.	CONCLUSIONES	130
6.1.	ENFOQUE METODOLÓGICO Y DESEMPEÑO DEL MODELO	130
6.2.	PROYECCIONES DEL CAMBIO EN EL VIENTO	130
6.3.	PROYECCIONES DEL CAMBIO EN EL AFLORAMIENTO (TRANSPORTE Y BOMBEO DE EKMAN)	131
7.	PERSPECTIVAS Y RECOMENDACIONES	132
	REFERENCIAS	134
	APÉNDICE A. HIPERPARÁMETROS EN LAS REDES NEURONALES CONVOLUCIONALES	1
I.	Optimizadores en el <i>deep learning</i>	1
II.	Tasa de aprendizaje y decaimiento	3
III.	Tamaño del minibatch	5
IV.	Número de épocas	6
V.	Subconjunto de validación y criterios de detención temprana	8
VI.	Sobre la configuración de hiperparámetros	9
	APÉNDICE B. FIGURAS SUPLEMENTARIAS	10

Resumen

El Sistema de Afloramiento Peruano (SAP) es uno de los ecosistemas marinos más productivos del mundo. Su dinámica está controlada principalmente por la intensidad y la estructura espacial de los vientos superficiales costeros, los cuales permiten el ascenso de aguas profundas, frías y ricas en nutrientes, sosteniendo así la alta productividad biológica del mar peruano. En el contexto del cambio climático, las posibles alteraciones en los vientos costeros podrían afectar esta dinámica. Por ello, diversos estudios han utilizado diferentes métodos de reducción de escala (*downscaling*) para proyectar el viento futuro a partir de las salidas de Modelos Climáticos Globales (GCMs). Estos modelos concuerdan en un debilitamiento de los vientos de verano, pero discrepan respecto a los vientos de invierno. La incertidumbre es alta, ya que muchas proyecciones se han basado en un único modelo global o en un solo escenario de emisiones, con periodos cortos de evaluación debido a limitaciones computacionales. Para superar estas limitaciones, es necesario utilizar una mayor variedad de GCMs y aplicar un método de *downscaling* computacionalmente eficiente.

Esta tesis tiene como objetivo evaluar el impacto del cambio climático sobre los vientos costeros, y el transporte y bombeo de Ekman forzados por el viento en el SAP, mediante el *downscaling* estadístico de vientos superficiales de múltiples GCM del CMIP6. Se utilizaron modelos basados en redes neuronales convolucionales (CNN) debido a su capacidad para aprender características espaciales complejas de los datos de entrada y relaciones no lineales entre las variables. Se entrenaron tres arquitecturas CNN (dos lineales y una de *coding*-

decoding) para aprender las relaciones estadísticas entre las salidas de viento de baja resolución (~100 km) y las observaciones de alta resolución (~25 km). El modelo con mejor desempeño se aplicó para realizar la reducción de escala de 12 modelos del CMIP6 en cuatro periodos: histórico (1995-2014), futuro cercano (2021-2040), futuro intermedio (2046-2065) y futuro lejano (2081-2100). Los resultados mostraron cambios débiles (<5 %) y no robustos en los patrones de viento para los futuros cercano e intermedio. Para el futuro lejano, se observan cambios robustos al norte de los 8° S durante el verano, con un debilitamiento de los vientos (~15 %) y del rotacional del esfuerzo del viento (~5-10 %), implicando una reducción de ~12 % en el transporte de Ekman y de ~7 % en el bombeo de Ekman. A lo largo de la costa central, los cambios fueron pequeños (<5 %), mientras que en la región sur se observó un ligero fortalecimiento robusto del viento superficial y el rotacional del viento, condiciones favorables para el afloramiento.

Palabras clave: *Downscaling* estadístico, Cambio climático, Redes neuronales convolucionales, Viento costero, Transporte de Ekman, Bombeo de Ekman, Sistema de afloramiento peruano, Modelos CMIP6.

Abstract

The Peruvian Upwelling System (PUS) is one of the most productive marine ecosystems in the world. Its dynamics is primarily controlled by the intensity and spatial structure of nearshore surface winds, enabling the rise of deep, cold and nutrient-rich waters, which sustains the high biological productivity of the Peruvian sea. In the context of climate change, potential alterations in coastal winds could affect this dynamics. Therefore, several studies have used different downscaling methods in order to project future wind patterns from global climate models (GCMs) outputs. These models agree on a weakening of summer winds, but differ regarding winter winds. Uncertainty remains high, as many projections have been based on a single global model or on a single emissions scenario, with short evaluation periods due to computational limitations. To overcome these limitations, it is necessary to use a larger diversity of GCMs and to apply a computationally low-cost downscaling method.

This thesis aims to assess the impact of climate change on coastal winds, as well as on wind-forced Ekman transport and pumping in the PUS, through statistical downscaling of surface winds from multiple GCMs of the CMIP6 project. Convolutional neural network (CNN) based models were used, due to their capacity to learn complex spatial features from the input data and nonlinear relations between variables. Three CNN model architectures (two linear and one coding-decoding) were trained to learn statistical relationships between coarse-resolution wind outputs (~100 km) and high-resolution observations (~25 km). The best-performing model was applied to downscale 12 CMIP6 models across four periods:

historical (1995-2014), the near future (2021-2040), intermediate future (2046-2065), and far future (2081-2100). The results showed weak ($<5\%$) and non-robust changes in the wind patterns for the near and intermediate futures. For the far future, robust changes are observed north of 8° S during the summer, with weaker winds ($\sim 15\%$) and wind stress curl ($\sim 5\text{-}10\%$), implying a $\sim 12\%$ reduction in Ekman transport and a $\sim 7\%$ reduction in Ekman pumping. Along the central coast, non-robust changes were small ($<5\%$), while in the southern region near, a robust slight strengthening of upwelling-favorable surface winds and wind stress curl was observed.

Keywords: Statistical Downscaling, Climate change, Convolutional neural networks, Coastal wind, Ekman transport, Ekman pumping, Peruvian upwelling system, CMIP6 models.

1. INTRODUCCIÓN

MARCO TEÓRICO

El sistema de afloramiento peruano

Los ecosistemas de afloramiento de borde oriental (EBUS) son de las regiones más importantes en el océano mundial, los cuales poseen una gran productividad marina como resultado de la pesca de pequeños pelágicos, implicando un alto beneficio económico para sus países vecinos (Echevin et al. 2020). En total se contabilizan 4 EBUS: California, Benguela, Iberia/noroeste de África (o Canarias) y Humboldt (o Perú-Chile).

Dentro del sistema de afloramiento de Humboldt se pueden diferenciar 3 biomas (Chavez & Messié 2009): un sistema de afloramiento estacional (de verano) de alta productividad, ubicado frente al sur de Chile (entre 30°-40° S); una zona de “sombra de afloramiento”, con una productividad de moderada a baja frente al norte de Chile y el sur de Perú (entre 18°-26° S); y el sistema de afloramiento peruano (SAP), altamente productivo a lo largo de todo el año (entre 4°-16° S). En particular, el SAP destaca por ser el responsable de aproximadamente el 10 % del total de captura de peces en todo el mundo, pese a representar una pequeña fracción del océano global (menos del 0.1 %) (Messié et al. 2009, Echevin et al. 2020). Más aún, y a pesar de no ser el ecosistema más productivo, el sistema de afloramiento peruano evidencia una tasa de captura de peces diaria por unidad de área de un orden de magnitud superior que los otros EBUS (Chavez et al. 2008); siendo impulsado principalmente por la rica pesca de anchoveta.

Particularmente, la gran actividad biológica en nuestro sistema de afloramiento favorece a las altas tasas de consumo de oxígeno producto de la descomposición de materia orgánica (remineralización) que, sumado a la lenta ventilación sobre la región, propician el desarrollo de una de las principales Zonas de Mínimo Oxígeno (ZMO) en todo el océano (Chavez et al. 2008, Mogollón & Calil 2017). La ZMO frente a Perú es intensa ($<22.5 \mu\text{mol kg}^{-1}$) y posee una amplia extensión vertical (~ 500 m). En algunas latitudes su límite superior puede llegar a ser bastante superficial (entre 25-50 m), interceptándose con la zona eufótica e incidiendo en la plataforma continental (Graco et al. 2017). Además, estudios recientes (Mogollón & Calil 2017) sugieren que las ZMO se estarían expandiendo e intensificando, impactando sobre la biodiversidad marina y su distribución.

Por otro lado, la ubicación latitudinal del SAP lo hace sensible a la dinámica ecuatorial, siendo susceptible a eventos de variabilidad interanual como El Niño y la Oscilación del Sur (ENOS) y a la ocurrencia de eventos extremos de calentamiento de menor escala (espacio-temporal) como las olas de calor marina (Espinoza-Morriberón et al. 2017, Pietri et al. 2021). De manera general, durante la fase cálida del ENOS (El Niño, EN) la intensidad de los vientos muestra anomalías positivas frente a la costa peruana; una termoclina más profunda y aguas más cálidas provocan un afloramiento empobrecido en nutrientes, reduciendo la clorofila superficial y mermando la producción primaria. Por el contrario, la fase fría del ENOS (La Niña, LN) se asocia con vientos más débiles frente al centro y norte de Perú; sin embargo, la termoclina es más somera, derivando en un mayor

aporte de nutrientes sobre las aguas superficiales y una mayor producción primaria (Chamorro et al. 2018, Yari et al. 2023).

Transporte y bombeo de Ekman forzado por el viento




Figura 1. Mapas de (a) TSM, vientos superficiales (intensidad y dirección) y (b) clorofila para cada el sistema de afloramiento peruano. La TSM es el promedio mensual MODIS de julio de 2002 a abril de 2008; la clorofila es el promedio mensual de SeaWiFS desde septiembre de 1997 hasta septiembre de 2007; los vientos son un promedio semanal de QuikSCAT desde julio de 1999 hasta julio de 2008. El inserto en el mapa de clorofila muestra la productividad primaria media (PP) y la captura de peces para los años 1998-2005 (extraído de Chavez & Messié 2009).

Como en otros EBUS, la dinámica del afloramiento frente a la costa peruana es influenciada principalmente por la estructura del viento costero. El esfuerzo o “*stress*” del viento a lo largo de la costa y hacia el ecuador genera una divergencia de las corrientes costeras, desplazando mar adentro las aguas superficiales (transporte de Ekman, flechas verdes en Figura 2), siendo compensadas por un ascenso vertical de aguas frías, profundas y ricas en nutrientes (Chavez & Messié

2009). Este efecto se manifiesta en variables como la temperatura superficial del mar (TSM, peculiarmente baja cerca de la costa peruana dada su proximidad al ecuador) y la concentración de fitoplancton superficial (Figura 1); y se hace más pronunciado durante los meses de invierno a raíz de un aumento en la intensidad de los vientos paralelos a la costa (“*alongshore winds*”) y favorables al afloramiento (Chavez et al. 2008).

Por su parte, el *stress* del viento fluctúa a lo largo de la costa dentro de una franja (entre 100-250 km), intensificándose mar adentro (“*drop-off*” del viento, flechas negras en Figura 2). Podemos medir la variación espacial de la intensidad del viento a través del rotacional del esfuerzo del viento (“*wind stress curl*”). Específicamente para el sistema de afloramiento peruano, el efecto *drop-off* genera valores negativos para *curl* del *stress* del viento y fomenta un proceso de afloramiento complementario conocido como “bombeo de Ekman” (Albert et al. 2010, Chavez & Messié 2009). De manera esquemática, se representa el bombeo de Ekman en la Figura 2 (flechas magenta), como consecuencia del efecto *drop-off*. Para una lectura más amigable, en adelante nos referiremos al rotacional del esfuerzo del viento como “*curl* del viento”.

Si bien la intensidad del afloramiento costero suele ser medirse utilizando únicamente una relación sencilla basada en el *stress* del viento a lo largo de la costa, esta aproximación ignora otros procesos físicos de mayor complejidad como el *curl* del viento o el flujo geostrófico hacia la costa (Bravo et al. 2016). En particular y para el caso del *curl* del viento, estudios de modelado oceánico regional muestran que los cambios en la estructura del viento cerca de la costa impactan fuertemente

en el afloramiento (Capet et al. 2004). Esto enfatiza la importancia de disponer de una base de datos de alta resolución que permita reproducir de manera más precisa del efecto *drop-off* del viento y, por ende, del bombeo de Ekman.




Figura 2. Representación esquemática del transporte (flechas verdes) y bombeo de Ekman (flechas magenta) para el SAP. Las flechas negras indican la intensidad (y *drop-off*) del viento paralelo a la costa.

Modelado climático y *downscaling*

Hoy por hoy, la herramienta principal utilizada para investigar la evolución del clima a escala global son los Modelos Generales de Circulación (GCM) (Rummukainen 2010). Estos modelos solucionan las ecuaciones físicas que gobiernan la dinámica de un sistema climático (conservación de energía y masa, ecuaciones de Navier-Stokes, etc.), mediante aplicación de algoritmos numéricos sobre un espacio discretizado tridimensional (Figura 3).




Figura 3. Representación de la estructura de grillado usada para la aplicación del método numérico de diferencias finitas en un GCM (extraído de Edwards 2011).

Ya desde la década de 1990, se han ido modelando procesos complementarios relevantes en el clima (como aspectos sociales, políticos y económicos), los cuales se han acoplado a los Modelos Generales de Circulación acoplados Atmósfera-Océano (AOGCM) para dar lugar a los *Earth System Models* (ESM) y los *Integrated Assesment Models* (IAM). Diversas disciplinas vienen trabajando de manera conjunta con el fin de satisfacer el intenso interés científico por implementar simulaciones más realistas de cambio climático. Como resultado de esta colaboración, se ha creado una infraestructura global, modular y cada vez más estandarizada para generar conocimientos sobre el clima de la Tierra, basados en simulaciones de modelos (Edwards 2011).

La resolución espacial de los AOGCM suele variar entre los 100-200 km, resultando suficiente para la representación de características climáticas a gran escala, como la circulación general de la atmósfera y el océano, y los patrones temperatura, precipitación, etc.; pero insuficiente cuando se pretende de estudiar características regionales y locales del clima, tales como la topografía continental, la nubosidad, el uso de la tierra, etc. En la actualidad, el elevado costo computacional que implica el desarrollo de modelos globales a alta resolución (25 km o menos) dificulta su implementación. De modo que, resulta necesario el desarrollo de métodos alternativos para cerrar la brecha entre la información de baja resolución espacial brindada por los GCM y los procesos oceanográficos de escala regional y/o local, dando lugar a lo que se conoce como reducción de escala o “*downscaling*” (Fowler et al. 2007, Rummukainen 2010).

Durante las últimas décadas han emergido dos metodologías esenciales y conceptualmente distintas para la reducción de escala: el *downscaling* dinámico y el *downscaling* estadístico.

El *downscaling* dinámico se sustenta en la implementación y manipulación de modelos climáticos regionales (RCM). Estos emplean datos de GCMs como condiciones iniciales y de frontera lateral para solucionar numéricamente (con diversas técnicas de discretización y parametrizaciones) las ecuaciones que definen la dinámica del sistema climático sobre un área acotada de interés, a una escala espacial típicamente menor a 0.5° (~50 km). En consecuencia, estos tienen la capacidad de replicar, de manera más precisa, las características climáticas regionales propios de un sistema, como topografía compleja, uso de la tierra, líneas

de costa, efectos directos e indirectos de aerosoles y circulaciones de mesoescala (Giorgi & Gutowski 2015, Fowler et al. 2007). El uso de los RCM para la evaluación del impacto del cambio climático se ha restringido a un número corto de proyecciones (principalmente una o dos) en intervalos de tiempo reducidos (por lo general, menores a 30 años), dado el elevado costo computacional que estos implican (Jang & Kavvas 2014).

Asimismo, el *downscaling* de tipo estadístico se establece bajo el supuesto de que el clima a escala regional está influenciado tanto por las características fisiográficas locales/regionales como por las condiciones climáticas a gran escala. En lugar de resolver la física involucrada en el intercambio de energía y masa entre la tierra y la atmósfera, el *downscaling* estadístico se centra en establecer una relación o “función de transferencia”, mediante métodos estadísticos, entre las variables climáticas a gran escala (predictores) y variables regionales y/o locales (predictantes) durante un período preestablecido de entrenamiento (Mearns et al. 2003, Wilby et al. 2004, Jang & Kavvas 2014). Así, es posible estimar las características climáticas locales y regionales durante un periodo de interés utilizando la función de transferencia resultante (Mearns et al. 2003). Además de tener en cuenta el predictante (la variable que se busca reducir de escala) y sus conexiones, los conjuntos de predictores suelen asociarse a la presión a nivel del mar, la altura geopotencial, los campos de viento, la humedad absoluta o relativa y las variables de temperatura. Cada una de las variables predictoras se recopila bajo su propia resolución espacial; sin embargo, el grillado de los modelos climáticos operativos o productos de reanálisis (predictores durante el entrenamiento), y el de

los resultados de las proyecciones de cambio climático a partir de GCM (predictores para la aplicación) no siempre se corresponden. Por lo tanto, promover la aplicación de un modelo estadístico de reducción de escala sobre las salidas de un GCM, generalmente requiere de la interpolación de sus datos a la resolución espacial de los predictores atmosféricos utilizados durante el entrenamiento (Wilby et al. 2004).

Tabla 1. Resumen comparativo entre las técnicas de *downscaling* estadístico y dinámico (adaptado de Fowler et al. 2007).

	<i>Downscaling</i> estadístico	<i>Downscaling</i> dinámico
Ventajas	▪ Computacionalmente económico y eficiente. ▪ Basado en procedimientos estadísticos aceptados. ▪ Fácilmente aplicable a otras regiones. ▪ Fácilmente aplicable a múltiples GCM. ▪ Utiliza directamente datos de observaciones	▪ Los resultados se basan en principios físicamente consistentes. ▪ Pueden arrojar resultados a una escala mucho más fina (espacial y temporal). ▪ Múltiples variables como resultado.
Desventajas	▪ Requiere de un periodo largo de datos observacionales para la calibración. ▪ La resolución de los resultados depende los datos predictantes (observaciones). ▪ La relación predictor-predictante puede no ser estacionaria. ▪ Las retroalimentaciones propias del sistema climático no se incluyen. ▪ La misma técnica no es aplicable a múltiples variables.	▪ Computacionalmente costoso. ▪ Depende de las condiciones de frontera adoptadas de los GCM.

El *downscaling* estadístico emerge como una opción computacionalmente más económica, en comparación con el *downscaling* dinámico; siendo aplicable de manera factible sobre los datos de GCM (ver Tabla 1). En relación a esto, se han implementado una diversidad de modelos estadísticos para la reducción de escala, desde regresiones lineales hasta modelos de redes neuronales (Goubanova et al. 2011, Gómez-Navarro et al. 2022, Baño-Medina et al. 2020), para regiones con disponibilidad de datos lo suficientemente buenos como para la calibración del modelo (Mearns et al. 2003). Sin embargo, su principal defecto es que su “suposición base” no puede verificarse; es decir, no es posible garantizar que las relaciones estadísticas obtenidas durante el periodo de entrenamiento sigan siendo válidas bajo los diversos escenarios de climas futuros. (Wilby et al. 2004, Mearns et al. 2003).

Escenarios de cambio climático

Más allá de las fluctuaciones climáticas naturales, el cambio climático provocado por el ser humano debido al aumento de las concentraciones de gases de efecto invernadero (GEI) ha perjudicado a los seres humanos y al medio ambiente. Según el último reporte (AR6) del Panel Intergubernamental sobre el Cambio Climático (IPCC), el aumento de los fenómenos meteorológicos y climáticos extremos ha tenido un efecto irreversible tanto en los sistemas humanos como en los medioambientales.

Asimismo, se prevé que el calentamiento global que alcance 1,5 °C en un futuro próximo (a mediados del siglo XXI) tenga efectos significativos, generalizados y

permanentes en las personas y los ecosistemas. Aunque no podrían eliminarlos por completo, las medidas de mitigación inmediatas que mantengan el calentamiento global en torno a 1,5 °C reducirían significativamente las pérdidas y los costes estimados asociados al cambio climático en comparación con niveles de calentamiento más elevados (IPCC 2022).

Los escenarios de cambio climático son un componente crucial para la investigación, ya que describen posibles desarrollos futuros de diversos factores antropogénicos (como aerosoles, uso de la tierra, gases de efecto invernadero y gases químicamente reactivos) que son coherentes con posibles desarrollos socioeconómicos. En virtud de diversas proyecciones futuras, estos permiten a los investigadores evaluar posibles alteraciones en el sistema climático, sus efectos en los ecosistemas y la sociedad, y la eficacia de las opciones de respuesta, como la adaptación y la mitigación. (O'Neill et al. 2016, Riahi et al. 2017).

Recientemente, el Proyecto de Intercomparación de Modelos de Escenarios (ScenarioMIP) ha sido la principal actividad dentro de la Fase 6 del Proyecto de Intercomparación de Modelos Acoplados (CMIP6), teniendo como objetivo actualizar los escenarios RCP (rutas representativas de concentración, basadas en el aumento del forzamiento radiativo para 2100) 2.6, 4.5, 6.0 y 8.5 del CMIP5; y cubrir las brechas generadas por las vías de forzamiento no abordadas con los RCP: las que alcanzarían un aumento de 7.0, 3.4 y menor a 2.6 W m⁻² para 2100 (Riahi et al. 2017).

Como resultado, el ScenariMIP ha elaborado proyecciones climáticas multimodelo basadas en trayectorias de desarrollo social futuras, “trayectorias socioeconómicas compartidas” (SSP) y los RCP, y que se basan en un nuevo conjunto de escenarios de emisiones y uso del suelo (Riahi et al. 2017) Además de utilizar modelos climáticos globales actualizados, las proyecciones climáticas del CMIP6 se basan en escenarios SSP y datos actualizados sobre las tendencias actuales de las emisiones de GEI, lo que las diferencia de las estimaciones del CMIP5 (O’Neill et al. 2016).

Los SSP describen las diferentes evoluciones sociales futuras en ausencia de cambio climático o políticas climáticas. El escenario SSP1, “Sostenibilidad: Tomando el Camino Verde”, y el escenario SSP3, “Rivalidad regional: un camino rocoso”, describen futuros con problemas de adaptación y mitigación bajos y altos respectivamente. Además, se crean dos “casos asimétricos”, uno de los cuales combina bajos obstáculos de adaptación con altos problemas de mitigación (escenario SSP5, “Desarrollo a base de combustibles fósiles: tomando la carretera”), y el otro en el que ocurre lo contrario (escenario SSP4, “Desigualdad: un camino dividido”). Por último, un escenario central (SSP2, “A mitad del camino”) donde se describe un futuro con problemas de adaptación y mitigación intermedios (Riahi et al. 2017).

Con importantes gastos en salud y educación, una economía mundial en auge e instituciones para mejorar el capital social y humano, los escenarios SSP1 y SSP5 pronostican tendencias comparativamente positivas para el desarrollo humano. Sin embargo, en el escenario SSP1, el mundo avanza gradualmente (pero generalizada)

hacia una senda más sostenible, haciendo hincapié en un desarrollo más equitativo que respeta los límites medioambientales reconocidos, mientras que el escenario SSP5 prevé una economía basada en el uso de combustibles fósiles.

Los escenarios SSP3 y SSP4 pronostican patrones de desarrollo aún más negativos ante los importantes obstáculos para la adaptación, entre los que se incluyen el rápido crecimiento demográfico, el aumento de la desigualdad y la limitada inversión en salud y educación. En el escenario SSP3 los países se ven obligados a centrarse más en cuestiones de seguridad nacional y regional debido a las preocupaciones sobre la seguridad y la competitividad, así como a los conflictos regionales. Sin embargo, en el SSP4 predominan las inversiones desiguales en capital humano, junto con el aumento de las diferencias en el poder político y económico, lo que crea una importante desigualdad dentro de las naciones y entre ellas, así como dentro de las sociedades, especialmente vulnerables a los efectos del cambio climático.

Por último, el SSP2 imagina un escenario intermedio en el que las tendencias técnicas, sociales y económicas no se alejan sustancialmente de las tendencias pasadas. Aunque el progreso es lento, los organismos nacionales e internacionales se esfuerzan por alcanzar los objetivos de desarrollo sostenible. Sigue siendo difícil reducir la sensibilidad a los cambios sociales y medioambientales, y la disparidad de ingresos se mantiene igual o solo mejora gradualmente (Riahi et al. 2017).

La combinación de los SSP y RCP forman una matriz de posibles escenarios integrados de cambio climático y social futuro (Figura 4). Cada fila contiene

simulaciones de modelos climáticos basadas en una vía de forzamiento que puede usarse en combinación con las condiciones sociales descritas por cualquiera de los SSP, siempre que las emisiones de SSP sean coherentes con esa vía de forzamiento. Hacemos referencia a estos escenarios integrados como SSPx-y, donde x es el SSP específico e y representa el RCP definido por su nivel de forzamiento radiativo promedio global a largo plazo (O'Neill et al. 2016).




Figura 4. Matriz de escenarios SSP-RCP. Cada celda de la matriz indica la combinación entre una vía de desarrollo socioeconómico (SSP) y una vía de forzamiento particular (RCP). Las celdas de color azul oscuro indican escenarios considerados de mayor relevancia para la investigación (*Tier 1*); las celdas de color azul claro indican escenarios adicionales de interés (*Tier 2*). Los RCP del CMIP5, que se desarrollaron a partir de escenarios socioeconómicos anteriores en lugar de SSP, se muestran a modo de comparación (celdas verdes). Las celdas blancas indican escenarios de menor interés y/o aún en desarrollo (O'Neill et al. 2016).

Según su prioridad, los escenarios SSP-RCP se dividen en dos niveles. (*Tier-1* y *Tier-2*; Figura 3). El nivel 1 (*Tier-1*) es el experimento central, incluyendo los escenarios SSP1-2.6 (que actualiza RCP2.6), SSP2-4.5 (que actualiza RCP4.5), SSP3-7.0 (que llena el vacío de emisiones de combustibles fósiles no mitigadas entre el extremo medio a alto), y SSP5-8.5 (que actualiza RCP8.5) (Burke et al. 2020, O'Neill et al. 2016).

Estos cuatro escenarios SSP-RCP se emplean actualmente con frecuencia en estudios sobre el cambio climático (Burke et al. 2020, Fan et al. 2021, Zhang et al. 2022), y son descritos por O'Neill et al. (2016) de la siguiente manera:

- I. **SSP1-2.6:** El RCP2.6 se actualiza en este escenario, que es el extremo inferior del rango de posibles trayectorias de forzamiento. Para 2100, se prevé que se genere un calentamiento medio multimodelo inferior a 2 °C. El cambio significativo en el uso de la tierra del SSP1 (concretamente, el aumento de la cobertura forestal mundial) motivó su selección. La combinación de baja vulnerabilidad, pocos problemas de mitigación y una señal impulsora débil hace que este escenario sea relevante.
- II. **SSP2-4.5:** Este escenario actualiza la ruta RCP4.5 y refleja el punto medio del espectro de las futuras trayectorias de forzamiento. Además de ser un escenario que combina una vulnerabilidad social intermedia con un nivel de forzamiento intermedio, se seleccionó el SSP2 para su investigación porque sus rutas de uso de la tierra y aerosoles no son tan drásticas como las de otros escenarios SSP.

- III. **SSP3-7.0:** Este escenario representa el extremo medio-alto del espectro de posibles trayectorias. Muestra cambios significativos en el uso de la tierra, incluida una reducción de la cobertura forestal mundial, así como altas emisiones de forzamientos climáticos a corto plazo. Además, esta trayectoria de forzamiento y el SSP3 son relevantes dado que combinan un aumento del forzamiento razonablemente fuerte (7,0) con un nivel bastante alto de vulnerabilidad social (SSP3).
- IV. **SSP5-8.5:** Este escenario actualiza la ruta RCP8.5 y refleja el límite superior del espectro de las futuras trayectorias de forzamiento. El SSP5 es el único con emisiones lo suficientemente altas como para provocar un aumento del forzamiento radiativo de 8.5 W m^{-2} para 2100.

Por último, cabe mencionar algunos escenarios de nivel 2 (*Tier-2*), entre ellos el SSP4-3.4, que combina una trayectoria de forzamiento bajo con retos de mitigación bajos; el SSP4-6.0, que actualiza la trayectoria RCP6.0; el SSP5-3.4, donde se sigue la línea del escenario SSP5-8.5 hasta mediados de siglo, para posteriormente dar paso a una estrategia agresiva de mitigación; o el SSP1-1.9, que tiene una alta probabilidad de mantenerse por debajo de $1.5 \text{ }^{\circ}\text{C}$ en 2100, según el acuerdo de París (O'Neill et al. 2016, Riahi et al. 2017).

***Deep learning* y redes neuronales convolucionales**

Los modelos de aprendizaje profundo ("*deep learning*"), inicialmente inspirados por la neurobiología, se han convertido en una eficaz herramienta de aprendizaje automático e inteligencia artificial (Kriegeskorte & Golan 2019).

La forma más básica de red neuronal se conoce como “perceptrón”, donde se reciben entradas $x_1, \dots, x_n \in \mathbb{R}$, y se arroja una salida y en base a ciertos pesos $w_1, \dots, w_n \in \mathbb{R}$ y una función de activación f no lineal (e.g. sigmoidal). Esta estructura se muestra en la Figura 5a y se expresa matemáticamente como:

$$y = f\left(\sum_{j=1}^n w_j x_j - b\right),$$

donde b es la unidad de sesgo asociado al modelo (Alpaydin 2020).

Independientemente de la función de activación que se tenga en cuenta, una sola neurona solo puede alcanzar un grado muy limitado de no linealidad. Con el fin de mejorar la adaptabilidad del modelo, las neuronas se organizan en estructuras complejas que especifican la topología o arquitectura de la red. Aunque, inicialmente se buscó solo aumentar el número de neuronas, la construcción de una estructura multicapa produjo resultados superiores, dando lugar al aprendizaje profundo o *deep learning*, donde la “profundidad” de la red neuronal viene determinada por el número de capas que contiene.

La estructura más común que se encuentra en la literatura es la “red neuronal densa” (Figura 5b), en la que las neuronas se organizan en tres o más capas completamente conectadas (Goodfellow et al. 2016). Aunque en un inicio las ventajas de las redes de arquitectura profunda fueron teóricamente comprendidas, en la práctica esta herramienta no alcanzó su máximo potencial de manera inmediata. Esto debido, principalmente, a la limitada potencia informática y a la escasez de datos disponibles para el aprendizaje. Las técnicas superficiales (poco profundas) de

aprendizaje automático, como las *support vector machine*, funcionaron mejor en la práctica y se sometieron a un análisis matemático más riguroso (Kriegeskorte & Golan 2019). El principal cambio en las últimas dos décadas fueron los avances en la informática, contando hoy en día con procesadores en paralelo y servidores en la nube. Además, se dispone de conjuntos de datos mucho más grandes y a escala web, de gran utilidad durante la etapa de entrenamiento. Esto ha impulsado el reciente éxito del *deep learning*, siendo aplicado en diversas áreas, desde el reconocimiento facial hasta la realización de actividades lúdicas como jugar *Go* (Alpaydin 2020).




Figura 5. Diagrama de (a) un modelo de una sola neurona (perceptrón), junto con (b) una topología de red neuronal densa.

Las redes neuronales convolucionales (CNN), por otro lado, son un tipo de *deep learning* que se centra en el manejo de datos estructurados localmente. Por ejemplo, en el campo del reconocimiento de imágenes sabemos que los píxeles cercanos están correlacionados y existen características locales como bordes o esquinas. Sin embargo, la manipulación de datos bidimensionales (imágenes) no es el único uso que se le da. La localidad en el reconocimiento del sonido (onda) se encuentra en el tiempo y las entradas cercanas en el tiempo pueden agruparse como estructuras base del habla; al combinar estas estructuras se pueden definir expresiones más largas, como fonemas del habla (Alpaydin 2020, Goodfellow et al. 2016).




Figura 6. Esquema básico de una CNN. Se muestra una sola capa que aplica un *kernel* de entrada seguido de una función de activación y una operación de agrupación o *max pooling* (adaptado de Georgiou et al. 2020).

El nombre “red neuronal convolucional” hace referencia al uso de la operación matemática llamada “convolución” (Goodfellow et al. 2016), usada frecuentemente para el procesamiento y descomposición de señales. A diferencia de las redes densas estándar, las CNNs aprenden características espaciales de los datos para posteriormente alimentar una red densa. Capa a capa se realizan convoluciones

sobre los datos de entrada utilizando núcleos o “*kernels*” tridimensionales (variable, latitud y longitud). Debido a estas operaciones convolucionales, las capas consisten en mapas de características (“*feature maps*”), que pueden interpretarse como la representación espacial de la característica aprendida por el *kernel* (Figura 6). Este tipo de redes se aplicaron inicialmente en el reconocimiento de dígitos escritos a mano, aunque su uso se ha ampliado al reconocimiento de cualquier tipo patrones en datos con configuración espacial (Georgiou et al. 2020). Luego de la etapa de convolución, el mapa de características pasa por la función de activación; además, se suele acompañar este tipo de redes con una operación extra llamada “*max pooling*” (parte azul en Figura 6), con el objetivo de reducir el exceso de información captado en las etapas previas.

ANTECEDENTES

La costa peruana es una de las zonas de pesca más productivas de los mares del mundo. Esta elevada productividad es consecuencia del afloramiento de aguas profundas frías y ricas en nutrientes. Además, la estructura del viento costero es el factor principal que gobierna la dinámica del afloramiento, a través de procesos como el transporte de Ekman, relacionado con la intensidad del viento a lo largo de la costa, y el bombeo de Ekman, relacionado con la estructura espacial del viento. En este sentido, estudiar la variabilidad espacio-temporal de los vientos favorables al afloramiento en el ecosistema peruano resulta crucial desde una perspectiva científica y económica.

En el contexto de cambio climático, Bakun (1990) ha sugerido que el calentamiento global podría repercutir en un incremento del contraste térmico tierra-mar, y este a su vez en un mayor gradiente de presión transversal a la costa (baja presión sobre la tierra y la alta presión sobre el mar), lo que finalmente impulsaría una intensificación de los vientos *alongshore* y del transporte de Ekman. Los modelos de circulación globales acoplados atmósfera-océano (AOGCM) han proporcionado información valiosa sobre cómo el cambio climático está afectando al SAP. En su análisis de los cambios del viento de afloramiento, la temperatura y la presión de 21 AOGCM del CMIP5, Rykaczewski et al. (2015) mostró que, si bien se produjo un aumento en la diferencia térmica entre la tierra y el mar, no hay pruebas de un aumento consistente en los gradientes de presión. Esto sugiere que los procesos que rigen las variaciones en los vientos de afloramiento son más complejos que los sugeridos por Bakun (1990).

En cuanto al sistema de alta presión del Pacífico sur, forzante dominante de los vientos superficiales regionales, los resultados de estudios previos son bastante robustos. Se prevé que el Anticiclón del Pacífico Sur (APS) se intensifique y desplace su centro hacia el sur, según la mayoría de los AOGCM del Panel Intergubernamental sobre el Cambio Climático (IPCC) (e.g. Garreaud & Falvey 2009, Rykaczewski et al. 2015). Esto podría provocar una reducción en la intensidad del viento costero y del bombeo de Ekman frente a las costas de Perú. (Belmadani et al. 2014). En ese sentido, Camarena (2022) evaluó los cambios en la variabilidad interdiaria del viento en el SAP para 12 modelos globales del CMIP6 bajo los escenarios futuros SSP5-8.5 (pesimista) y SSP1-2.6 (optimista). Para el escenario pesimista se mostró un incremento de 5-21 % en la ocurrencia de días de viento débil (por debajo del percentil 25), y una disminución de 5-15 % en la ocurrencia de días de viento fuerte (por encima del percentil 75). Además, se encontró que existe una probabilidad de 30-40 % que un día de viento débil (o fuerte) ocurra forzado por la disminución (o incremento) del gradiente norte-sur de la TSM a lo largo de la costa. No obstante, hay que tener en cuenta que los AOGCM no pueden usarse directamente para evaluar el impacto del calentamiento global sobre los vientos y el transporte y bombeo de Ekman frente al Perú, ya que su gruesa resolución espacial (entre 100 y 400 km) hace imposible captar de manera precisa la influencia adicional de factores locales involucrados en la dinámica océano-atmósfera. En este contexto, diferentes autores han empleado el *downscaling* con el propósito de reducir las proyecciones de los vientos superficiales a una escala regional, a partir de AOGCM.

Goubanova et al. (2011) realizó un *downscaling* estadístico de vientos superficiales a partir del modelo global IPSL-CM4 (~300 km de resolución) y de observaciones del satélite QuikSCAT (~50 km), a lo largo de las costas de Perú y Chile y bajo los escenarios futuros de cambio climático de $2\times\text{CO}_2$ y $4\times\text{CO}_2$. Su modelo se basó en regresiones lineales múltiples (MLR), en el espacio de funciones ortogonales empíricas (EOF) para los predictores y predictantes. Las EOF se calcularon para las anomalías relativas al ciclo estacional medio durante el período de entrenamiento (2000-2008). Sus hallazgos coincidieron con lo proyectado por los modelos globales, especialmente en verano, mostrando vientos más fuertes frente a las costas de Chile y una disminución de la intensidad media frente a las costas de Perú debido a una intensificación moderada (no significativa) en invierno y una reducción significativa en verano.

Siguiendo esta línea de razonamiento, Goubanova & Ruiz (2010) evaluaron los efectos del cambio climático en el afloramiento impulsado por el viento frente a las costas de Perú y Chile utilizando el enfoque de reducción de escala sugerido por Goubanova et al. (2011) para un grupo de 12 modelos CMIP3 globales bajo el escenario SRES A2. Sus hallazgos fueron comparables a los de Goubanova et al. (2011) en términos de intensidad del viento. Sin embargo, Goubanova & Ruiz (2010) también analizaron el transporte de Ekman. Sus resultados mostraron un incremento de entre 10-18 % en el transporte de Ekman para Chile y de un 6 % para Perú, como consecuencia de una intensificación del ciclo estacional de afloramiento frente a la costa central de Perú y una temporada de afloramiento más prolongada frente a la costa central de Chile.

Así mismo, Belmadani et al. (2014) emplearon un modelo atmosférico global con una resolución cada vez más fina, hasta $0,5^\circ$ sobre el sistema Humboldt, forzado también por el IPSL-CM4 y bajo mismos escenarios que Goubanova et al. (2011). A diferencia de los hallazgos de Goubanova et al. (2011) y Goubanova & Ruiz (2010), que indicaban que el viento se intensificaba en invierno, los resultados en este caso demostraron un debilitamiento de los vientos costeros frente a las costas de Perú tanto en verano como en invierno. Tanto Belmadani et al. (2014) como Goubanova et al. (2011) mostraron que los vientos invernales se intensifican frente a la costa de Chile; sin embargo, Belmadani et al. (2014) evidenció que los vientos de verano disminuyen frente a la costa central de Chile, lo que contrasta con los hallazgos de Goubanova et al. (2011). Del mismo modo, se observan variaciones en el *curl* del viento a diferentes latitudes del sistema de Humboldt, con valores más débiles (y desfavorables al afloramiento generado por el bombeo de Ekman) frente a Perú y el norte de Chile, y valores más intensos (favorables al bombeo de Ekman) frente al centro-sur de Chile. En el escenario de $4\times\text{CO}_2$, estos cambios son más pronunciados (en comparación con la era preindustrial).

Chamorro et al. (2021) utilizaron el modelo atmosférico regional *Weather Research and Forecasting* (WRF) de alta resolución (~ 7 km) para reducir dinámicamente la escala de un conjunto de 31 modelos globales del CMIP5 bajo el escenario pesimista RCP8.5, con el fin de evaluar el efecto del cambio climático en los vientos ascendentes frente a las costas de Perú. Sus hallazgos mostraron que los vientos costeros se debilitaron ligeramente (0-5 %) durante el verano, mientras que durante el invierno se mostró una ligera intensificación (0-10 %). Adicionalmente, según

una investigación preliminar sobre los cambios en el gradiente norte-sur de la temperatura superficial del mar (TSM) realizada por Chamorro et al. (2021), el promedio multimodelo indicó una reducción menor ($\sim 0,2$ °C por cada 1000 km, es decir, el aumento de la SST fue algo más débil en el norte de Perú que en el sur). Además de la simulación central basada en la media multimodelo, se realizaron simulaciones experimentales utilizando tres modelos globales con gradientes de TSM positivos, (casi) nulos y negativos como forzamientos en el modelo WRF, a fin de evaluar la sensibilidad de las proyecciones de los vientos costeros al gradiente de TSM a lo largo de la costa. Los resultados demostraron lo sensibles que son las proyecciones del viento a las variaciones del gradiente de temperatura norte-sur en la costa norte y central de Perú. No se observaron variaciones entre las simulaciones experimentales y centrales en el caso del sector sur (14° - 18° S), lo que indica que los cambios en los vientos en el sur de Perú probablemente dependan más de los cambios a gran escala relacionados con el APS y se vean menos afectados por los cambios en la TSM.

Una alternativa al *downscaling* dinámico y al *downscaling* estadístico basado en regresiones lineales (e.g. Goubanova et al. 2011) es el empleo de métodos como el aprendizaje profundo (*deep learning*). Según Baño-Medina et al. (2020), las redes neuronales convolucionales (CNN) destacan entre las topologías de redes neuronales debido a su excepcional capacidad para "aprender" las propiedades espaciales de los datos. En la investigación climática, esta característica es útil para el manejo de datos con variables espacio-temporales.

En su análisis de las técnicas basadas en *deep learning* para el *downscaling* estadístico de variables climáticas, Baño-Medina et al. (2020) evaluaron la capacidad de los distintos componentes de la arquitectura de una CNN para replicar la temperatura y las precipitaciones en Europa y compararon estos modelos con otros que utilizaban regresiones lineales múltiples. Los predictores incluían datos de variables ambientales con resolución de 2° del reanálisis ERA-Interim. Además, se empleó un predictor basado en el conjunto de datos de observación E-OBS v14 (resolución de 0,5°). Baño-Medina et al. (2020) utilizaron criterios que incluían el sesgo en los valores medios de temperatura y precipitación, así como el sesgo en los valores extremos representados por los percentiles P02 y P98 de cada una de estas variables, para evaluar en qué medida las técnicas de reducción de escala reproducían los datos observacionales. Además, se evaluaron las correlaciones entre los datos observados y los previstos, así como el error cuadrático medio (RMSE). Además, Baño-Medina et al. (2020) también introdujeron el paquete de R *downscaleR.keras*, permitiendo el uso de las librerías de *machine learning* Keras y TensorFlow en *climate4R* (Iturbide et al. 2019), un entorno abierto orientado a servicios climáticos basado en R.

Partiendo del trabajo de Baño-Medina et al. (2020), Quesada-Chacón et al. (2022) pudo utilizar CNN para reducir los datos de precipitación diaria a una resolución de 1 km utilizando un subconjunto del conjunto de datos en cuadrículas ReKIS como predictantes. El conjunto de datos en cuadrículas ReKIS utiliza datos de estaciones propiedad del Servicio Meteorológico Alemán (Deutscher Wetterdienst, DWD) y el Instituto Hidrometeorológico Checo (CHMI). Sin embargo, hay una escasez de

datos de alta resolución para otras variables climáticas y otros lugares. Esto ha llevado al uso reciente de datos de alta resolución de modelos regionales (*downscaling* dinámico) en el entrenamiento de redes neuronales para el *downscaling* estadístico (e.g. Gómez-Navarro et al. 2022, Tran Anh & Taniguchi 2018). Esta variante es denominada como “*downscaling* híbrido” y permite combinar las ventajas de ambos enfoques de *downscaling* (ver Tabla 1); sin embargo, su uso sigue siendo cuestionado debido a la ausencia de datos observacionales durante la fase de entrenamiento.

PLANTEAMIENTO DEL PROBLEMA

Tabla 2. Comparación del cambio en el viento costero frente al Perú a partir de las proyecciones de modelos climáticos globales bajo el escenario pesimista (extraído de Camarena 2022).

Referencia	Resolución	Periodo		Cambios del viento		
		Histórico	Futuro	Media anual	Verano	Invierno
Goubanova et al. (2011)	50 km	1970 - 1999	2120 - 2149	↓ 5-10 %	↓ 5-10 %	–
Belmadani et al. (2014)	50 km	1979 - 1999	2079 - 2099	↓ 10-20 %	↓ 20-30 %	↓ 5-10 %
Chamorro et al. (2021)	7 km	1994 - 2003	2086 - 2095	–	↓ 0-5 %	↑ 5-10 %

Si bien existe cierto consenso en que los vientos costeros tenderían a debilitarse en el verano bajo escenarios de cambio climático pesimistas, persiste una alta incertidumbre debido a que muchas proyecciones se han basado en un único modelo climático global, en la media multimodelo, en un solo escenario de emisiones (típicamente pesimista), o han considerado periodos de evaluación relativamente

cortos debido a limitaciones computacionales (Tabla 2). En ese contexto, resulta necesario reducir la incertidumbre y mejorar la robustez de las proyecciones del viento costero mediante el uso de múltiples modelos climáticos globales y la implementación de técnicas de regionalización eficientes y de bajo costo computacional.

El presente trabajo de tesis de maestría evalúa las proyecciones futuras del viento costero sobre el sistema de afloramiento peruano, utilizando técnicas de *downscaling* estadístico basadas en redes neuronales convolucionales (CNN), aplicadas a múltiples modelos climáticos globales del proyecto CMIP6 bajo el escenario SSP5-8.5. A partir de estas proyecciones regionalizadas de viento a alta resolución, se analiza el impacto del cambio climático sobre el transporte y el bombeo de Ekman, dos mecanismos clave del afloramiento. Este enfoque permite evaluar la robustez (el acuerdo intermodelo) de los cambios proyectados en distintos horizontes temporales.

PREGUNTA CENTRAL

En este contexto, la pregunta científica es:

¿Cuáles son los posibles efectos del cambio climático sobre el viento costero, así como sobre el transporte y bombeo de Ekman en el sistema de afloramiento peruano para el siglo XXI, y cuál es la incertidumbre de estas proyecciones?

HIPÓTESIS

Ante un escenario de cambio climático pesimista se espera una proyección robusta del debilitamiento del viento y del transporte y bombeo de Ekman frente a Perú, sobre las regiones dominadas por la circulación a gran escala, pero baja robustez sobre las regiones dominadas por factores locales.

JUSTIFICACIÓN

La evaluación del impacto del cambio climático sobre el sistema de afloramiento peruano requiere proyecciones regionales del viento costero a alta resolución espacial. Sin embargo, los modelos climáticos globales (GCM) tienen una resolución gruesa, y las simulaciones con modelos regionales dinámicos (RCM) suelen implicar altos costos computacionales. En este sentido, el uso de técnicas de *downscaling* estadístico basadas en redes neuronales convolucionales (CNN) significa una alternativa eficiente, que permite integrar múltiples variables atmosféricas y oceánicas como predictores, y capturar las complejas relaciones espaciales entre estas y el viento costero.

El uso de redes neuronales convolucionales para el *downscaling* de vientos superficiales es relevante dado que permiten el uso estructurado de múltiples variables climáticas predictoras (ver Sección 3.2) durante la etapa de entrenamiento, haciendo factible que el modelo reconozca o aprenda relaciones espaciales complejas entre el predictor y el predictante. Este proceso representa un ahorro computacional importante en comparación con la resolución numérica de ecuaciones diferenciales característicos de modelos dinámicos regionales.

Este trabajo también resulta importante desde el punto de vista cognitivo, dado que la implementación de un modelo estadístico de bajo costo computacional para la generación de datos de viento a alta resolución, permiten su incorporación al desarrollo de escenarios oceanográficos futuros de cambio climático. Así mismo, esta herramienta también es aplicable a otras áreas como los estudios de reconstrucción paleoceanográfica sobre el sistema de afloramiento peruano.

Por otro lado, este enfoque multimodelo permite analizar la robustez de las proyecciones futuras, entendida como la consistencia entre modelos, y explorar la incertidumbre asociada a los cambios en la intensidad y estructura del viento costero. Las proyecciones resultantes permiten además estimar el impacto esperado sobre el transporte y bombeo de Ekman, mecanismos clave en el afloramiento.

En cuanto a la relevancia socioeconómica para las regiones aledañas al sistema de afloramiento peruano, la disponibilidad de simulaciones climáticas de alta resolución para las próximas décadas es fundamental para el desarrollo de políticas de sostenibilidad y planes de adaptación y mitigación ante el cambio climático.

Finalmente, el presente trabajo fortalece la integración e interacción entre inteligencia artificial y ciencia del clima, demostrando el potencial de los modelos de aprendizaje profundo para generar datos regionales físicamente consistentes y aptos para ser usados en simulaciones oceanográficas y otros estudios interdisciplinarios.

2. OBJETIVOS

2.1. GENERAL

Evaluar los posibles efectos del cambio climático sobre el viento costero y sobre el transporte y bombeo de Ekman en el sistema de afloramiento peruano bajo el escenario SSP5-8.5 del CMIP6, mediante proyecciones regionalizadas del viento obtenidas a través la implementación del *downscaling* estadístico del viento usando un modelo de redes neuronales convolucionales, con el fin de analizar la consistencia intermodelo y la robustez de los cambios proyectados.

2.2. ESPECÍFICOS

- 2.2.1. Implementar y evaluar un modelo de redes neuronales para reducir de escala (*downscaling*) los datos de viento diario sobre la superficie del mar peruano de modelos globales del CMIP6, usando datos de observaciones satelitales en el periodo 2008-2022.
- 2.2.2. Aplicar el modelo estadístico de redes neuronales de *downscaling* del viento a 12 modelos del CMIP6 y bajo el escenario de cambio climático SSP5-8.5, para distintos horizontes temporales del siglo XXI: periodo histórico (1995-2014), futuro cercano (2021–2040), intermedio (2046–2065) y lejano (2081–2100).
- 2.2.3. Evaluar las variaciones de la intensidad del viento y su rotacional en el sistema de afloramiento peruano bajo el escenario de cambio climático SSP5-8.5, utilizando las proyecciones a alta resolución generadas por el modelo de redes neuronales.

2.2.4. Evaluar el impacto del cambio climático sobre el transporte y bombeo de Ekman en el sistema de afloramiento peruano bajo el escenario de cambio climático SSP5-8.5, considerando las modificaciones en la intensidad y rotacional del viento derivadas de los datos del modelo de redes neuronales.

3. METODOLOGÍA

3.1. DISEÑO EXPERIMENTAL

La presente tesis de maestría consiste en modelamiento estadístico, basándose en datos observados y de modelos numéricos, e implementando una herramienta de reducción de escala apoyado en el uso de redes neuronales convolucionales. Nos enfocamos en analizar el impacto del cambio climático sobre el viento costero y sobre el transporte y bombeo de Ekman.

Se implementó un modelo estadístico basado en el uso de redes neuronales con la finalidad encontrar relaciones estadísticas (o funciones de transferencia) entre datos de un reanálisis a baja resolución y datos de vientos de observaciones satelitales a alta resolución. La función de transferencia encontrada se validó y aplicó sobre datos de múltiples modelos del CMIP6, obteniendo proyecciones futuras de vientos a alta resolución bajo el escenario SSP5-8.5 de cambio climático (Figura 7). Los datos resultantes permitieron estimar de mejor manera los cambios futuros en el transporte y bombeo de Ekman, así como evaluar la robustez (coincidencia en los resultados por parte del 66.6 %, o más, de los modelos globales) de las proyecciones futuras respecto a estas variables.

El dominio espacial de estudio se extiende entre 7° N-24° S y 98°-67° W, considerando tanto la parte oceánica frente al Perú como la parte continental, incluyendo la cordillera de los Andes (d02 en Figura 8). Un dominio de mayor extensión (comprendido entre 128°-65° W y 14° N-49° S, d01 en Figura 8) se consideró para los datos de baja resolución durante el entrenamiento de la red

neuronal, a fin de que el modelo tome en cuenta factores influyentes como la dinámica en el ecuador, la interacción tierra-mar o el sistema de alta presión del Pacífico Sur.




Figura 7. Esquematización del *downscaling* estadístico. Los datos predictores y predictantes durante el periodo histórico (azul) se emplean para la etapa de entrenamiento (verde) de la red neuronal convolucional. La relación estadística aprendida se aplica a un periodo futuro más extenso (naranja).

Los datos se recopilaron teniendo en cuenta los siguientes periodos:

- **Periodo de entrenamiento:** Entre 2008 y 2019. Los modelos estadísticos permitieron obtener una función de transferencia entre la información de alta y baja resolución durante este periodo.

- **Periodo de validación 1:** Entre 2020 y 2022. Se aplicó el modelo entrenado a los datos de baja resolución durante este periodo. Los resultados se compararon con datos de observaciones satelitales.
- **Periodo de validación 2:** Entre 2008 y 2011. Durante este periodo, se aplicó el modelo entrenado a datos de una base de datos (de resolución gruesa) no utilizada durante el entrenamiento. Los resultados se compararon con datos de observaciones satelitales.
- **Periodo de aplicación 1 (histórico):** Entre 1995 y 2014. Durante este periodo, se aplicó el modelo estadístico entrenado a los datos del experimento histórico de los modelos globales del CMIP6.
- **Periodo de aplicación 2 (futuro):** Entre 2015 y 2100. Durante este periodo, se aplicó el modelo estadístico de *downscaling* a los datos de los modelos globales para el escenario pesimista de cambio climático SSP5-8.5. Este segundo periodo se subdivide en: periodo futuro cercano (2021-2040), futuro intermedio (2046-2065) y futuro lejano (2081-2100).

Los periodos de entrenamiento y validación se seleccionaron considerando los periodos disponibles de las bases de datos para los predictores y predictantes (ver Sección 3.2).

Con la finalidad de evaluar la capacidad del modelo a ser aplicado a múltiples bases de datos (como lo son los diferentes modelos globales del CMIP6), la validación 2 toma como *inputs* para el modelo estadístico, datos de un producto de reanálisis no utilizado durante el entrenamiento (NCEP).




Figura 8. Dominio espacial de investigación. El dominio d01 corresponde a los predictores (entre 16° N-52° S y 131°-65° W). El dominio d02 (entre 7° N-24° S y 97°-67° W) corresponde a los predictantes.

3.2. VARIABLES DE ESTUDIO Y BASES DE DATOS

Las fuentes y tipos de datos a utilizar son los siguientes:

Reanálisis ERA5: Datos diarios utilizados como predictores (~25 km de resolución), para las variables:

- Viento zonal a 10 m (m s^{-1})
- Viento meridional a 10 m (m s^{-1})
- Temperatura a 2 m ($^{\circ}\text{C}$)
- Presión a nivel del mar (Pa).

ASCAT METOP-A: Contiene datos diarios de observaciones satelitales de alta resolución (~25 km) para las variables:

- Viento zonal sobre la superficie del mar (m s^{-1})
- Viento meridional sobre la superficie del mar (m s^{-1})

Estos datos satelitales se usaron como predictantes en el entrenamiento de las redes neuronales. Además, esta data se utiliza durante los procesos de **validación 1 y 2**, siendo comparada con los *outputs* de los modelos estadísticos de *downscaling*.

NCEP/DOE II: Datos diarios de baja resolución (~250 km), para las variables:

- Viento zonal a 10 m (m s^{-1})
- Viento meridional a 10 m (m s^{-1})
- Temperatura a 2 m ($^{\circ}\text{C}$)
- Presión a nivel del mar (Pa).

Estos datos se utilizaron para la **validación 2** como base de datos predictora alternativa y como datos de ruido en el entrenamiento de los modelos estadísticos.

CFSv2: Datos diarios (~100 km de resolución) para las variables:

- Viento zonal a 10 m (m s^{-1})
- Viento meridional a 10 m (m s^{-1})
- Temperatura a 2 m ($^{\circ}\text{C}$)
- Presión a nivel del mar (Pa).

Estos datos se utilizaron como ruido en el entrenamiento de los modelos estadísticos.

Modelos Globales: Datos diarios de 12 modelos del CMIP6 (ver Tabla 3) de baja resolución (ver Tabla 3), para las variables:

- Viento zonal a 10 m (m s^{-1})
- Viento meridional a 10 m (m s^{-1})
- Temperatura a 2 m ($^{\circ}\text{C}$)
- Presión a nivel del mar (Pa).

Se obtuvieron los datos del experimento histórico entre 1995-2014 y del escenario SSP5-8.5 entre 2015-2100 de cada modelo global, desde la interfaz de búsqueda del CMIP6 (esgf-node.llnl.gov/search/cmip6).

Tabla 3. Lista de modelos climáticos del CMIP6, validados por Camarena (2022).

<i>N</i> ^o	Modelo CMIP6	Resolución (km)	Centro de modelamiento
1	BCC-CSM2-MR	100	Beijing Climate Center (China)
2	CanESM5	500	Canadian Centre for Climate Modelling and Analysis, Environment and Climate Change (Canada)
3	CMCC-CM2-SR5	100	Fondazione Centro Euro-Mediterraneo sui Cambiamenti Climatici (Italy)
4	CNRM-ESM2-1	250	Centre National de Recherches Meteorologiques (France)
5	GFDL-CM4	100	National Oceanic and Atmospheric Administration, Geophysical Fluid Dynamics Laboratory (USA)
6	GFDL-ESM4	100	National Oceanic and Atmospheric Administration, Geophysical Fluid Dynamics Laboratory (USA)
7	IPSL-CM6A-LR	250	Institut Pierre Simon Laplace (France)
8	MIROC6	250	MIROC (Japan)
9	MPI-ESM1-2-HR	100	Max Planck Institute for Meteorology (Germany)
10	MPI-ESM1-2-LR	250	Max Planck Institute for Meteorology (Germany)
11	MRI-ESM2-0	100	Meteorological Research Institute (Japan)
12	NESM3	250	Nanjing University of Information Science and Technology (China)

La Tabla 3 enlista los modelos globales del CMIP6 catalogados como regulares y buenos según Camarena (2022), basándose en índices de “habilidad climática” y de “variabilidad del modelo”. Para una aplicación adecuada de la función de transferencia (ver Sección 3.4.a), realizamos una interpolación espacial (a una grilla común de ~100 km) sobre todos los modelos globales.

3.3. **DESCRIPCIÓN DE LOS MODELOS DE RED NEURONAL**

La implementación se realizó en lenguaje de programación R, usando el paquete `downscaleR.keras`, que permite el uso de las librerías de *machine learning*: Keras y TensorFlow (Iturbide et al. 2019). Los modelos estadísticos descritos a continuación se implementaron para cada una de las componentes (zonal y meridional) del viento y en base a variaciones de los modelos presentados por Baño-Medina et al. (2020).

Modelos de redes neuronales convolucionales (CNN)


La estructura fundamenta de una red neuronal se basa en redes compuestas por múltiples capas de neuronas completamente conectadas entre capas consecutivas, desde la entrada hasta la salida (redes “densas”).

En contraste con las redes densas estándar (cuya entrada son los datos de variables predictoras sin procesar), los modelos CNN se caracterizan por la aplicación de *kernels* (o núcleos) 3-D (variable, latitud y longitud) a lo largo de la matriz de datos. El uso de estos *kernels* en cada capa convolucional permite que la red neuronal

aprenda características espaciales de los datos de entrada (predictores) relevantes para el objetivo del modelo a entrenar (*downscaling*).

Implementamos 2 modelos CNN, diferentes en su arquitectura, para reproducir las componentes zonal y meridional del viento superficial frente a Perú (ver Tabla 4). El modelo CNN 1 utiliza una arquitectura con 100, 50, 25 y 10 *kernels* en sus capas convolucionales (Figura 9a) para ambas componentes del viento. Por su parte, el modelo CNN 2 utiliza una arquitectura con 64, 32 y 16 *kernels* (Figura 9b) para ambas componentes.

(a) CNN 1: 100-50-25-10



(b) CNN 2: 64-32-16




Figura 9. Arquitecturas de los modelos basados en redes neuronales convolucionales (CNN 1 y CNN 2) utilizadas para el *downscaling* estadístico.

La dimensión de la matriz de datos de entrada es de 64^2 ($\times 4$ variables predictoras). En cada capa convolucional la operación convolución reduce la dimensión de la matriz de datos en 2 unidades (en filas y columnas), logrando dimensiones finales de 56^2 y 58^2 para las arquitecturas CNN 1 y CNN 2 respectivamente. Se utilizó la función *Leaky ReLu* (con pendiente $\alpha = 0.3$) como función de activación (flechas azules en la Figura 9). Las salidas de la última capa convolucional son vectorizadas (*flatten*, flecha amarilla en la Figura 9) y posteriormente pasan por una capa densa totalmente conectada (*dense*, flecha negra en la Figura 9) hasta alcanzar el tamaño de los datos (también vectorizados) del predictante.

Tabla 4. Arquitectura de las CNNs empleadas. *input* y *output* son las capas de entrada y salida, respectivamente. Los números en negrita indican la cantidad de neuronas en cada capa convolucional oculta. Los símbolos ‘-’ y ‘-’ denotan las conexiones convolucionales y densas, respectivamente. Adaptado de Baño-Medina et al. (2020).

modelo	Arquitectura U-wind	Arquitectura V-wind
CNN 1	<i>input-100-50-25-10-output</i>	<i>input-100-50-25-10-output</i>
CNN 2	<i>input-64-32-16-output</i>	<i>input-64-32-16-output</i>

Modelos *Coding-Decoding* (C-D)

Como indica su nomenclatura, este tipo de redes neuronales tiene la particularidad de contar con dos etapas o bloques: *coding* y *decoding*. Los detalles de la estructura utilizada para implementar nuestro modelo (para ambas componentes de viento) y sus operaciones internas se muestran en la Figura 10.

La arquitectura C-D propuesta utiliza funciones de activación *Leaky ReLU* (con $\alpha = 0.3$, flechas azules) entre sus capas ocultas y la salida de la última capa es vectorizada (flecha amarilla) y ajustada mediante una capa densa (flecha negra).

Dentro del bloque “*coding*”, la operación de “*max pooling*” (flechas rojas en la Figura 10) reduce la dimensión de la matriz a la mitad (tanto en filas como en columnas); mientras que dentro del bloque “*decoding*” la operación “convolución transpuesta” (flechas verdes en la Figura 10) realiza el proceso contrario, duplicando la dimensión de la matriz entrante (tanto en filas como en columnas). Se cuenta con cinco operaciones *max pooling*, llegando a reducir los datos de entrada hasta bloques 2×2 (Figura 10).




Figura 10. Arquitectura del modelo C-D para el *downscaling* estadístico de las componentes del viento superficial.

3.4. PROCEDIMIENTOS Y MÉTODOS

A continuación, se detallan los principales procedimientos y métodos teniendo en cuenta los objetivos específicos.

a. Implementación y aplicación del modelo de redes neuronales para el *downscaling* de vientos

Los modelos estadísticos de redes neuronales descritos en la sección 3.3 se entrenaron para cada componente del viento, utilizando los datos del reanálisis ERA5 (~25 km resolución) como predictores y los datos de observaciones satelitales ASCAT (~25 km de resolución) como predictantes.




Figura 11. Diagrama de los procedimientos para el entrenamiento, validación y aplicación de los modelos de redes neuronales (adaptado de Baño-Medina et al. 2022). El símbolo “*” en los GCMs en la zona de *downscaling* (roja) indica la remoción de la tendencia para los modelos globales.

Con el fin de aplicar los modelos obtenidos a múltiples GCMs, y dado que la mayoría de simulaciones globales del CMIP6 se encuentran disponibles a resoluciones cercanas a los 100 km (ver Tabla 3); los datos del reanálisis ERA5 se interpolaron bilinealmente (ver Sección 3.4.b) a una grilla común de 100 km (ver zona verde en Figura 11). Luego de la interpolación, los datos se recortaron según el dominio espacial del predictor (d01 en Figura 8), resultando en una matriz de dimensión final de $64 \times 64 \times 4 \times 4383$ (latitud $\times$ longitud $\times$ variable $\times$ tiempo) para la data de entrenamiento y de $64 \times 64 \times 4 \times 1096$ (latitud $\times$ longitud $\times$ variable $\times$ tiempo) para la data de validación.

Adicionalmente, el 20 % de la data predictora (ERA5) durante el entrenamiento se reemplazó (de manera aleatoria) con datos de 2 fuentes distintas (ruido, 10 % de NCEP y 10 % de CFSv2), con la finalidad de que los modelos estadísticos sean capaces de reconocer diferentes bases de datos (como lo son los modelos del CMIP6). Así, los datos de NCEP y CFSv2, utilizados como ruido, también se interpolaron bilinealmente a la grilla de 100 km y se corrigieron respecto a los datos de ERA5 (estos últimos métodos se detallan en la Sección 3.4.b como parte del procesamiento de los modelos del CMIP6).

Los datos resultantes se estandarizaron respecto al periodo de entrenamiento según:

$$x_e \leftarrow \frac{(x_e - x_{e_{clim}})}{x_{e_{sd}}}, \quad x_v \leftarrow \frac{(x_v - x_{e_{clim}})}{x_{e_{sd}}};$$

donde x_e es la data predictora correspondiente al periodo de entrenamiento (2008-2019), x_v es la data predictora correspondiente al periodo de validación (2020-

2022), $x_{e_{clim}}$ es la climatología de la data predictora en el periodo de entrenamiento, y $x_{e_{sd}}$ es la desviación estándar de la data predictora en el periodo de entrenamiento.

Para el entrenamiento de las redes neuronales se utilizó un *mini-batch* de tamaño 512, con una partición de la data del 90 % para entrenar el modelo en cada época, guardando el 10 % restante para su validación (en cada época). Se consideró un máximo de 1000 épocas para el algoritmo y una paciencia de 100 épocas. Se utilizó el optimizador *Adam*, con una tasa de aprendizaje de 0.0001 (ver Apéndice A).

El proceso de validación para las funciones de transferencia obtenidas de cada modelo estadístico se llevó a cabo de dos maneras (zona azul en Figura 11). En la primera validación se compararon los datos de las observaciones ASCAT entre 2020-2022, con las salidas de cada modelo estadístico tomando como predictor a ERA5 entre 2020-2022 (se repite la base de datos del entrenamiento, pero en un periodo diferente). Para la segunda validación, los datos de ASCAT entre 2008-2011 se compararon con las salidas de cada modelo estadístico tomando como predictor una base de datos alternativa (NCEP) entre 2008-2011.

La comparación se realizó evaluando diferentes criterios (Baño Medina et al. 2020, Quesada-Chacón et al. 2022):

- El error absoluto medio (MAE):

$$MAE = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i|,$$

- Sesgo simple en la media (Bias):

$$Bias = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i) = mean(\hat{y}) - mean(y).$$

- Sesgo simple en los percentiles 25 y 75 (P25 y P75 respectivamente):

$$Bias = P25(\hat{y}) - P25(y),$$

$$Bias = P75(\hat{y}) - P75(y);$$

donde $\hat{y}$ son las salidas del modelo estadístico, y son los datos de las observaciones ASCAT y n es la cantidad total de días durante el periodo de validación (1096 días entre 2020-2022). Estas métricas se calcularon para cada variable climática y para cada punto de grilla en el dominio predictante (d02 en Figura 8).

Además, comparamos los perfiles de ambas componentes del viento con la distancia a la costa. En base a estos criterios, se seleccionó el mejor modelo estadístico para el *downscaling* de cada componente del viento.

b. Reducción de escala de vientos para modelos del CMIP6 a partir de CNN

Esta etapa de los procedimientos se muestra esquematizada en zona roja de la Figura 11. El símbolo “*” en los GCMs indica la remoción de la tendencia para los modelos globales (proceso explicado párrafos abajo). Debido a que los modelos estadísticos fueron entrenados con datos de 100 km de resolución, fue necesaria una interpolación previa de la data de los GCM a esta grilla. Si bien la mayoría de GCM están disponibles a una resolución de 100 km, los puntos de grilla no necesariamente coinciden con los de la data predictora durante el entrenamiento. El método elegido fue la interpolación bilineal.

La **interpolación bilineal** consiste en lo siguiente: Sea (l_x, l_y) un punto de la grilla objetivo tal que $x_i \leq l_x \leq x_j \wedge y_i \leq l_y \leq y_j$, con (x_p, y_q) puntos de la grilla original para $p, q = i, j$. Sean

$$e_x = \frac{l_x - x_i}{x_j - x_i}, \quad e_y = \frac{l_y - y_i}{y_j - y_i}$$

el interpolante es:

$$(1 - e_x)(1 - e_y) \cdot z_{i,i} + (1 - e_x)(e_y) \cdot z_{i,j} + (e_x)(1 - e_y) \cdot z_{j,i} + (e_x)(e_y) \cdot z_{j,j},$$

donde $z_{p,q}$ son los valores de la variable a interpolar de la grilla original, para $p, q = i, j$.

Si alguno de los valores de $z_{p,q}$ resulta NA (not available), el interpolante se divide entre 1 menos el coeficiente que acompaña a $z_{p,q}$ en la ecuación anterior. Si más de un valor de $z_{p,q}$ de la variable a interpolar resulta NA, el interpolante se divide entre 1 menos la suma de coeficientes que acompañan a los $z_{p,q}$.

La interpolación a la grilla de 100 km se realizó diferenciando la data oceánica y continental, mediante la variable “fracción de área continental” (*sftlf*) de cada modelo global del CMIP6. Para la interpolación de datos oceánicos, se consideraron los puntos de grilla donde el porcentaje de tierra sea 0 %. La data restante se consideró como NA. Posteriormente, se aplicó la máscara tierra-mar de la grilla de 100 km para extraer los puntos ubicados en la zona oceánica (según esta grilla). Para la interpolación de datos en tierra, se consideraron los puntos donde el porcentaje de tierra sea del 100 %. La data restante se consideró como NA.

Posteriormente, se aplicó la máscara tierra-mar de la grilla de 100 km, para extraer los puntos ubicados en tierra (según esta grilla). Debido a la diferencia entre las grillas de los modelos del CMIP6 y la grilla de 100 km, algunos puntos cerca de la línea de costa no pudieron ser interpolados: el punto de grilla objetivo estuvo rodeado de cuatro puntos con valores NA según la distinción de data tierra/mar explicada en este párrafo. Para completar estos puntos se realizaron interpolaciones progresivas, incrementando (de 25 en 25) el porcentaje tierra-mar hasta completar los puntos costeros con data NA (generalmente alcanzado con el 50 %).




Figura 12. Gráficos de cajas de las variables predictoras (componentes del viento, temperatura superficial y presión superficial) entre 0 a 250 km frente a Perú, para bases de datos de múltiple resolución: ERA5 (100 km), CFS (100 km) y NCEP (250 km).

Este método de interpolación (bilineal) también se utilizó sobre los datos originales de ERA5 (pasando de la grilla original de 25 km, a una de 100 km de resolución); y sobre los datos de reanálisis NCEP y CFSv2 (data utilizada como ruido en el entrenamiento).

Además de la interpolación, se realizó una corrección de sesgo sobre la data de los modelos globales respecto a la data predictora utilizada en el entrenamiento (ERA5). Este procesamiento extra resulta necesario debido a que en algunas zonas (e.g. la franja costera) la data de resolución gruesa se distribuye de manera diferente a la data de ERA5 de 100 km de resolución (Figura 12), haciendo que los modelos estadísticos generen salidas incoherentes con lo esperado (Figura 13). Esta corrección de sesgo también se aplicó a los reanálisis (interpolados) NCEP y CFSv2, previo a su inserción como ruido durante el entrenamiento de los modelos estadísticos.

Entre los métodos de corrección de sesgo, el método propuesto es la corrección de sesgo tipo “delta” (Xu et al. 2019, Maraun 2016).

Corrección de sesgo tipo “delta”: Este tipo de corrección de sesgo consiste en restar a los datos diarios resultantes de la interpolación bilineal, la diferencia entre el mapa promedio de la interpolación y el mapa promedio del predictor ERA5 (usado en el entrenamiento). Es decir:

$$GCM_{\Delta} = GCM - (\overline{GCM} - \overline{ERA5}),$$

donde GCM son los datos del modelo global a utilizar (interpolados bilinealmente a la grilla de CFSv2), GCM_{Δ} son los datos corregidos, y $\overline{GCM}$, $\overline{ERA5}$ son los datos promedio del modelo global y ERA5. Las climatologías se tomaron entre 2008-2019 (periodo de entrenamiento) para ERA5 y 2003-2014 para los modelos globales (a pesar de que los periodos no coinciden, se considera la misma cantidad de años dentro de registro histórico poco cambiante).




Figura 13. Gráfico de cajas de las componentes (a) zonal y (d) meridional para los datos entre 2020-2022 de las observaciones ASCAT, y las salidas del modelo estadístico C-D a partir de los datos de ERA5, NCEP sin corrección de sesgo y NCEP con corrección de sesgo. Sesgo absoluto medio entre los datos de las componentes (b) zonal y (e) meridional de las salidas del modelo estadístico C-D y ASCAT. Sesgo promedio entre los datos de las componentes (c) zonal y (f) meridional de las salidas del modelo estadístico C-D y ASCAT.

Evidentemente, al aplicar este método de corrección se sesgo para periodos futuros, se asume que las diferencias entre las climatologías del predictor ERA5 y el modelo global, se conservan. De no utilizar la corrección de sesgo, los *outputs* de los modelos de redes neuronales generan vientos en un rango de intensidad no realista (Figura 13a y 13d), con un sesgo absoluto medio de entre 7 y 9 m/s respecto a los datos observacionales (Figura 13b y 13e).




Figura 14. Series de tiempo para los valores promedio anuales del viento meridional entre 0 a 200 km frente a la costa peruana, a partir del modelo global CNRM-ESM2-1 (negro), su interpolación bilineal a la grilla de 100 km (rojo), su posterior corrección de sesgo respecto a ERA5 (naranja) y la salida del modelo estadístico C-D respecto a la data interpolada y corregida (azul). Las pendientes de cada curva se muestran a su lado derecho.

Finalmente, para cada punto de grilla de la data interpolada y corregida, se extrae la tendencia de las variables predictoras utilizando una descomposición de su serie temporal mediante la regresión tipo *Loess*. Este procedimiento se realiza debido a que los modelos estadísticos se entrenan con datos predictores dentro del rango histórico, por lo que su desempeño dentro de un rango diferente como el alcanzado

durante el periodo futuro (debido a tendencias pronunciadas en cada variable predictora) no es el esperado. En ese sentido, el aplicar los modelos estadísticos a los datos de modelos globales procesados sin remover la tendencia original, podrían arrojar salidas con tendencias diferentes u opuestas (Figura 14).

Para cada modelo del CMIP6 (Tabla 3), el modelo estadístico de redes neuronales previamente seleccionado se aplica sobre: la data interpolada a la grilla de 100 km, corregida respecto al predictor ERA5 durante el periodo de entrenamiento (2008-2019) y sin tendencia.

Para reincorporar la información de la tendencia en la salida del modelo estadístico, para cada punto de la grilla original de cada modelo global se extrae y almacena la tendencia con el método *Loess*. A la data resultante (tendencia), se le aplica la máscara tierra-mar de cada modelo (*sfilf*), para obtener los valores correspondientes únicamente a la zona oceánica. Los puntos correspondientes a la zona continental se completan, por latitud, con el promedio entre los dos valores oceánicos más cercanos (de la misma latitud: uno a la izquierda y uno a la derecha) al punto con data faltante. En caso se disponga de data oceánica solamente en una dirección (izquierda o derecha) y a la misma latitud del punto faltante, se considerará este valor para completar la data. Esta data “completada latitudinalmente”, se interpola bilinealmente a la grilla de ASCAT (~25 km de resolución) para posteriormente ser añadida a las salidas del modelo estadístico, las cuales cuentan con datos únicamente en la zona oceánica.

c. Intensidad y rotacional del viento en la costa

Las salidas (componentes zonal y meridional del viento) de la aplicación del modelo estadístico de *downscaling* (basado en redes neuronales) sobre los modelos globales del CMIP6 (Tabla 3) durante los periodos histórico (1995-2014) y futuro (2015-2100) se utilizaron para obtener la información correspondiente de la intensidad y rotacional del viento.

La intensidad del viento, w_{spd} (m s^{-1}), se calcula como la magnitud del vector resultante, $\overrightarrow{w_{spd}}$, de las componentes del viento:

$$w_{spd} = |\overrightarrow{w_{spd}}| = \sqrt{u^2 + v^2},$$

donde u y v son las componentes zonal y meridional del viento (m s^{-1}) respectivamente.

La componente paralela a la costa (*alongshore*) del viento, $w_{alongshore}$ (m s^{-1}), se obtiene (por latitud) a partir de:

$$w_{alongshore} = w_{spd} \cdot \cos(\text{ang}(w_{spd}) - \theta_{ASCAT}),$$

donde $\text{ang}(w_{spd})$ es el ángulo del vector w_{spd} desde el origen (obtenido a partir de las componentes u y v), y θ_{ASCAT} es el ángulo de la línea de costa (por latitud) obtenido de la base de datos de ASCAT (misma grilla del predictante). Si bien este cálculo se puede realizar para todo el campo de vientos, nos centraremos en el análisis de la componente *alongshore* para punto oceánico más cercano a la costa (según la grilla predictante).

Derivado de la intensidad del viento, el *stress* del viento, $\vec{\tau}$ (Pa, N m⁻², kg m⁻¹ s⁻²), se determina según (Schwing et al. 1996):

$$\vec{\tau} = \rho_a C_d w_{spd} \overrightarrow{w_{spd}},$$

donde ρ_a es la densidad del aire (1.225 kg m⁻³), C_d es un coeficiente de arrastre constante (0.0013, adimensional, Mendo et al. 1987), utilizado por la NOAA.

El *curl* del *stress* del viento, $\nabla \times \vec{\tau}$ (Pa m⁻¹, N m⁻³, kg m⁻² s⁻²), se calcula como:

$$\nabla \times \vec{\tau} = \left(\frac{\partial \tau_y}{\partial x} - \frac{\partial \tau_x}{\partial y} \right).$$

Los cálculos realizados se utilizaron en la etapa de validación de los modelos estadísticos, comparándolos con los correspondientes a los datos de ASCAT. Así mismo, se comparó la capacidad de los modelos de reproducir el efecto *drop-off*.

Analizamos los cambios en la intensidad y *stress curl* del viento sobre dominio espacial de interés (ver d02 en Figura 8), así como los cambios en cada una de las componentes del viento (zonal y meridional).

Adicionalmente realizamos un análisis latitudinal de la intensidad y el *stress curl* del viento, evaluando sus cambios totales y mensuales frente a la costa peruana. Estos análisis se realizaron para cada uno de los modelos globales del CMIP6, así como para el promedio multimodelo.

d. Transporte y bombeo de Ekman

El transporte Ekman, $\vec{E}_T$ ($\text{m}^2 \text{s}^{-1}$, o $\text{m}^3 \text{s}^{-1}$ por metro de costa), es calculado a partir de (Schwing et al. 1996):

$$\vec{E}_T = \frac{1}{\rho_w f} \vec{\tau} \times \vec{k},$$

donde ρ_w es la densidad del agua de mar (1025 kg m^{-3}), f el parámetro de Coriolis dependiente de la latitud (s^{-1}), y $\vec{k}$ es un vector unitario vertical hacia arriba.

La componente mar adentro del transporte de Ekman, $E_T^{offshore}$ ($\text{m}^2 \text{s}^{-1}$), es impulsada por el componente a lo largo de la costa de $\vec{\tau}$ ($\tau_{alongshore}$, calculada de manera análoga a $w_{alongshore}$), y se define como (Messié et al. 2009, Pickett & Paduan 2003):

$$E_T^{offshore} = -\frac{\tau_{alongshore}}{\rho_w f}.$$

El bombeo de Ekman ocurre cuando el *stress* del viento reduce su intensidad en dirección a la costa (*drop-off*). Esto genera un movimiento ascendente, cuya velocidad vertical w (m s^{-1}) es (Messié et al. 2009, Halpern 2002, Jacox et al. 2018):

$$w = \frac{1}{\rho_w f} \left(\frac{\partial \tau_y}{\partial x} - \frac{\partial \tau_x}{\partial y} \right) = \frac{1}{\rho_w f} (\nabla \times \vec{\tau}),$$

donde los subíndices x y y hacen referencia a las componentes zonal y meridional del *stress* del viento respectivamente. Notemos que el término entre paréntesis en la ecuación anterior viene a ser el *curl* del *stress* del viento. Un valor positivo de w implica un valor negativo en el *curl* del viento y favorece el afloramiento.

Para comparar directamente los dos procesos de afloramiento convertimos la velocidad vertical asociada al *curl* del viento en transporte vertical o bombeo de Ekman (E_p), integrando la velocidad vertical w hasta cierta distancia mar adentro (150 km). Este proceso se realiza promediando w longitudinalmente (hasta 150 km mar adentro, valor utilizado también por Messié et al. (2009) para realizar el mismo cálculo) y multiplicando por la distancia total (150 - 25 km), es decir,

$$E_p = \bar{w} \cdot (150 - 25),$$

donde $\bar{w}$ es la velocidad vertical promedio (Messié et al. 2009). Cabe resaltar que otros autores denominan como bombeo de Ekman a la velocidad vertical w ; sin embargo, aquí consideramos como bombeo de Ekman al transporte vertical asociado a w .

Los resultados obtenidos en la Sección 3.4.c permiten determinar los diferentes cambios en el viento a lo largo de la costa peruana. En base a esto se realizó una segmentación latitudinal del dominio, con el fin de evaluar de mejor manera los cambios en el transporte y bombeo.

Se analizaron los cambios mensuales en el transporte y bombeo de Ekman para los múltiples modelos del CMIP6 frente a la costa peruana durante los diferentes periodos histórico y futuro. No buscamos analizar únicamente los cambios promedio en el transporte y bombeo, sino también los cambios en sus valores extremos (percentiles 25 y 75). Adicionalmente se evaluaron los cambios en el transporte total (por latitud y de manera estacional)

Los resultados obtenidos a partir de los procedimientos descritos en las Secciones 3.4.c y 3.4.d nos permiten evaluar las diferencias en los cambios proyectados según los múltiples modelos globales y determinar su robustez. Consideramos a los resultados como robustos, si se muestra concordancia en al menos 8 de 12 (~70 %) modelos del CMIP6 (Parvathi et al. 2017).

4. RESULTADOS

4.1. COMPARACIÓN Y SELECCIÓN DEL MODELO DE REDES NEURONALES PARA EL *DOWNSCALING* ESTADÍSTICO DE VIENTOS

Luego del entrenamiento de los modelos estadísticos de redes neuronales (descritos en la sección 3.3), aplicamos las funciones de transferencia resultantes a los datos del reanálisis ERA5 durante el periodo de validación 1 (2020-2022). Las salidas finales se compararon con las observaciones ASCAT (2020-2022).

Para la componente zonal (Figura 15a), los valores de sesgo absoluto (MAE) son similares con cada modelo estadístico, la dispersión de los sesgos (medida a través del rango intercuartílico, RIC) es ligeramente menor para CNN 2 (0.15 m s^{-1}). Con C-D, los sesgos en la media son más centrados en cero y menos dispersos (RIC de 0.13 m s^{-1}). Los sesgos en el percentil 25 (P25) son más cercanos a cero con C-D; los tres modelos estadísticos presentan un RIC de $\sim 0.15 \text{ m s}^{-1}$ en este sesgo. Los sesgos en el percentil 75 (P75) son más centrados en cero con CNN 1 y CNN 2; sin embargo, el RIC es más bajo (0.18 m s^{-1}) con el modelo C-D.

Para la componente meridional (Figura 15b), los sesgos absolutos son similares con CNN 1 y CNN 2, mientras que C-D muestra sesgos ligeramente más altos y más dispersos (RIC de 0.24 m s^{-1}). Los sesgos en la media son similares con los tres modelos, con una dispersión ligeramente menor para CNN 1 (RIC de 0.12 m s^{-1}). Los sesgos en el P25 son más cercanos a cero con C-D; sin embargo, su RIC es el mayor (0.2 m s^{-1}). Los sesgos en el P75 son más cercanos a cero con los modelos

CNN 1 y CNN 2; los valores del RIC de los tres modelos son de $\sim 0.18 \text{ m s}^{-1}$ para este sesgo.




Figura 15. Boxplot de los criterios de validación (MAE, MBE, BiasP25, BiasP75 respecto a ASCAT) para cada salida de los modelos de *downscaling* (CNN 1, CNN 2, C-D), para las componentes **(a)** zonal y **(b)** meridional del viento, y a partir de los datos de ERA5 durante el periodo de validación 1 (2020-2022). Los valores del rango intercuartílico se muestran en la parte superior de cada caja.

Asimismo, analizamos la distribución espacial de los criterios de validación. Para la componente zonal (Figura 16) el MAE se distribuye prácticamente igual con cada modelo estadístico, con un menor valor promedio para CNN 1 (0.715 m s^{-1}). El MAE se incrementa ligeramente cerca de la costa peruana, llegando a superar los 0.8 m s^{-1} para todos los modelos estadísticos. El sesgo en la media muestra valores positivos ($\sim 0.2 \text{ m s}^{-1}$) para CNN 1 y CNN 2 entre 5° - 20° S, mientras que para C-D los valores son más neutros (más cercanos a 0 m s^{-1}). Los sesgos en el P25 son

positivos en casi todo el dominio predictante según los tres modelos estadísticos, con un menor valor promedio para C-D (0.164 m s^{-1}). Entre 5° - 18° S, los sesgos en el P75 son positivos ($\sim 0.2 \text{ m s}^{-1}$) para los modelos CNN 1 y CNN 2, y ligeramente negativos ($\sim 0.1 \text{ m s}^{-1}$) para C-D, esto hace que el valor promedio sea más negativo para este modelo (-0.211 m s^{-1}); para el resto del dominio los sesgos son negativos según los tres modelos estadísticos ($\sim 0.3 \text{ m s}^{-1}$).




Figura 16. Mapas de los criterios de validación (MAE, MBE, BiasP25, BiasP75 respecto a ASCAT) para cada salida de los modelos de *downscaling* (CNN 1, CNN 2, C-D) a partir de ERA5, para la componente zonal del viento. Los valores promedio se muestran en la parte superior de cada mapa.

Para la componente meridional (Figura 17), el MAE se distribuye de manera prácticamente idéntica con cada modelo estadístico, con un menor valor promedio

para CNN 1 (0.802 m s^{-1}). Para los tres modelos estadísticos, los valores del sesgo absoluto se incrementan ligeramente cerca de la costa. El sesgo en la media muestra valores negativos en casi todo el dominio con los tres modelos; para CNN 1, el valor de este sesgo es más negativo al oeste de las islas Galápagos en comparación con los otros modelos. Los sesgos en el P25 muestran una mejor distribución con CNN 1, con valores más cercanos a cero frente a la costa; mientras que con los otros modelos estadísticos se obtienen valores positivos de $\sim 0.2 \text{ m s}^{-1}$. Los sesgos en el P75 son negativos en todo el dominio con los tres modelos, con valores por debajo de -0.75 m s^{-1} al oeste de Galápagos y alrededor de 5° N . Para C-D los valores de este sesgo se incrementan negativamente frente a la costa norte de Perú y la costa norte de Chile ($\sim -0.75 \text{ m s}^{-1}$).




Figura 17. Similar a la Figura 16, pero para la componente meridional del viento.




Figura 18. Perfiles del viento **(a)** zonal y **(b)** meridional promedio entre 3.25° - 18.5° S frente a la costa peruana para ASCAT, y las salidas de los modelos CNN 1, CNN 2 y C-D a partir de ERA5. Nótese que el eje Y para el viento zonal está invertido.

Finalmente, evaluamos la capacidad de cada modelo estadístico de reproducir el comportamiento de cada componente del viento frente a la costa peruana. Para la componente zonal (Figura 18a), los tres modelos muestran un perfil del viento muy similar a lo obtenido a partir de ASCAT, aunque con una ligera subestimación de la caída de esta variable (caída en magnitud, ya que los valores son negativos) en los puntos más cercanos a la costa. Para la componente meridional (Figura 18b), los modelos arrojan valores ligeramente menores (en $\sim 0.15 \text{ m s}^{-1}$) que ASCAT entre los 50 y 250 km mar adentro. Para ambas componentes, las diferencias en los perfiles del viento son mínimas entre los modelos estadísticos.

De manera complementaria a esta primera validación y debido a la paridad en los resultados mostrados entre los tres modelos estadísticos, se realizó una segunda validación aplicando las funciones de transferencia a los datos del reanálisis NCEP de resolución original similar a los modelos del CMIP6 ($\sim 250 \text{ km}$), durante el

periodo de validación 2 (2008-2011). Las salidas finales se compararon con las observaciones ASCAT (2008-2011).




Figura 19. Boxplot de los criterios de validación (MAE, MBE, BiasP25, BiasP75 respecto a ASCAT) para cada salida de los modelos de *downscaling* (CNN 1, CNN 2, C-D), para las componentes (a) zonal y (b) meridional del viento, y a partir de los datos de NCEP durante el periodo de validación 2 (2008-2011). Los valores del rango intercuartílico se muestran en la parte superior de cada caja.

Para la componente zonal (Figura 19a), los valores del MAE son similares para CNN 1 y CNN 2, y son más bajos con C-D; para los tres modelos estadísticos el RIC es de $\sim 0.25 \text{ m s}^{-1}$. Con CNN 2 y C-D los sesgos en la media son más centrados en cero y menos dispersos (RIC de 0.47 m s^{-1}), mientras que para CNN 1 el sesgo en la media tiende a valores más negativos y más dispersos (RIC de 0.6 m s^{-1}). Los sesgos en el P25 son más centrados en cero con CNN 2, mientras que para CNN 1 estos valores son más negativos y para C-D son más positivos; los tres modelos

estadísticos presentan un RIC de $\sim 0.54 \text{ m s}^{-1}$ en este sesgo. Los sesgos en el P75 son más centrados en cero con el modelo CNN 2 y muestra valores ligeramente más negativos con CNN 1 y C-D; además, el RIC en este sesgo para CNN 2 es el más bajo (0.38 m s^{-1}).

Para la componente meridional (Figura 19b), el MAE muestra valores similares con los modelos CNN 1 y CNN 2, y son más bajos con C-D; para los tres modelos el RIC es de $\sim 0.3 \text{ m s}^{-1}$. Los sesgos en la media son más centrados en cero y menos dispersos (RIC de 0.2 m s^{-1}) con C-D; mientras que para CNN 1 y 2 los sesgos se muestran más positivos, con RIC de 0.37 y 0.36 m s^{-1} respectivamente. Para los sesgos en los percentiles 25 y 75, los valores más cercanos a cero se obtienen con CNN 2, pero son mucho menos dispersos con C-D (RIC de 0.26 m s^{-1} para el P25 y 0.21 m s^{-1} para el P75).

En cuanto a la distribución espacial de los criterios de validación, para la componente zonal (Figura 20) la distribución del MAE muestra valores más bajos con C-D (con una diferencia de $\sim 0.1 \text{ m s}^{-1}$ respecto de los valores obtenidos a partir de los otros modelos). Para todos los modelos, el MAE es más elevado en latitudes norte ($>1.5 \text{ m s}^{-1}$), y se va reduciendo en dirección a la costa centro norte de Perú. Para los sesgos en la media y percentiles, los patrones espaciales son similares con los tres modelos estadísticos, mostrando sesgos positivos en la parte oceánica cerca al continente y sesgos negativos para la parte oceánica más alejada. En latitudes norte los sesgos positivos superan el 1 m s^{-1} cerca de la costa. En general, los patrones de sesgo son menos intensos para el modelo C-D, especialmente para el sesgo en el P75.




Figura 20. Mapas de los criterios de validación (MAE, MBE, BiasP25, BiasP75 respecto a ASCAT) para cada salida de los modelos de *downscaling* (CNN 1, CNN 2, C-D) a partir de NCEP, para la componente zonal del viento. Los valores promedio se muestran en la parte superior de cada mapa.

Para la componente meridional (Figura 21) la distribución del MAE cuenta con valores más bajos para C-D (con una diferencia de $\sim 0.1 \text{ m s}^{-1}$ respecto de los valores obtenidos a partir de los otros modelos estadísticos). Para todos los modelos, el MAE llega a su punto máximo en latitudes norte (mayor a 1.75 m s^{-1}), y es más reducido entre los 5° - 20° S y mar dentro. Cerca de la costa, los valores más altos del MAE se muestran alrededor de 13° S para todos los modelos. Para los sesgos en la media y el P25 los patrones espaciales son similares con todos los modelos, con sesgos positivos en latitudes norte ($>1 \text{ m s}^{-1}$); mientras que para latitudes sur se

muestran sesgos negativos cerca de la costa y sesgos positivos en la parte oceánica más alejada del continente. En general, los patrones de sesgo son menos intensos con C-D y más intensos con CNN 1. Los patrones espaciales del sesgo en el P75 se distribuyen de manera similar a los sesgos en la media y P25 según los CNNs; mientras que para el modelo C-D los sesgos son negativos en casi todo el dominio, mostrando valores ligeramente más intensos cerca de la costa norte de Perú.




Figura 21. Similar a la figura 20, pero para la componente meridional del viento.

Por último, se evaluó la habilidad de los modelos (forzados con un predictor diferente al utilizado en el entrenamiento) para reproducir el *drop-off* del viento. Para la componente zonal (Figura 22a), CNN 2 muestra un perfil del viento con pendiente similar a ASCAT; sin embargo, sus valores son superiores (menos negativos) en $\sim 0.3 \text{ m s}^{-1}$. Para CNN 1 y C-D, los sesgos son ligeramente menores

entre los 100-250 km y se van reduciendo al acercarse a la costa, generando diferencias entre las pendientes de los modelos estadísticos y ASCAT. Para la componente meridional (Figura 22b) los modelos arrojan valores ligeramente menores ($\sim 1\text{-}2\text{ m s}^{-1}$) que ASCAT; el modelo con mejor performance es CNN 1. Esto se explica desde que los perfiles del viento mostrados en la Figura 22 son promedio de toda la franja costera frente a Perú; por tanto, los sesgos positivos según CNN 1 en la zona norte se compensan con los sesgos negativos en la zona sur (ver los sesgos en la media en la Figura 21). Esto no ocurre con CNN 2 y C-D, donde los sesgos son negativos y de menor magnitud a lo largo de la costa.




Figura 22. Perfiles del viento **(a)** zonal y **(b)** meridional promedio entre 3.25° - 18.5° S frente a la costa peruana para ASCAT, y las salidas de los modelos CNN 1, CNN 2 y C-D a partir de NCEP. Nótese que el eje Y para el viento zonal está invertida.

En base a los resultados mostrados, podemos decir que el modelo estadístico de redes neuronales con arquitectura *coding-decoding* (C-D) es el mejor para realizar el *dowscaling* del viento de diferentes bases de datos como lo son los múltiples modelos del CMIP6. En adelante, los resultados mostrados serán los obtenidos a partir de la aplicación del modelo C-D (para ambas componentes) sobre los datos

predictores de los 12 modelos globales del CMIP6 listados en la Tabla 3 y bajo el escenario SSP5-8.5 de cambio climático.

4.2. PROYECCIONES DEL VIENTO EN A LA COSTA

Esta sección divide la revisión de las proyecciones del viento superficial en el análisis de los cambios en la intensidad del viento (*alongshore*) y del *curl stress* del viento, a partir de las salidas del modelo estadístico C-D aplicados sobre los modelos globales del CMIP6 (Tabla 3) y según las ecuaciones descritas en la Sección 3.4.c. Los datos de los 12 modelos se promediaron para obtener una base de datos multimodelo. Los cambios proyectados se consideraron robustos cuando la dirección del cambio (signo) coincidió en al menos 8 de los 12 modelos globales.

a. Proyecciones de la intensidad viento *alongshore* frente a la costa peruana

La media multimodelo durante el periodo histórico (1995-2014, Figura 23a) representa de buena manera la distribución espacial de la intensidad del viento según el satélite ASCAT (2008-2022, Figura suplementaria 1.a).

En general, para el periodo futuro cercano los cambios en el viento son muy pequeños ($\sim 0\%$), con una ligera intensificación cerca de la costa y un leve debilitamiento mar adentro (Figura 23b). La zona oceánica entre 0° - 5° S también muestra una leve intensificación ($<5\%$). Los cambios proyectados para este periodo no son robustos.

Para el periodo futuro intermedio los cambios en la media multimodelo se acentúan ligeramente, principalmente mar dentro (Figura 23c). Sin embargo, frente a la costa peruana los cambios se mantienen por debajo del 5 %, con un debilitamiento al norte de 16° S (robusto al norte de 6° S y alrededor de 8° S) y una intensificación al sur de 16° S (robusto alrededor de 18° S).




Figura 23. (a) Mapa de intensidad del viento para el periodo histórico según el promedio multimodelo. Cambios proyectados (colores en m s^{-1} y contornos en %) en la intensidad del viento para los periodos **(b)** futuro cercano, **(c)** intermedio y **(d)** lejano, según el promedio multimodelo. Las zonas NO sombreadas indican los puntos de grilla donde los cambios respecto al periodo histórico son robustos.

Para el periodo futuro lejano y cerca de la costa norte del Perú (al norte de 7° S), el promedio multimodelo indica de manera robusta un debilitamiento de los vientos superior al 5 % (Figura 23d). En la zona centro-sur frente a Perú (al sur de 8° S) los cambios son pequeños (<5 %). El debilitamiento del viento se extiende hasta ~15° S, al sur de este punto se muestra una ligera intensificación (<5 %). Los resultados obtenidos entre 10°-16° S no son robustos. En latitudes norte los vientos se debilitan un 5-10 % (robusto), mientras que al sur de 20° S se muestra una intensificación de hasta ~5 % en la zona oceánica (robusto).




Figura 24. Similar a la Figura 23, pero para las componentes zonal (paneles superiores) y meridional (paneles inferiores) del viento.

También analizamos los cambios en ambas componentes del viento (Figura 24), teniendo en cuenta que los cambios positivos en la componente zonal implican un debilitamiento en la magnitud de esta variable. Para el futuro cercano (Figura 24b) los cambios son pequeños, menores al 5 % para ambas componentes. Para el futuro intermedio (Figura 24c) el viento zonal se debilita (<5 %) de manera robusta; mientras que para la componente meridional es más débil (intensa) al norte (sur) de 8° S (robusto al norte de 6° S y entre 9°-13° S). Para el futuro lejano (Figura 24d) la componente zonal muestra un debilitamiento (~5 %) robusto a lo largo de la costa; mientras que la componente meridional se debilita (robusto) al norte de 7° S (superando el 5 % alrededor de 5° S), e intensifica (robusto) al sur de 10° S (<5 %).

Por otro lado, analizamos de manera más detallada los cambios en el ciclo estacional de la componente *alongshore* del viento (y favorable al afloramiento), para una franja de 150 km frente a la costa peruana (Figura 25). El promedio multimodelo indica cambios muy pequeños en el ciclo estacional según el futuro cercano (~ 0 % durante todo el año), mostrando una ligera intensificación entre octubre-marzo y un debilitamiento entre abril-setiembre. Los resultados encontrados son robustos a lo largo del litoral peruano durante octubre-diciembre, y entre 4° - 10° S durante febrero-marzo y agosto-setiembre; aunque en general (Figura 25b).

Para el futuro intermedio (Figura 25c) los cambios se muestran por debajo del 5 %, excepto alrededor de 6° y 4° S durante enero-mayo, donde se evidencia un debilitamiento de ~ 5 % (robusto). Al norte de 6° S los cambios son robustos a lo largo del ciclo estacional. La incertidumbre de los resultados se incrementa al sur de 6° S (en comparación con el futuro cercano).

Para el futuro lejano (Figura 25d) los mayores cambios en el promedio multimodelo se muestran en la zona norte frente de la costa peruana. Los vientos *alongshore* muestran un debilitamiento superior al 5 % al norte de 7° S (salvo durante noviembre-diciembre), llegando a superar el 20 % al norte de 6° S durante enero-abril (robusto). En la zona central (8° - 17° S) los cambios a lo largo del ciclo estacional se mantienen por debajo del 5 % (no robustos). En la zona más al sur frente a la costa peruana (al sur de 17° S), se muestra una leve intensificación a lo largo del ciclo estacional (robusto, < 5 %).




Figura 25. Perfil del viento *alongshore* promedio para una franja de hasta 150 km frente a la costa (a) para el periodo histórico (negro) y futuros cercano (azul), intermedio (verde) y lejano (rojo), según el promedio multimodelo. Cambios proyectados (colores m s^{-1} y contornos en %) en el ciclo estacional promedio de los vientos *alongshore* (en una franja costera de hasta 150 km) para los periodos (b) futuro cercano, (c) intermedio y (d) lejano, según el promedio multimodelo. Los valores NO sombreados indican robustez en los cambios.

De manera análoga, se analizaron los cambios mensuales para cada uno de los modelos globales del CMIP6 (Figura suplementaria 2). Para el futuro cercano la mayoría de modelos muestran cambios generales por debajo del 5 %; resaltando CanESM5 (con una intensificación de $\sim 5\%$ entre 4° - 10° S durante octubre-mayo, alcanzando un 10 % durante el verano), CNRM-ESM2-1 (con un debilitamiento de 5-10 % entre 4° - 15° S, excepto en octubre), y NESM3 (con un debilitamiento superior al 5 % entre 5° - 16° S durante noviembre-diciembre y abril-mayo). Para el futuro intermedio, los cambios en el ciclo estacional se acentúan ligeramente respecto al futuro cercano (Figura suplementaria 2). En ese sentido, el modelo CanESM5 muestra una intensificación superior al 5 % entre 5° - 10° S durante casi todo el año (salvo agosto), CNRM-ESM2-1 muestra un debilitamiento de más del

5 % entre 5°-16° S durante todo el año (superando el 20 % durante enero-marzo al norte de 8° S), y NESM3 evidencia un debilitamiento superior al 10 % durante diciembre-julio entre 8°-10° S. Para el periodo futuro lejano, los cambios en el ciclo estacional son más intensos según la mayoría de modelos (Figura suplementaria 2); salvo para MIROC6, donde los cambios se mantienen por debajo del 10 % durante este periodo. Para BCC-CSM2-MR, el cambio más importante es el debilitamiento del viento al norte de 8° S durante el verano (>5 %, alcanzando el 20 % alrededor de 6° S). El modelo CanESM5 muestra una intensificación general de 5-10 % al sur de 13° S, mientras que al norte de este punto el cambio más relevante es una intensificación de ~10 % durante primavera y otoño. Los principales cambios según CMCC-CM2-SR5 son una intensificación superior al 10 % entre setiembre-noviembre al sur de 12° S y un debilitamiento superior al 5 % al norte de 4° S. CNRM-ESM2-1 indica un debilitamiento del viento al norte de 15° S, llegando a superar el 10 % durante julio-setiembre y el 20 % durante diciembre-abril. Los modelos GFDL-CM4 y GFDL-ESM4 muestran un debilitamiento de ~5-10 % al norte de 9° S. Por otro lado, IPSL-CM6A-LR, MPI-ESM1-2-HR y MRI-ESM2-0 muestran un debilitamiento arriba del 15 % al norte de 6° S (superando el 20 % durante enero-abril). Para el MPI-ESM1-2-LR, el cambio más relevante es un debilitamiento de ~20 % durante el verano al norte de 6° S. Finalmente, NESM3 muestra un debilitamiento de 10-15 % al norte de 10° S durante diciembre-abril.

Además de los cambios en la media, analizamos los cambios en los percentiles 25 y 75, de manera que se pueda tener una idea del impacto del cambio climático sobre los eventos de viento débil y fuerte a una escala diaria. Las Figuras 26a-d muestran

los cambios absolutos en el P25 para cada estación. Notamos que los cambios proyectados ocurren de manera progresiva conforme se avanza en el tiempo durante el periodo futuro. Los mayores cambios ocurren en la zona norte (entre 4°-9° S) para el periodo futuro lejano, con valores promedio del P25 hasta $\sim 0.3 \text{ m s}^{-1}$ más débiles. Alrededor de 8° S los cambios menos importantes ocurren en verano (Figura 26a); aunque se debe considerar que durante esta estación los vientos encuentran sus valores climatológicos más bajos, por lo cual es razonable un debilitamiento limitado. Los cambios negativos en el P25 son robustos (según la dispersión de la nube multimodelo) al norte de $\sim 6^\circ \text{ S}$ para el futuro intermedio y al norte de $\sim 8^\circ \text{ S}$ para el futuro lejano. Alrededor de 14° S se muestra un incremento de $\sim 0.2 \text{ m s}^{-1}$ en el P25 durante la primavera (robusto), mientras que para el verano este incremento (de hasta 0.2 m s^{-1}) ocurre al sur de 16° S .

De manera complementaria, se determinó la probabilidad de encontrar días con vientos por debajo del percentil 25 histórico (viento débiles) durante los periodos futuros (Figuras 26e-h). Acorde con lo expuesto en el párrafo anterior, la probabilidad de vientos débiles aumenta entre 5-10% durante el futuro intermedio al norte de 6° S , y entre 10-20% durante el futuro lejano al norte de 8° S . Estos resultados son robustos, aunque la dispersión de la nube (que representa el 50% de los resultados intermodelos) es más pequeña durante el invierno. Entre 10° - 16° S los cambios son mínimos (así como la dispersión de la nube), mientras que para el verano la probabilidad de vientos débiles durante el futuro lejano se reduce en $\sim 10\%$ al sur de 17° S (robusto), acorde el incremento en el valor del P25 mostrado en la Figura 26a.




Figura 26. (a), (b), (c) y (d) Cambios absolutos en el P25 del viento *alongshore* según los futuros cercano (azul), intermedio (verde) y lejano (rojo) por estación y latitud. (e), (f), (g) y (h) Probabilidad de días con vientos por debajo del P25 histórico según los futuros cercano (azul), intermedio (verde) y lejano (rojo) por estación y latitud. En cada caso, la línea sólida representa la mediana multimodelo, mientras que la nube de cada curva está delimitada por los percentiles 25 y 75 multimodelo.

De manera análoga, las Figuras 27a-d muestran los cambios absolutos en el P75 por estación. Los cambios más importantes ocurren al norte de 8° S y para el periodo futuro lejano, con valores promedio del P75 hasta $\sim 0.3 \text{ m s}^{-1}$ más débiles (robusto). Esto sumado a los cambios en el promedio y el P25 indican un desplazamiento de la distribución de los vientos *alongshore* hacia valores más débiles: $\sim 0.1 \text{ m s}^{-1}$ al norte de 6° S durante el futuro intermedio y entre $0.2\text{-}0.3 \text{ m s}^{-1}$ al norte de 8° S

durante el futuro lejano. Alrededor de 14° S se muestran cambios positivos en el P75 de aproximadamente 0.2 m s⁻¹ (robusto), mientras que durante el verano y al sur de 17° S el P75 se incrementa en ~0.15 m s⁻¹.




Figura 27. Análogo a la Figura 26, pero para los cambios absolutos en el P75 (a, b, c, d), y la probabilidad de días con vientos superiores al P75 histórico (e, f, g, h).

La probabilidad de vientos fuertes en el periodo futuro se determinó a partir de la cantidad de días con vientos superiores al percentil 75 histórico (Figuras 27e-h). En relación al debilitamiento general del viento *alongshore*, la probabilidad de vientos fuertes se reduce ~5% al norte de 6° S para el futuro intermedio y hasta un 15% al norte de 8° S para el futuro lejano (resultados robustos). La zona entre 10°-16° S no muestra cambios importantes, con una baja dispersión de la nube intermodelo.

Por último, notamos que durante el verano la probabilidad de días con vientos fuertes aumenta un $\sim 10\%$ al sur de 17° S para el futuro lejano (robusto).

b. Proyecciones del rotacional del viento frente a la costa peruana

El análisis de esta variable está enfocado entre los 25-150 km frente a la costa. La media multimodelo para el periodo histórico (1995-2014, Figura 28a) representa de buena manera el *curl stress* del viento según ASCAT (2008-2022, Figura suplementaria 1b). Dado que el *curl* es negativo a lo largo de la costa peruana (Figura 29a), decimos que el *curl stress* del viento se “debilita” (fortalece) durante un periodo futuro si se muestran “cambios positivos” (negativos) en esta variable.




Figura 28. (a) Mapa de *curl stress* del viento para el periodo histórico según el promedio multimodelo. Cambios proyectados en *curl stress* del viento para los periodos (b) futuro cercano, (c) intermedio y (d) lejano, según el promedio multimodelo. Los contornos en cada mapa separan los cambios positivos y negativos en el *curl stress* del viento. Las zonas NO sombreadas indican los puntos de grilla donde los cambios respecto al periodo histórico son robustos. Las unidades en todos los paneles son 10^{-7} N m^{-3} .

Los cambios en el *curl stress* del viento durante el periodo futuro cercano son muy pequeños, con ligero debilitamiento (menor a $0.05 \times 10^{-7} \text{ N m}^{-3}$) en la zona costera

al norte de 17° S (Figura 28). Al sur de 16° S se muestra un leve fortalecimiento (menor a $0.05 \times 10^{-7} \text{ N m}^{-3}$). Cerca de la costa estos cambios son poco robustos. Para el periodo futuro intermedio el *curl* se debilita en $\sim 0.1 \times 10^{-7} \text{ N m}^{-3}$ al norte de 14° S (Figura 28). Al sur de 14° S se muestra una pequeña intensificación (menor a $0.1 \times 10^{-7} \text{ N m}^{-3}$), robusta alrededor de 17° S. Para el futuro lejano, los cambios indican una reducción superior a $0.1 \times 10^{-7} \text{ N m}^{-3}$ al norte de 14° S (Figura 28), alcanzado diferencias de $\sim 0.15 \times 10^{-7} \text{ N m}^{-3}$ entre 11°-14° S, entre 6°-8° S y al norte de 4° N (robusto). Al sur de 14° S el *curl* se fortalece $\sim 0.1 \times 10^{-7} \text{ N m}^{-3}$ (robusto).

Análogo al análisis realizado para la intensidad del viento paralelo a la costa (ver ítem anterior), mostramos los cambios en el ciclo estacional para el *curl stress* del viento. Los resultados se obtuvieron a partir de una franja entre 25-150 km frente a la costa peruana.

El promedio multimodelo indica cambios muy pequeños en el ciclo estacional para el futuro cercano (Figura 29), sobresaliendo porcentualmente los cambios alrededor de 4.5° S, principalmente debido a que en esta zona los valores del *curl* son los más cercanos a cero frente al litoral. Entre 6°-16° S encontramos un leve debilitamiento ($\sim 1 \%$) durante abril-setiembre, mientras que alrededor de 16.5° S se muestra un leve fortalecimiento ($\sim 1 \%$) durante todo el ciclo estacional. En general, los cambios proyectados para el futuro cercano no son robustos. Para el futuro intermedio los cambios en la media multimodelo son similares al periodo anterior. Entre 6°-14° S el *curl* es más débil ($>1 \%$), llegando al 5 % alrededor de 4° S durante julio-setiembre (robusto). Alrededor de 17° S se muestra una intensificación a lo largo del ciclo estacional, alcanzando el 5 % durante junio-setiembre (robusto), además

estos cambios se extienden frente a la costa entre 14°-18° S durante el invierno. Para el futuro lejano los cambios son más pronunciados en comparación con los otros periodos de evaluación. Al norte de 14° S se evidencia una reducción permanente en el *curl*. Al norte de 4° S estos cambios (debilitamiento) superan el 10 % de manera robusta a lo largo del ciclo estacional, mientras que entre 6°-8° S los cambios son de ~5 % y robustos durante todo el año. Entre 15°-17° S los cambios en el *curl* indican un fortalecimiento, superando el 5 % entre febrero-noviembre y el 10 % entre julio-octubre (robusto).




Figura 29. (a) Perfil del *curl stress* del viento promedio entre los 25-150 km frente a la costa para el periodo histórico (negro) y futuros cercano (azul), intermedio (verde) y lejano (rojo), según la media multimodelo. Cambios proyectados (colores en 10^{-7} N m^{-3} y contornos en %) en el ciclo estacional promedio del *curl stress* del viento (en una franja costera entre 25-150 km) para los periodos futuro (b) cercano, (c) intermedio y (d) lejano, según la media multimodelo. Los valores NO sombreados indican robustez en los cambios.

Analizando los cambios estacionales para cada uno de los modelos globales del CMIP6, para el futuro cercano (Figura suplementaria 3), el modelo con mayores cambios es CNRM-ESM2-1, con un debilitamiento permanente de 5-15 %. El resto

de modelos muestra cambios en el *curl* por debajo del $\sim 10\%$ entre 6° - 18° S. Para el futuro intermedio (Figura suplementaria 3), los modelos CMCC-CM2-SR5, GFDL-CM4, GFDL-ESM4, MPI-ESM1-2-HR, MPI-ESM1-2-LR y MRI-ESM2-0, mantienen cambio mínimos en el *curl* y similares al futuro cercano. El modelo BBC-CSM2-MR muestra un debilitamiento de hasta 10% al norte de 4° S y entre 5° - 15° S durante junio-setiembre. CanESM5 evidencia un fortalecimiento del *curl* de entre 15° - 18° S, llegando a superar el 15% de cambio durante setiembre-octubre y el 20% durante abril-julio, de igual manera al norte de 4° S se muestra un incremento superior al 20% entre enero-abril. CNRM-ESM2-1 acentúa los cambios encontrados en el futuro cercano, principalmente entre 10° - 14° S, con una disminución del *curl* de $\sim 20\%$ durante primavera-verano. Para IPSL-CM6A-LR los resultados más relevantes ocurren durante julio-octubre, con un aumento de 10% alrededor de 9° S y 15% alrededor de 17° S. El modelo MIROC6 muestra un fortalecimiento alrededor de 17° S, llegando al 10% durante junio-octubre; al norte de 4° S se muestra un debilitamiento de hasta 5% durante mayo-setiembre. Por último, NESM3 proyecta un *curl* reducido entre 7° - 15° durante abril-mayo y noviembre-enero ($>10\%$), y alrededor de 15° S durante todo el año ($>5\%$).

Para el futuro lejano (Figura suplementaria 3), BCC-CSM2-MR muestra cambios similares a los mostrados para el futuro intermedio, excepto entre 15° - 17° S durante marzo-octubre, donde se acentúan el fortalecimiento del *curl* (llegando al 10% entre abril-julio). CanESM5 muestra una disminución de hasta un 10% al norte de 4° S durante mayo-agosto, mientras que alrededor de 16° S el incremento supera el 20% a lo largo del ciclo estacional. Para CMCC-CM2-SR5, la principal diferencia

respecto al futuro intermedio es un fortalecimiento más pronunciado (hasta 20 %) al sur de 10° S durante setiembre-noviembre. CNRM-ESM2-1 indica un debilitamiento de ~20 % entre 10°-15° S y durante junio-diciembre. GFDL-CM4 y MRI-ESM2-0 proyectan cambios similares en el futuro intermedio y lejano. Los modelos GFDL-ESM4 y MPI-ESM1-2-HR indican una reducción (entre 10-15 %) al norte de 10° S, y un aumento (~5 %) alrededor de 15.5°-16° S. IPSL-CM6A-LR indica un debilitamiento (>20 %) al norte de 4° S, mientras que alrededor de 17° S el aumento en el *curl* alcanza el 20 % durante el verano-otoño y el 15 % durante el invierno. Para MIROC6 la disminución del *curl* alcanza el 15 % al norte de 4° S, mientras que el fortalecimiento alrededor de 16.5° S alcanza el 20 % durante el invierno. MPI-ESM1-2-LR indica una reducción (~15 %) al norte de 4° S, mientras que entre 5°-15° S el aumento es de 5-10 % durante abril-junio y setiembre-diciembre. Según NESM3, los cambios indican un debilitamiento del *curl* (> 5 %), llegando al 15 % entre 6°-11° S de manera permanente; solo se muestra un incremento durante agosto, al norte de 4° S, entre 9°-14° S y al sur de 16° S.

Al igual que para el viento *alongshore*, evaluamos los cambios en los P25 y P75, aunque para el caso de esta variable los valores debajo del P25 (P75) corresponden a los valores del *curl* más intensos o más negativos (débiles o más positivos). Las Figuras 30a-d muestran los cambios absolutos en el P25 del *curl stress* del viento para cada estación. Los cambios proyectados ocurren de manera progresiva conforme se avanza en el tiempo en el periodo futuro. Al norte de 10° S los cambios son positivos (debilitamiento), siendo los más importantes entre 6°-8° S durante invierno y primavera ($\sim 0.2 \times 10^{-7} \text{ N m}^{-3}$, Figuras 30c y d). Durante la primavera del

futuro lejano los cambios superan el $0.2 \times 10^{-7} \text{ N m}^{-3}$ alrededor de 12° S , aunque dispersión de la nube intermodelo se magnifica (sobretudo alredeodr de 13° S , Figura 30d). Entre $16^\circ\text{-}18^\circ \text{ S}$, se muestran cambios negativos (fortalecimiento) durante otoño-invierno-primavera del futuro lejano (Figura 30b, c y d), alcanzando el $0.2 \times 10^{-7} \text{ N m}^{-3}$ durante el invierno. Al norte de 4° S se muestra un debilitamiento importante (especialmente durante otoño-invierno-primavera).




Figura 30. (a), (b), (c) y (d) Cambios absolutos en el P25 del *curl stress* del viento según los futuros cercano (azul), intermedio (verde) y lejano (rojo) por estación y latitud. (e), (f), (g) y (h) Probabilidad de días con valores del *curl stress* del viento por debajo del P25 histórico según los futuros cercano (azul), intermedio (verde) y lejano (rojo) por estación y latitud. En cada caso, la línea sólida representa la mediana multimodelo, mientras que la nube de cada curva está delimitada por los percentiles 25 y 75 multimodelo.

Asimismo, mostramos la probabilidad de encontrar días con valores del *curl* por debajo del P25 histórico (más intensos) durante el periodo futuro (Figuras 30e-h). Acorde con lo expuesto previamente, la probabilidad de valores más altos del *curl* se reduce hasta 5% durante el futuro intermedio al norte de 7° S, y entre 5-10 % durante el futuro lejano al norte de 8° S. Estos resultados son robustos teniendo en cuenta la distersión de la nube (que representa el 50 % de los resultados intermodelos). La región entre 10°-16° S no muestra cambios importantes. Alrededor de 17° S la probabilidad de valores altos del *curl* se incrementa un 5 % durante otoño-invierno-primavera (robusto, Figuras 30f, g y h).




Figura 31. Análogo a la Figura 30, pero para los cambios absolutos en el P75 (a, b, c, d), y la probabilidad de días con valores del *curl* superiores al P75 histórico (e, f, g, h).

De manera análoga, las Figuras 31a-d muestran los cambios absolutos en el P75 por estación. Los resultados más importantes se mostraron alrededor de 7° S durante el invierno y primavera del futuro lejano, con cambios positivos (debilitamiento) de $\sim 0.2 \times 10^{-7} \text{ N m}^{-3}$ (robusto). Esto sumado a los cambios en los valores promedio y el P25 indican un desplazamiento de la distribución del *curl stress* del viento hacia valores menos intensos (menos negativos) en la zona norte durante el futuro lejano. Entre 10°-16° S los cambios son menores a $0.1 \times 10^{-7} \text{ N m}^{-3}$ para todos los periodos futuros. Alrededor de 17° S se muestra un P75 más intenso ($\sim 0.15 \times 10^{-7} \text{ N m}^{-3}$) durante el otoño-invierno-primavera del futuro lejano (robusto). Los cambios en el futuros cercanos e intermedio a lo largo de la franja frente a la costa peruana se mantuvieron por debajo de $\pm 0.1 \times 10^{-7} \text{ N m}^{-3}$.

La probabilidad un *curl stress* más débil se determinó a partir la cantidad de días valores del *curl* superiores al P75 histórico (los menos negativos, Figuras 31e-h). La media multimodelo indica un incremento de entre 5-10 % en la probabilidad de valores del *curl* más débiles alrededor de 7° S durante el futuro lejano (robusto). Asimismo, alrededor de 17° S esta probabilidad se reduce un 5% para el otoño-invierno-primavera del futuro lejano, acorde con los resultados previos. Para los futuros cercano e intermedio los cambios en esta probabilidad son menores al 5 %.

4.3. PROYECCIONES DEL TRANSPORTE Y BOMBEO DE EKMAN

Para esta sección se calcularon los valores del transporte y bombeo de Ekman frente al litoral peruano, a partir de las salidas del modelo estadístico de redes neuronales *coding-decoding* (C-D) aplicados sobre los modelos globales del CMIP6 (Tabla 3)

y según las ecuaciones descritas en la Sección 3.4.d. Los datos de los 12 modelos se promediaron para obtener una base de datos multimodelo. Los cambios proyectados se consideraron robustos cuando la dirección del cambio (signo) coincidió en al menos 8 de los 12 modelos globales.

a. Proyecciones del transporte de Ekman frente a la costa peruana

La Figura 32 muestra los cambios absolutos de la media, mediana, P25 y P75 correspondientes al transporte de Ekman mar adentro a lo largo del litoral peruano.

Los cambios en el futuro cercano son mínimos; no obstante, la dispersión de los cambios intermodelo se incrementa durante la primavera entre 4°-6° S. En general para todos los periodos futuros y al sur de 10° S, los cambios en todas las estadísticas están por debajo del $\pm 0.1 \text{ m}^2 \text{ s}^{-1}$, aunque la dispersión de los resultados intermodelo para el P75 se incrementa entre 10°-17° S durante la primavera del futuro lejano. Acorde con el debilitamiento del viento *alongshore* en la región norte (ver Sección 4.2.a), los resultados indican, con robustez, un desplazamiento en la distribución del transporte de Ekman hacia valores más débiles para los futuros intermedio (hasta $0.2 \text{ m}^2 \text{ s}^{-1}$ durante invierno-primavera) y lejano (hasta $0.4 \text{ m}^2 \text{ s}^{-1}$ durante invierno-primavera). Durante el verano y otoño, los cambios en el P25 son menores a los del P75; esto asociado a que, análogo a los vientos *alongshore*, el transporte de Ekman muestra sus valores más bajos durante diciembre-abril, limitando la reducción del P25 (Figura 33b).




Figura 32. Cambios absolutos en la media y percentiles 50 (mediana), 25 y 75 del transporte de Ekman mar adentro según los futuros cercano (azul), intermedio (verde) y lejano (rojo) por estación y latitud. En cada caso, la línea sólida representa la mediana multimodelo, mientras que la nube de cada curva está delimitada por los percentiles 25 y 75 multimodelo.

Considerando estos resultados y los de la Sección 4.2.a, resulta apropiado separar los análisis en dos regiones según su grado de afectación ante el cambio climático: región norte (entre 3.25°-8° S, Figura 33a) y región centro-sur (entre 10°-18.5° S, Figura 34a).




Figura 33. (a) Región norte de evaluación: entre 3.25°-8° S. **(b)** Valores de los percentiles 25, 50 y 75 del transporte de Ekman mensual en el periodo histórico. Cambios porcentuales mensuales en la **(c)** media y percentiles **(d)** 50, **(e)** 25 y **(f)** 75 del transporte de Ekman según los futuros cercano (azul), intermedio (verde) y lejano (rojo). En cada caso **(b-f)**, la línea sólida representa la mediana multimodelo, y la nube está delimitada por los percentiles 25 y 75 multimodelo.

Las Figuras 33c-f muestran los cambios porcentuales mensuales para la media, mediana (P50), P25 y P75 en la región norte frente al Perú. La Figura 33b muestra el ciclo estacional de los percentiles 25, 50 y 75 según la media multimodelo del periodo histórico; evidenciando una baja dispersión intermodelo. Para el futuro cercanos los cambios porcentuales en el transporte de Ekman se mostraron próximos al 0 %, salvo durante marzo para la media, P25 y P50, donde se muestra una intensificación de ~10 % (aunque la dispersión de los modelos se muestra elevada). Para el futuro intermedio, los principales cambios mensuales rondaron el 5 %, indicando valores más bajos del transporte de Ekman en todas las estadísticas. En general, los resultados para el verano muestran una mayor incertidumbre, y aún más para el P75. Para el futuro lejano los cambios son más claros (curva roja en las Figuras 33c-f), la media y percentiles muestran valores más débiles (>8 %) durante todo el ciclo estacional, con un debilitamiento más pronunciado durante el verano (cambio de 15-20 %). Sin embargo, es durante el verano donde encontramos una mayor dispersión en los resultados intermodelo. Durante el invierno la dispersión de la nube es menor, indicando cierta robustez en los resultados.

Complementando la información de la Figura 33c, los mayores cambios absolutos en la media según la data multimodelo se dieron entre mayo-setiembre (Tabla 5), con un pico de reducción durante agosto de $0.3 \text{ m}^2 \text{ s}^{-1}$ (8.2 %). Por otro lado, los cambios porcentuales más grandes ocurren entre enero-mayo, con un pico en enero de 20.6 % ($0.15 \text{ m}^2 \text{ s}^{-1}$). Los cambios mensuales según la media multimodelo son robustos; aunque para febrero y marzo, la magnitud del cambio no excede la desviación estándar de los cambios proyectados según cada modelo de forma

individual (criterio de robustes utilizado en Rykaczewski et al. 2015). Evaluando los modelos de manera individual, los mayores cambios absolutos en los periodos futuros cercano e intermedio se obtuvieron con CNRM-ESM2-1, alcanzando una reducción de $\sim 0.4 \text{ m}^2 \text{ s}^{-1}$ entre julio y setiembre.

Tabla 5. Cambios mensuales en el transporte de Ekman (en $\text{m}^2 \text{ s}^{-1}$) correspondientes el futuro lejano respecto al histórico sobre la región norte, para los 12 modelos del CMIP6 y la media multimodelo (celda gris). La coloración de cada celda indica si los cambios son positivos (rojo) o negativos (azul), mientras su intensidad es proporcional a la magnitud del cambio. Para la media multimodelo, los valores resaltados en “negrita” indican robustez en los resultados (al menos 8 de los 12 modelos coinciden en la dirección del cambio o signo), mientras que las celdas con contorno más grueso indican que el cambio en la media multimodelo es mayor que desviación estándar de los cambios de cada modelo individual.

Región norte [3.25° - 8° S]	Transporte de Ekman											
	Futuro Lejano - Histórico											
	Jan	Feb	Mar	Apr	May	Jun	Jul	Ago	Sep	Oct	Nov	Dec
BCC-CSM2-MR	-0.28	-0.17	-0.12	-0.22	-0.16	-0.09	-0.12	-0.23	-0.17	-0.10	-0.19	-0.17
CanESM5	-0.04	-0.02	0.18	0.10	-0.01	-0.10	-0.08	-0.05	0.17	0.05	0.10	-0.03
CMCC-CM2-SR5	-0.02	0.00	0.01	-0.10	-0.13	-0.08	-0.09	-0.17	-0.11	-0.14	-0.13	-0.11
CNRM-ESM2-1	-0.22	-0.13	-0.29	-0.39	-0.44	-0.35	-0.49	-0.60	-0.55	-0.28	-0.36	-0.36
GFDL-CM4	-0.13	-0.01	-0.04	-0.28	-0.34	-0.34	-0.32	-0.40	-0.33	-0.16	-0.34	-0.21
GFDL-ESM4	-0.06	0.02	-0.03	-0.13	-0.31	-0.30	-0.37	-0.45	-0.33	-0.28	-0.18	-0.14
IPSL-CM6A-LR	-0.26	-0.28	-0.33	-0.35	-0.52	-0.69	-0.67	-0.61	-0.68	-0.54	-0.38	-0.30
MIROC6	-0.09	-0.01	-0.01	-0.09	-0.19	-0.16	-0.12	-0.17	-0.12	-0.16	-0.17	-0.14
MPI-ESM1-2-HR	-0.29	-0.21	-0.24	-0.39	-0.47	-0.52	-0.41	-0.48	-0.40	-0.39	-0.44	-0.35
MPI-ESM1-2-LR	-0.10	-0.03	-0.06	-0.18	-0.17	-0.02	-0.04	-0.09	-0.22	-0.11	0.01	-0.04
MRI-ESM2-0	-0.24	-0.25	-0.29	-0.30	-0.30	-0.26	-0.31	-0.21	-0.30	-0.06	-0.22	-0.20
NESM3	-0.13	-0.08	-0.06	-0.18	-0.41	-0.37	-0.34	-0.11	-0.24	-0.28	-0.37	-0.22
Multi-model	-0.15	-0.10	-0.11	-0.21	-0.29	-0.28	-0.28	-0.30	-0.27	-0.21	-0.22	-0.19

Para el futuro lejano los mayores cambios absolutos se obtuvieron con el modelo IPSL-CM6A-LR, con una debilitamiento de $\sim 0.65 \text{ m}^2 \text{ s}^{-1}$ entre junio-setiembre

(Tabla 5). También destaca CanESM5, debido a presenta una mayor cantidad de meses con incremento en el transporte durante el futuro lejano (contrario los resultados explicados previamente) en comparación con el resto de modelos del CMIP6 (Tabla 5); en este caso los mayores cambios ocurren durante marzo-abril y setiembre-noviembre, alcanzando un aumento del 27.9 % durante marzo.

Tabla 6. P25, P50 (mediana), P75 y media de las diferencias entre los valores del transporte de Ekman (en $\text{m}^2 \text{s}^{-1}$) correspondientes el futuro lejano respecto al histórico sobre la región norte, para los 12 modelos del CMIP6 y la media multimodelo (celda gris). La coloración de cada celda indica si los cambios son positivos (rojo) o negativos (azul), mientras su intensidad es proporcional a la magnitud del cambio. Para la media multimodelo, los valores resaltados en “negrita” indican robustez en los resultados (al menos 8 de los 12 modelos coinciden en la dirección del cambio o signo), mientras que las celdas con contorno más grueso indican que el cambio en la media multimodelo es mayor que desviación estándar de los cambios de cada modelo individual.

Región norte [3.25° - 8° S]	Transporte de Ekman			
	Futuro Lejano - Histórico			
	P25	P50	P75	Media
BCC-CSM2-MR	-0.154	-0.177	-0.162	-0.162
CanESM5	0.079	0.056	-0.053	-0.011
CMCC-CM2-SR5	-0.005	-0.044	-0.128	-0.073
CNRM-ESM2-1	-0.242	-0.330	-0.485	-0.363
GFDL-CM4	-0.135	-0.251	-0.356	-0.261
GFDL-ESM4	-0.067	-0.196	-0.346	-0.239
IPSL-CM6A-LR	-0.236	-0.359	-0.616	-0.432
MIROC6	-0.024	-0.084	-0.183	-0.115
MPI-ESM1-2-HR	-0.246	-0.344	-0.521	-0.390
MPI-ESM1-2-LR	-0.034	-0.054	-0.112	-0.079
MRI-ESM2-0	-0.133	-0.183	-0.343	-0.252
NESM3	-0.134	-0.256	-0.340	-0.256
Multi-model	-0.121	-0.185	-0.298	-0.220

También analizamos los cambios promedio de cada estadístico (media, mediana, P25 y P75) correspondientes a cada periodo de evaluación. Durante el periodo futuro cercano el transporte de Ekman mar adentro muestra cambios mínimos relativos al periodo histórico según la media multimodelo. La media de los datos para este periodo es de $1.76 \text{ m}^2 \text{ s}^{-1}$, frente al $1.77 \text{ m}^2 \text{ s}^{-1}$ durante el periodo histórico, representando una reducción de apenas 0.01 %; los percentiles 25 y 75 mostraron cambios similares. MPI-ESM1-2-HR y NESM3 muestran una reducción en el transporte de ~6 %, mientras que para CNRM-ESM2-1 la reducción de $0.24 \text{ m}^2 \text{ s}^{-1}$ representó el 13.3%. MIROC6 muestra un incremento de 5.5% ($0.1 \text{ m}^2 \text{ s}^{-1}$). Los ocho modelos restantes no muestran cambios superiores al 5 % o al $0.1 \text{ m}^2 \text{ s}^{-1}$.

Para el periodo futuro intermedio, la media multimodelo muestra una reducción promedio del transporte de $0.08 \text{ m}^2 \text{ s}^{-1}$ (4.61 %); los percentiles muestran cambios similares. CNRM-ESM2-1, GFDL-CM4, IPSL-CM6A-LR, MPI-ESM1-2-HR y NESM3 muestran una reducción de la media superior al 5 % (y superior al 10 %, salvo para IPSL-CM6A-LR). Entre estos destaca CNRM-ESM2-1, indicando valores promedio disminuidos en $0.29 \text{ m}^2 \text{ s}^{-1}$ (16.44 %). Solo CanESM5 indica un incremento en el transporte ($0.14 \text{ m}^2 \text{ s}^{-1}$, 7.59 %). Los seis modelos restantes muestran cambios por debajo del 5 % o del $0.1 \text{ m}^2 \text{ s}^{-1}$.

Para el periodo futuro lejano (Tabla 6), los valores promedio para la media multimodelo se redujeron en $0.22 \text{ m}^2 \text{ s}^{-1}$ (12.42 %). El P25 se redujo en $0.12 \text{ m}^2 \text{ s}^{-1}$ (14.16 %) para la media multimodelo, mientras que el P75 se redujo en $0.3 \text{ m}^2 \text{ s}^{-1}$ (11.2 %). Los cambios proyectados según la media multimodelo en la media y percentiles son robustos. La reducción en la media proyectada según los modelos

CNRM-ESM2-1, IPSL-CM6A-LR y MPI-ESM1-2-HR superó el 20 %; destacando el IPSL-CM6A-LR con una reducción de $0.43 \text{ m}^2 \text{ s}^{-1}$ (25.24 %). Los modelos GFDL-CM4, GFDL-ESM4, MRI-ESM2-0 y NESM3 mostraron una reducción superior al reducción del 10 %. CanESM5 prácticamente no muestra cambios en la condición promedio, aunque es el único modelo con cambios positivos en el P25 y la mediana (9 y 4 % respectivamente). El resto de modelos mantienen los cambios negativos en los percentiles (Tabla 6).




Figura 34. Similar a la Figura 33, pero para la región sur (datos entre 8°-18.5° S).

De manera análoga a lo realizado en la zona norte, se replicaron los análisis para la región centro-sur frente a Perú (datos entre 10°-18.5° S, Figura 34a).

Los cambios porcentuales mensuales para la media, mediana (P50), P25 y P75 sobre la región centro-sur se muestran en las Figuras 34c-f. La Figura 34b muestra los valores mensuales promedio de los percentiles 25, 50 y 75 según la media multimodelo para la región centro-sur durante el periodo histórico, así como la dispersión intermodelo (nube), evidenciando una representación robusta de los percentiles del transporte de Ekman (principalmente para el P25 y P50). Acorde con los cambios en el viento *alongshore* (Figura 25) y en los valores absolutos del transporte de Ekman (Figura 32), los cambios porcentuales en esta región son mínimos y no robustos en el periodo futuro. Solo durante noviembre-diciembre y febrero se muestran cambios de 7-10 % para el futuro lejano (no robusto).

Tabla 7. Análogo a la Tabla 5, pero para la región sur (datos entre 10°-18.5° S).

Región sur [10° - 18.5° S]	Transporte de Ekman											
	Futuro Lejano - Histórico											
	Jan	Feb	Mar	Apr	May	Jun	Jul	Ago	Sep	Oct	Nov	Dec
BCC-CSM2-MR	-0.02	-0.04	-0.05	-0.05	0.03	0.07	0.04	-0.02	0.05	0.10	0.01	0.02
CanESM5	0.06	0.08	0.17	0.19	0.25	0.15	0.15	0.09	0.25	0.15	0.16	0.08
CMCC-CM2-SR5	0.07	0.05	0.07	0.09	0.08	0.07	0.13	0.08	0.16	0.19	0.17	0.07
CNRM-ESM2-1	-0.13	-0.10	-0.14	-0.17	-0.14	-0.13	-0.24	-0.27	-0.29	-0.07	-0.14	-0.18
GFDL-CM4	-0.02	0.01	-0.03	-0.06	-0.06	-0.07	0.02	-0.11	-0.08	0.05	-0.05	0.04
GFDL-ESM4	0.01	0.02	-0.01	0.01	0.01	0.02	0.00	-0.08	-0.05	-0.10	0.07	0.08
IPSL-CM6A-LR	-0.01	0.02	0.03	-0.01	-0.05	-0.12	-0.02	-0.01	-0.13	-0.08	0.05	0.01
MIROC6	0.04	0.02	-0.01	0.02	0.00	0.08	0.04	-0.02	0.01	-0.01	0.03	0.03
MPI-ESM1-2-HR	0.04	0.02	-0.02	-0.04	-0.02	-0.04	0.02	0.03	0.05	0.03	-0.06	0.02
MPI-ESM1-2-LR	0.01	0.05	0.04	-0.04	-0.02	0.06	0.06	0.02	-0.10	-0.02	0.10	0.01
MRI-ESM2-0	-0.01	0.00	-0.01	-0.02	-0.03	0.02	0.00	0.07	-0.03	0.18	0.05	0.04
NESM3	-0.07	-0.05	-0.04	-0.13	-0.22	-0.14	-0.17	0.04	-0.17	-0.20	-0.12	-0.12
Multi-model	0.00	0.01	0.00	-0.02	-0.01	0.00	0.00	-0.01	-0.03	0.02	0.02	0.01

Agregando información sobre la Figura 34c, estacionalmente los cambios absolutos durante invierno-primavera-verano son ligeramente positivos, mientras que para el otoño son negativos. Para los modelos globales de forma individual, nuevamente se destacan: CanESM5, CMCC-CM2-SR5, CNRM-ESM2-1 y NESM3. CanESM5 muestra un incremento general del transporte durante el futuro lejano, con picos de cambio absoluto durante mayo y setiembre de $0.25 \text{ m}^2 \text{ s}^{-1}$ (21.7 % y 18.85 % respectivamente); mientras que el cambio porcentual más grande se obtuvo durante marzo (27.43 %). Según CMCC-CM2-SR5, los mayores cambios durante el futuro lejano ocurren entre setiembre-noviembre, con un incremento medio de $\sim 18 \text{ m}^2 \text{ s}^{-1}$ (~ 17 %). Por otro lado, CNRM-ESM2-1 muestra resultados diferentes en el futuro lejano, con una reducción de aproximadamente $0.25 \text{ m}^2 \text{ s}^{-1}$ (~ 17.5 %); aunque porcentualmente los cambios más grandes se mostraron durante diciembre-abril, alcanzando un pico de 30.22 % durante marzo. NESM3 muestra una reducción del transporte promedio a lo largo del año (salvo agosto); el pico de reducción absoluta ocurre en mayo ($0.22 \text{ m}^2 \text{ s}^{-1}$, 16.5 %) y el de reducción porcentual durante diciembre (20.2 %, $0.12 \text{ m}^2 \text{ s}^{-1}$). Para resto de los modelos los cambios obtenidos se mantienen por debajo de 10-12 %. Para noviembre-diciembre y febrero, al menos 8 de los 12 modelos globales muestran un incremento en el transporte de Ekman. Ocurre lo mismo durante abril, pero proyectándose una reducción. Para los meses restantes, los cambios multimodelo sobre la región sur no son robustos (Tabla 7).

La región sur es la que muestra pocos cambios en el transporte de Ekman. Los cambios multimodelo en la media y percentiles promedio de cada periodo estuvieron por debajo del 0.5 % para los futuros cercano e intermedio. Para el futuro

lejano, el promedio multimodelo indica una reducción de 0.27 % en la media, un incremento de 1.04 % en el P25 y una reducción de 0.65 % en el P75. Los modelos con mayores cambios en el periodo futuro fueron CanESM5, CMCC-CM2-SR5, CNRM-ESM2-1 y NESM3, aunque entre ellos hubo resultados opuestos. Para el futuro lejano, CanESM5 y CMCC-CM2-SR5 indican un aumento en la media del 17.58 % ($0.17 \text{ m}^2 \text{ s}^{-1}$) y 11.14 % ($0.1 \text{ m}^2 \text{ s}^{-1}$) respectivamente. Por el contrario, CNRM-ESM2-1 y NESM3 muestran un debilitamiento de 17.4 % ($0.16 \text{ m}^2 \text{ s}^{-1}$) y 14.37 % ($0.15 \text{ m}^2 \text{ s}^{-1}$) respectivamente (Tabla 8). Para estos modelos, los percentiles mostraron cambios similares a la media. Los ocho modelos globales restantes mostraron cambios en la media menores a 5-6 %. Estos cambios mínimos hacen que los resultados multimodelo no sean robustos. Solamente para el caso del P75, durante el futuro lejano, se obtiene una coincidencia en la dirección del cambio (signo) para al menos 8 de los 12 modelos globales (Tabla 8).

Tabla 8. Análogo a la Tabla 6, pero para la región sur (datos entre 10°-18.5° S).

Región sur [10° - 18.5° S]	Transporte de Ekman			
	Futuro Lejano - Histórico			
	P25	P50	P75	Media
BCC-CSM2-MR	-0.037	-0.028	0.007	-0.018
CanESM5	0.108	0.178	0.199	0.167
CMCC-CM2-SR5	0.056	0.101	0.137	0.103
CNRM-ESM2-1	-0.095	-0.149	-0.222	-0.161
GFDL-CM4	0.000	-0.027	-0.070	-0.047
GFDL-ESM4	0.010	0.026	-0.011	0.002
IPSL-CM6A-LR	0.014	-0.012	-0.057	-0.026
MIROC6	0.018	0.016	0.008	0.011
MPI-ESM1-2-HR	0.013	0.003	-0.020	-0.008
MPI-ESM1-2-LR	0.032	0.018	0.012	0.019
MRI-ESM2-0	0.025	0.016	0.030	0.029
NESM3	-0.035	-0.105	-0.223	-0.150
Multi-model	0.005	0.005	-0.009	-0.002

b. Proyecciones del bombeo de Ekman frente a la costa peruana




Figura 35. Cambios absolutos en la media y percentiles 50 (mediana), 25 y 75 del bombeo de Ekman según los futuros cercano (azul), intermedio (verde) y lejano (rojo) por estación y latitud. En cada caso, la línea sólida representa la mediana multimodelo, mientras que la nube de cada curva está delimitada por los percentiles 25 y 75 multimodelo.

La Figura 35 muestra los cambios absolutos de la media, mediana, P25 y P75 en el bombeo de Ekman a lo largo de la costa. Notamos que los cambios en el futuro cercano son mínimos; salvo al norte de 4° S, donde encontramos cambios negativos de hasta $0.1 \text{ m}^2 \text{ s}^{-1}$ durante el invierno y positivos de $\sim 0.08 \text{ m}^2 \text{ s}^{-1}$ durante la primavera. Para el futuro intermedio, los mayores cambios ocurren al norte de 4° S durante invierno-primavera, con un debilitamiento en el bombeo de Ekman superior a $0.1 \text{ m}^2 \text{ s}^{-1}$ para todas las estadísticas. Al sur de 6° S los cambios en el futuro intermedio son mínimos ($< 0.05 \text{ m}^2 \text{ s}^{-1}$). Para el futuro lejano encontramos un debilitamiento superior a $0.1 \text{ m}^2 \text{ s}^{-1}$ al norte de 8° S, sobre todo alrededor de 7° S y al norte de 4° S (donde la reducción excede el $0.2 \text{ m}^2 \text{ s}^{-1}$ durante otoño-invierno-primavera). Para el P75 se muestra una disminución de $\sim 0.1 \text{ m}^2 \text{ s}^{-1}$ entre 10° - 14° S, aumentando también la incertidumbre de este resultado.

De manera análoga a lo realizado para el transporte de Ekman, y teniendo en cuenta los resultados previos, dividimos los análisis en dos regiones: región norte (entre 3.25° - 8° S, Figura 36a) y región centro-sur (entre 10° - 18.5° S, Figura 37a).

Las Figuras 36c-f muestran los cambios porcentuales mensuales para la media, mediana (P50), P25 y P75 del bombeo de Ekman sobre la región norte. Para el futuro cercanos los cambios porcentuales fueron cercanos al 0%, salvo durante marzo para el P25, donde encontramos un fortalecimiento del bombeo superior al 10 % (similar a lo proyectado para el transporte de Ekman). Para el futuro intermedio, se evidencia un debilitamiento de ~ 5 % durante el invierno. Para el P25

la reducción alcanza el 10 % durante julio. Para el futuro lejano los cambios indican un debilitamiento de ~10% para todas las estadísticas; sin embargo, durante el verano (y principalmente para el P50 y P25) la incertidumbre de los resultados se incrementa.




Figura 36. (a) Región norte de evaluación: entre 3.25°-8° S. **(b)** Valores de los percentiles 25, 50 y 75 del bombeo de Ekman mensual en el periodo histórico. Cambios porcentuales mensuales en la **(c)** media y percentiles **(d)** 50, **(e)** 25 y **(f)** 75 del bombeo de Ekman según los futuros cercano (azul), intermedio (verde) y lejano (rojo). En cada caso **(b-f)**, la línea sólida representa la mediana multimodelo, y la nube está delimitada por los percentiles 25 y 75 multimodelo.

Tabla 9. Cambios mensuales en el bombeo de Ekman (en $\text{m}^2 \text{s}^{-1}$) correspondientes el futuro lejano respecto al histórico sobre la región norte, para los 12 modelos del CMIP6 y la media multimodelo (celda gris). La coloración de cada celda indica si los cambios son positivos (rojo) o negativos (azul), mientras su intensidad es proporcional a la magnitud del cambio. Para la media multimodelo, los valores resaltados en “negrita” indican robustez en los resultados (al menos 8 de los 12 modelos coinciden en la dirección del cambio o signo), mientras que las celdas con contorno más grueso indican que el cambio en la media multimodelo es mayor que desviación estándar de los cambios de cada modelo individual.

Región norte [3.25° - 8° S]	Bombeo de Ekman											
	Futuro Lejano - Histórico											
	Jan	Feb	Mar	Apr	May	Jun	Jul	Ago	Sep	Oct	Nov	Dec
BCC-CSM2-MR	-0.08	-0.14	-0.10	-0.17	-0.11	-0.08	-0.09	-0.15	-0.10	-0.04	-0.05	0.01
CanESM5	-0.05	-0.03	0.11	0.05	0.04	-0.07	-0.09	-0.08	0.11	0.03	0.03	-0.07
CMCC-CM2-SR5	0.04	0.05	0.08	0.01	0.03	0.00	0.02	-0.03	0.05	0.07	0.08	0.03
CNRM-ESM2-1	-0.17	-0.08	-0.20	-0.23	-0.21	-0.16	-0.31	-0.35	-0.37	-0.16	-0.17	-0.20
GFDL-CM4	-0.09	0.01	-0.03	-0.17	-0.11	-0.22	-0.18	-0.23	-0.19	-0.10	-0.13	-0.05
GFDL-ESM4	-0.04	0.03	-0.04	-0.10	-0.10	-0.15	-0.22	-0.30	-0.23	-0.21	-0.07	-0.05
IPSL-CM6A-LR	-0.04	-0.06	-0.11	-0.11	-0.16	-0.22	-0.18	-0.16	-0.22	-0.14	-0.04	-0.04
MIROC6	0.00	-0.01	-0.06	-0.07	-0.10	-0.03	-0.05	-0.12	-0.09	-0.12	-0.06	-0.04
MPI-ESM1-2-HR	-0.07	-0.11	-0.11	-0.17	-0.17	-0.21	-0.16	-0.17	-0.14	-0.16	-0.19	-0.11
MPI-ESM1-2-LR	0.04	0.09	0.02	-0.06	0.00	0.02	0.01	-0.01	-0.13	-0.06	0.09	0.04
MRI-ESM2-0	-0.10	-0.15	-0.19	-0.14	-0.13	-0.18	-0.25	-0.17	-0.23	-0.05	-0.14	-0.09
NESM3	-0.11	-0.07	-0.02	-0.14	-0.23	-0.20	-0.21	-0.06	-0.20	-0.24	-0.15	-0.17
Multi-model	-0.06	-0.04	-0.05	-0.11	-0.10	-0.12	-0.14	-0.15	-0.14	-0.10	-0.07	-0.06

Teniendo en cuenta los cambios absolutos mensuales promedio del bombeo en la región norte, para el futuro cercano los cambios absolutos son mínimos. El futuro intermedio proyecta un debilitamiento permanente, con un pico de $\sim 0.08 \text{ m}^2 \text{s}^{-1}$ durante julio-agosto (robusto). Para el futuro lejano (Tabla 9), los mayores cambios absolutos se evidenciaron entre julio-setiembre (invierno), con un pico de reducción durante agosto ($0.15 \text{ m}^2 \text{s}^{-1}$). En general, para el futuro lejano los cambios mensuales en el bombeo son robustos. Además, entre abril-octubre los cambios según la media

multimodelo superan la desviación estándar de los cambios de cada modelo de forma individual (Tabla 9).

Tabla 10. P25, P50 (mediana), P75 y media de las diferencias entre los valores del bombeo de Ekman (en $\text{m}^2 \text{s}^{-1}$) correspondientes el futuro lejano respecto al histórico sobre la región norte, para los 12 modelos del CMIP6 y la media multimodelo (celda gris). La coloración de cada celda indica si los cambios son positivos (rojo) o negativos (azul), mientras su intensidad es proporcional a la magnitud del cambio. Para la media multimodelo, los valores resaltados en “negrita” indican robustez en los resultados (al menos 8 de los 12 modelos coinciden en la dirección del cambio o signo), mientras que las celdas con contorno más grueso indican que el cambio en la media multimodelo es mayor que desviación estándar de los cambios de cada modelo individual.

Región norte [3.25° - 8° S]	Bombeo de Ekman			
	Futuro Lejano - Histórico			
	P25	P50	P75	Media
BCC-CSM2-MR	-0.080	-0.100	-0.083	-0.075
CanESM5	0.022	0.054	0.030	0.029
CMCC-CM2-SR5	0.019	0.047	0.079	0.046
CNRM-ESM2-1	-0.131	-0.197	-0.271	-0.192
GFDL-CM4	-0.058	-0.081	-0.109	-0.077
GFDL-ESM4	-0.066	-0.070	-0.095	-0.079
IPSL-CM6A-LR	-0.040	-0.068	-0.104	-0.059
MIROC6	-0.032	-0.031	-0.040	-0.026
MPI-ESM1-2-HR	-0.098	-0.113	-0.139	-0.107
MPI-ESM1-2-LR	0.034	-0.030	-0.073	-0.013
MRI-ESM2-0	-0.086	-0.056	-0.040	-0.043
NESM3	-0.079	-0.172	-0.225	-0.151
Multi-model	-0.054	-0.070	-0.082	-0.060

Específicamente para cada modelo global, durante los futuros cercano e intermedio los mayores cambios porcentuales se dieron durante el verano (noviembre-marzo), con algunos modelos indicando una reducción de ~17% (CNRM-ESM2-1 y

NESM3) y otros señalando un aumento de $\sim 15\%$ (CanESM5, CMCC-CM2-SR5, GFDL-ESM4, MIROC6, y MPI-ESM1-2-LR). Durante el invierno (junio-agosto), la mayoría de modelos indicaron cambios por debajo del 10% , aunque durante esta estación los cambios absolutos son mayores. Para el futuro lejano se destacan los cambios mensuales según CNRM-ESM2-1, con una reducción de $\sim 0.35 \text{ m}^2 \text{ s}^{-1}$ ($\sim 23.05\%$) entre julio y setiembre; y según GFDL-ESM4, con una reducción de $\sim 0.26 \text{ m}^2 \text{ s}^{-1}$ ($\sim 17.33\%$) entre julio y octubre. Solo CMCC-CM2-SR5 muestra un incremento consistente durante verano ($\sim 8\text{-}10\%$).

Para la región norte y durante el futuro cercano, el bombeo de Ekman mar adentro no muestra cambios en relación al periodo histórico, según la media multimodelo. 5 de los 12 modelos globales (CanESM5, CMCC-CM2-SR5, GFDL-ESM4, MIROC6 y MPI-ESM1-2-LR) indican un incremento en los valores promedio del bombeo. Las mayores diferencias en la media se obtuvieron con CNRM-ESM2-1, con una reducción de $0.11 \text{ m}^2 \text{ s}^{-1}$ (13.57%) en la media, de $0.09 \text{ m}^2 \text{ s}^{-1}$ (20.5%) en el P25 y de $0.14 \text{ m}^2 \text{ s}^{-1}$ (11%) en el P75. BCC-CSM2-MR e IPSL-CM6A-LR muestran los menores cambios, por debajo del 1.5% en la media y percentiles.

Para el futuro intermedio, la media multimodelo indica cambios mínimos en el bombeo; pasando de $0.81 \text{ m}^2 \text{ s}^{-1}$ (histórico) a $0.78 \text{ m}^2 \text{ s}^{-1}$ (futuro intermedio), representando una reducción del 2.72% . Asimismo, los percentiles 25 y 75 del bombeo mostraron una reducción de $0.02 \text{ m}^2 \text{ s}^{-1}$ (4.11%) y $0.03 \text{ m}^2 \text{ s}^{-1}$ (2.31%) respectivamente. 7 de 12 modelos muestran valores promedio menores en comparación al periodo histórico, destacando CNRM-ESM2-1 (reducción del promedio de $0.15 \text{ m}^2 \text{ s}^{-1}$, 18.81%) y NESM3 (reducción promedio de $0.12 \text{ m}^2 \text{ s}^{-1}$,

13.69 %). 4 de los modelos (CanESM5, CMCC-CM2-SR5, GFDL-ESM4 y MIROC6) aumentan su valor promedio, destacando CanESM5 (aumento del promedio de $0.08 \text{ m}^2 \text{ s}^{-1}$, 9.03 %). Solo MPI-ESM1-2-LR no evidencia cambios en la media ($<0.25 \%$).

Para el periodo futuro lejano (Tabla 10), la media multimodelo muestra una disminución de $0.06 \text{ m}^2 \text{ s}^{-1}$; asimismo, el P25 se redujo en $0.05 \text{ m}^2 \text{ s}^{-1}$ y el P75 se redujo en $0.08 \text{ m}^2 \text{ s}^{-1}$. Solo CanESM5 y CMCC-CM2-SR5 muestran un incremento en el valor promedio del bombeo de Ekman; con $0.03 \text{ m}^2 \text{ s}^{-1}$ (3.36 %) para CanESM5, y $0.05 \text{ m}^2 \text{ s}^{-1}$ (5.53 %) para CMCC-CM2-SR5. Las mayores diferencias en la media se obtuvieron con CNRM-ESM2-1, con una reducción de $0.19 \text{ m}^2 \text{ s}^{-1}$ (24.25 %) en la media. También destacan los modelos MPI-ESM1-2-HR y NESM3, con reducciones en la media de $0.11 \text{ m}^2 \text{ s}^{-1}$ (13.71 %) y $0.17 \text{ m}^2 \text{ s}^{-1}$ (17.28 %) respectivamente. Los modelos restantes mostraron una reducción en los valores promedio del bombeo de Ekman de entre 2-10 %, aportando a la robustez de los resultados en la región norte (Tabla 10).

Similar a lo realizado para la región norte, se realizaron los análisis del bombeo sobre la región centro-sur frente al Perú (datos entre 10° - 18.5° S).

Las Figuras 37c-f muestran los cambios porcentuales mensuales para la media, mediana (P50), P25 y P75 en la región centro-sur frente al Perú. La Figura 37b muestra el ciclo estacional de los percentiles 25, 50 y 75 según la media multimodelo del periodo histórico; evidenciando una baja dispersión intermodelo. En general los cambios en estas estadísticas están por debajo del $\pm 5 \%$ para todos

los periodos futuros. Además, entre agosto-diciembre la incertidumbre de estos resultados se incrementa, sobre todo para el P25 (Figuras 37c-f).




Figura 37. Análogo a la Figura 36, pero para la región sur (datos entre 10° - 18.5° S).

Complementando lo expuesto, para el futuro lejano los mayores cambios absolutos en el bombeo sobre la región centro-sur se obtuvieron durante noviembre-abril, con un pico de $0.03 \text{ m}^2 \text{s}^{-1}$ en enero. Además, para este periodo los cambios son robustos durante enero-junio (Tabla 11), aunque los valores mensuales promedio no exceden a la desviación estándar de los cambios para los modelos de manera individual. En ese sentido y de manera más específica, para el futuro lejano CanESM5 muestra

mayores incrementos entre marzo-mayo ($0.06 \text{ m}^2 \text{ s}^{-1}$, $\sim 9 \%$) y setiembre-noviembre ($0.09 \text{ m}^2 \text{ s}^{-1}$, $\sim 12.67 \%$). CMCC-CM2-SR5 muestra un aumento de $0.12 \text{ m}^2 \text{ s}^{-1}$ (17.81%) durante setiembre-noviembre. Para CNRM-ESM2-1 los principales cambios (reducción del bombeo) ocurren durante setiembre ($0.18 \text{ m}^2 \text{ s}^{-1}$, 21.12%), aunque entre noviembre-marzo también se registra una disminución promedio considerable ($0.15 \text{ m}^2 \text{ s}^{-1}$, 23%). NESM3, muestra una reducción de $\sim 0.1 \text{ m}^2 \text{ s}^{-1}$ (15.89%) durante octubre-febrero, con picos de $0.12 \text{ m}^2 \text{ s}^{-1}$ durante octubre y diciembre (15.22 y 20.58% respectivamente). Los modelos globales restantes muestran cambios en el bombeo por debajo del 10% para la mayoría de meses.

Tabla 11. Análogo a la Tabla 9, pero para la región sur (datos entre 10° - 18.5° S).

Región sur [10° - 18.5° S]	Bombeo de Ekman											
	Futuro Lejano - Histórico											
	Jan	Feb	Mar	Apr	May	Jun	Jul	Ago	Sep	Oct	Nov	Dec
BCC-CSM2-MR	-0.04	-0.05	-0.05	-0.03	0.00	0.00	-0.03	-0.05	0.00	0.01	-0.03	0.02
CanESM5	-0.05	-0.02	0.06	0.05	0.08	0.04	0.06	0.04	0.12	0.08	0.07	-0.01
CMCC-CM2-SR5	0.02	0.02	0.04	0.07	0.02	-0.03	0.06	0.03	0.11	0.14	0.10	0.02
CNRM-ESM2-1	-0.16	-0.12	-0.15	-0.14	-0.09	-0.12	-0.17	-0.13	-0.18	-0.09	-0.15	-0.15
GFDL-CM4	-0.02	0.02	-0.04	-0.04	-0.04	-0.07	0.01	-0.07	-0.03	0.02	-0.06	0.04
GFDL-ESM4	0.00	-0.01	-0.05	0.00	-0.01	-0.01	-0.01	-0.04	-0.01	-0.08	0.00	0.06
IPSL-CM6A-LR	-0.02	0.01	0.03	0.03	0.00	-0.03	0.08	0.09	-0.02	-0.04	0.00	-0.04
MIROC6	0.02	0.00	-0.05	0.00	0.01	0.11	0.07	0.03	0.03	-0.02	0.02	0.01
MPI-ESM1-2-HR	0.04	-0.01	-0.03	-0.02	-0.01	-0.06	0.00	0.06	0.05	0.00	-0.09	-0.02
MPI-ESM1-2-LR	0.00	0.04	0.02	-0.04	-0.03	-0.01	0.01	0.00	-0.07	-0.08	-0.01	-0.06
MRI-ESM2-0	-0.04	-0.03	-0.02	0.00	0.00	0.00	-0.04	-0.01	-0.05	0.07	-0.02	-0.02
NESM3	-0.08	-0.06	-0.05	-0.11	-0.10	-0.05	-0.05	0.07	-0.09	-0.12	-0.10	-0.12
Multi-model	-0.03	-0.02	-0.02	-0.02	-0.01	-0.02	0.00	0.00	-0.01	-0.01	-0.02	-0.02

Al igual que para el transporte de Ekman, la región sur muestra menos cambios promedio en el bombeo durante el periodo futuro, teniendo en cuenta cada modelo de manera individual y la media multimodelo. Individualmente, los mayores

cambios en el bombeo de Ekman se obtuvieron con CanESM5, CMCC-CM2-SR5, CNRM-ESM2-1 y NESM3, aunque con algunos resultados opuestos (análogo a lo encontrado para el transporte de Ekman). CanESM5 mostró un incremento promedio de $0.02 \text{ m}^2 \text{ s}^{-1}$ (3.44 %), $0.04 \text{ m}^2 \text{ s}^{-1}$ (6.02 %) y $0.05 \text{ m}^2 \text{ s}^{-1}$ (7.66 %), para los futuros cercano, intermedio y lejano respectivamente. CMCC-CM2-SR5 muestra un incremento de $0.03 \text{ m}^2 \text{ s}^{-1}$ (3.32 %), $0.05 \text{ m}^2 \text{ s}^{-1}$ (6.89 %) y $0.05 \text{ m}^2 \text{ s}^{-1}$ (7.66 %), para los futuros cercano, intermedio y lejano respectivamente. En cuanto a CNRM-ESM2-1, este redujo su promedio en $0.07 \text{ m}^2 \text{ s}^{-1}$ (10.6 %), $0.09 \text{ m}^2 \text{ s}^{-1}$ (13.37 %) y $0.13 \text{ m}^2 \text{ s}^{-1}$ (19.97 %), para los futuros cercano, intermedio y lejano respectivamente. NESM3 muestra cambios negativos en la media de $0.05 \text{ m}^2 \text{ s}^{-1}$ (6.88 %), $0.07 \text{ m}^2 \text{ s}^{-1}$ (10.22 %) y $0.08 \text{ m}^2 \text{ s}^{-1}$ (12.24 %), para los futuros cercano, intermedio y lejano respectivamente. Los modelos globales restantes muestran cambios por debajo del 5 % (Tabla 12).

Tabla 12. Análogo a la Tabla 10, pero para la región sur (datos entre 10° - 18.5° S).

Región sur [10° - 18.5° S]	Bombeo de Ekman			
	Futuro Lejano - Histórico			
	P25	P50	P75	Media
BCC-CSM2-MR	-0.029	-0.031	-0.026	-0.029
CanESM5	0.075	0.075	0.049	0.054
CMCC-CM2-SR5	0.046	0.057	0.065	0.054
CNRM-ESM2-1	-0.089	-0.137	-0.178	-0.133
GFDL-CM4	0.005	-0.015	-0.039	-0.021
GFDL-ESM4	0.002	-0.009	-0.017	-0.009
IPSL-CM6A-LR	0.030	0.010	0.000	0.013
MIROC6	0.019	0.012	0.014	0.013
MPI-ESM1-2-HR	0.019	-0.001	-0.022	-0.007
MPI-ESM1-2-LR	0.001	-0.012	-0.029	-0.014
MRI-ESM2-0	0.005	-0.013	-0.020	-0.009
NESM3	-0.035	-0.073	-0.114	-0.081
Multi-model	-0.001	-0.013	-0.021	-0.013

5. DISCUSIONES

En la presente tesis se realizó la reducción de escala (“*downscaling*”) de los vientos superficiales frente al Perú para 12 modelos globales del CMIP6, bajo los experimentos histórico y escenario futuro SSP5-8.5. El método de *downscaling* fue del tipo estadístico y basado en la inteligencia artificial, en particular en el uso de redes neuronales convolucionales (CNN). Los datos de viento a alta resolución (obtenidos a partir de la aplicación del modelo estadístico) se utilizaron para determinar el impacto del cambio climático (bajo el escenario SSP5-8.5) sobre el transporte y bombeo de Ekman en el sistema de afloramiento peruano, así como la robustez del mismo.

5.1. SOBRE LA ARQUITECTURA DE LA RED NEURONAL

Las diferentes arquitecturas/topologías de redes neuronales evaluadas fueron tomadas a partir de estudios previos para la reducción de escala (*downscaling*) de variables climáticas como temperatura superficial del aire y precipitación a escala diaria y sobre diferentes regiones europeas (Baño-Medina et al. 2020, Quesada-Chacón et al. 2022, Doury et al. 2022).

Los primeros resultados indicaron un mejor performance con la arquitectura *coding-decoding* (C-D), pudiendo representar de mejor manera los vientos superficiales (ambas componentes) para diferentes bases de datos, en comparación con los modelos lineales CNN 1 y CNN 2. La principal diferencia entre las arquitecturas es su grado de abstracción. El modelo C-D logra compactar los datos de entrada, en el sentido de que estos son reducidos hasta matrices 2×2 (Figura 10),

con la finalidad de obtener características espaciales cada vez más generales de los predictores (abarcando una subregión cada vez más amplia al recorrer las capas de la red neuronal). Por otro lado, en los modelos CNNs la compactación es menor, apenas reduciendo en pocas unidades la dimensión de la matriz de predictores (Figura 9).

Los resultados encontrados se corresponden con González-Abad et al. (2023), quienes evalúan el comportamiento de diferentes arquitecturas de redes neuronales convolucionales para la reducción de escala temperatura, entre ellas dos similares a las aquí propuestas: CNNs y C-D (CNN-DeepESD y CNN-UNET respectivamente). Sus resultados señalan un mejor desempeño (ligero) por parte del modelo CNN-UNET (con una estructura similar al *coding-decoding*), tanto al ser aplicado sobre la data predictora como al ser aplicado sobre un modelo global en escenario futuro. Cabe resaltar que los métodos de validación empleados por González-Abad et al. (2023) no son exactamente los mismos a los expuestos en este trabajo.

5.2. SOBRE LA ELECCIÓN DE PREDICTORES

Si bien los modelos de redes neuronales brindan la facilidad de manejar múltiples *datasets*, los diferentes preprocesamientos (ver Sección 3.4.b) necesarios para cada uno de los 12 modelos globales evaluados (Tabla 3) hacen engorroso el uso de una lista extensa de predictores. Con el fin de minimizar el tiempo de preprocesamiento, se evaluó la eficiencia del modelo teniendo en cuenta diferentes subconjuntos de predictores.

Se conformaron tres *sets* de predictores:

- **Set 1:** Se tomó como punto de partida los 20 predictores utilizados previamente por Baño-Medina et al. (2020): viento zonal, viento meridional, temperatura del aire, humedad específica, altura geopotencial (cada variables a diferentes niveles de altura: 1000, 850, 700 y 500 hPa); así como datos de variables a nivel superficial (o pocos metros de altura): vientos zonal y meridional a 10 m, temperatura del aire a 2 m y presión superficial. Las variables superficiales de vientos y presión se eligieron siguiendo la línea del trabajo previo de Goubanova et al. (2011). En un inicio se consideró a la temperatura superficial del mar (TSM) como una variable predictora adicional (sugerido también por Goubanova et al. 2011); sin embargo, esta variable no contiene datos continentales, algo necesario para su uso en redes convolucionales. En su lugar (y a pesar de su distinta estructura y forzantes) se consideró la temperatura del aire a 2 m. El número total de variables para este conjunto de predictores es de 24.
- **Set 2:** Se consideraron las mismas variables del *Set 1* a excepción de la altura geopotencial y la humedad específica (en todos los niveles de altura). Estas variables se marginaron con el fin de evaluar el rendimiento del modelo al ser entrenado con los predictores de: viento zonal y meridional, presión y temperatura (a diferentes niveles del altura). El número total de variables para este conjunto de predictores es de 16.
- **Set 3:** Se consideraron las mismas variables del *Set 2* pero únicamente a nivel superficial. Este último conjunto de variables predictoras es el más similar al

utilizado por Goubanova et al. (2011) para el *downscaling* estadístico de vientos. El número total de variables para este conjunto de predictores es de 4.

La comparación de los diferentes *sets* de predictores se realizó teniendo en cuenta la arquitectura CNN 1 y de manera análoga a la validación 1 (ver Sección 3.4.a). Las estadísticas de los criterios de validación (sesgo en la media y percentiles 25 y 75) y el RMSE (*root mean square error*) se muestran en la Figura 38. Para el viento zonal, el RMSE es apenas menor con solo 4 predictores (*Set 3*), el sesgo en la media mejora considerablemente con el *Set 3*, el sesgo en el P25 es apenas más cercano a cero para el *Set 2* (16 predictores), y el sesgo en el P75 mejora con el *Set 3*. Para el viento meridional, el RMSE es apenas menor con el *Set 1* (los 24 predictores), los sesgos en la media y el P25 mejoran con el *Set 3*, y el sesgo en el P75 es prácticamente el mismo con cualquier conjunto de predictores.




Figura 38. Gráfico de cajas para el RMSE y los sesgos en la media y percentiles 25 y 75 entre las salidas del entrenamiento con *Set 1* (S1), *Set 2* (S2) y *Set 3* (S3) de predictores, y las observaciones ASCAT, para cada una de las componentes del viento superficial.

Este pequeño experimento muestra que una mayor cantidad de predictores no necesariamente mejora el entrenamiento de un modelo de redes neuronales, sino que, por el contrario, en ciertos casos puede perjudicarlo; evidenciando la sensibilidad de estos modelo a la cantidad (y calidad) de predictores. De hecho, Goubanova et al. (2011) realizó un experimento similar, usando vientos a 850 y 500 hPa como predictores adicionales (semejante al *Set 2*), sin lograr mejoras en los resultados y optando una menor cantidad de variables predictoras.

5.3. IMPACTO DEL CAMBIO CLIMÁTICO SOBRE EL AFLORAMIENTO COSTERO

Una vez realizado el *downscaling* de los 12 modelos globales del CMIP6 sobre el periodo futuro (2015-2100) bajo el escenario SSP5-8.5 de cambio climático, los resultados obtenidos según el promedio multimodelo evidencian cambios pequeños (<5 %) en la intensidad del viento frente al Perú durante los primeros años del periodo futuro (hasta el 2065). Los últimos años evaluados (2081-2100) muestran de manera robusta un debilitamiento del viento superior al 5 % frente al norte de Perú (3.25°-8° S), alcanzando el 20 % durante el verano (Figura 25). Los resultados durante el verano son consistentes con lo señalado por estudios previos como Goubanova et al. (2011) y Belmadani et al. (2014). Goubanova et al. (2011) realizó el *downscaling* estadístico del modelo IPSL-CM4 (CMIP3) en escenarios de cambio climático (2×CO₂ y 4×CO₂); mostrando vientos más débiles durante el verano (~5 % para el 2×CO₂, y ~10 % para el 4×CO₂), y casi sin cambios durante el invierno (bajo ningún escenario). De manera similar, Belmadani et al. (2014) realizó un *downscaling* dinámico de los vientos frente a Perú-Chile, forzado con

TSM del IPSL-CM4. Sus resultados mostraron vientos más débiles frente a Perú (entre 20-30 % durante el verano, y entre 5-10 % durante el invierno), consistente con nuestros resultados en el norte de Perú. Entre 8°-17° S, la media multimodelo no muestra cambios importantes en el ciclo estacional del futuro lejano (<5 %), contrastando con el debilitamiento de los vientos de verano sobre esta región según Goubanova et al. (2011) y Belmadani et al. (2014), más aún considerando que ambos estudios previos muestran su máximo debilitamiento alrededor de 15° S durante el verano (durante verano e invierno para el caso de Belmadani et al. 2014). Para el invierno y la región centro-sur, los cambios mínimos en el viento (<5 %) se corresponden con lo mostrado en Goubanova et al. (2011). Cabe resaltar que nuestros resultados son poco robustos entre 9°-16° S a lo largo del año. Particularmente para el futuro lejano (2081-2100) del modelo IPSL-CM6A-LR (CMIP6), y haciendo un paralelismo con el IPSL-CM4 (CMIP3), los vientos en la región norte se debilitan entre 15-20 % durante el verano y 10-15 % durante el invierno (Figura 26); acorde con Belmadani et al. (2014), pero distinto a lo mostrado por Goubanova et al. (2011) durante el invierno. En la región centro-sur no se muestra un claro debilitamiento durante el verano según el IPSL-CM6A-LR (Figura 26), algo que sí se muestra con el IPSL-CM4 según Goubanova et al. (2011) y Belmadani et al. (2014); por el contrario, se muestra una intensificación de hasta 10 % alrededor de 18° S durante febrero-marzo.

Por otro lado, Echevin et al. (2020) realizó un *downscaling* dinámico de 3 modelos del CMIP5: CNRM-CM5, IPSL-CM5-MR y GFDL-ESM2M bajo el escenario RCP8.5, mostrando una disminución en el stress del viento (sobre una franja costera

de 100 km entre 7-13° S) de 11 % para CNRM-CM5, 9 % para el IPSL-CM5-MR y un aumento del 2 % para el GFDL-ESM2M. Estos resultados son consistentes con los cambios proyectados de la componente *alongshore* del viento (Figura 26) para el futuro lejano (2081-2100) según el CNRM-ESM2-1 (entre 15-20 %) e IPSL-CM6A-LR (entre 5-10 %). Para el caso de GFDL-ESM4 (Figura 26), si bien se tiene un incremento de ~2 % para los futuros cercano e intermedio, para el futuro lejano prácticamente no se muestran cambios (debilitamiento menor al 5 %). No obstante, los resultados obtenidos por Echevin et al. (2020) son una muestra más de la importancia de analizar el impacto del cambio climático a partir de datos de múltiples modelos globales, debido a las diferencias entre los análisis de cada modelo individual. En ese sentido, autores como Goubanova y Ruiz (2010), Belmadani et al. (2014) y Chamorro et al. (2021) estudiaron los cambios en el viento frente a Perú bajo escenarios de cambio climático teniendo en cuenta datos promedio de múltiples modelos globales. Goubanova y Ruiz (2010) analizaron un conjunto de 12 modelos globales del CMIP3 bajo el escenario SRES A2, encontrando vientos reducidos (hasta 0.2 m s⁻¹) frente a Perú durante el verano e intensificados (hasta 0.3 m s⁻¹) durante el invierno. Esto se corresponde con los resultados obtenidos a partir de la media multimodelo para el futuro lejano durante el verano en la región norte y el invierno alrededor de 18° S, pero contrasta durante el verano en la región centro-sur y el invierno al norte de 16° S. Por su parte y adicional al experimento principal (descrito en el párrafo anterior), Belmadani et al. (2014) realiza un *downscaling* dinámico de vientos tomando como forzante un promedio multimodelo (de 9 modelos del CMIP3) de la TSM, obteniendo una debilitamiento del viento frente al norte de Perú y una intensificación en otras

latitudes. Esto es consistente con nuestros resultados en la región norte y alrededor de 18° S (Figuras 23 y 25), los cuales son robustos. Así mismo, los resultados del *downscaling* dinámico de datos promedio de 31 modelos globales del CMIP5 presentados por Chamorro et al. (2021) indican, según sus simulaciones WRF21 y WRF7, un debilitamiento en los vientos (5-10 %) en los extremos norte (5°-9° S) y sur (14°-17° S) del Perú durante noviembre-febrero, manteniéndose sin cambios (intensificación menor al 5 %) durante el invierno. Entre 9°-14° S ocurre lo contrario, con vientos que tienden a intensificarse durante otoño-invierno un ~5 % con WRF21 y un ~10 % con WRF7 y manteniéndose sin cambios durante el verano (con ambos modelos). En nuestro caso y durante el verano, esto se corresponde con la reducción del viento superior al 5 % al norte de 8° S según la media multimodelo, pero es contrario a la leve intensificación (hasta 5 %) del viento en la zona sur (Figuras 23 y 25). Para el invierno, el debilitamiento del viento en el norte de Perú contrasta con los resultados obtenidos por Chamorro et al. (2021); mientras que en la zona central (8°-17.5° S) se puede identificar una leve intensificación (~2 %) entre 12°-15° S (poco robusto), similar a lo mostrado en Goubanova y Ruiz (2010) y Chamorro et al. (2021).

Nuestros resultados para las proyecciones del viento en el futuro, indican una mayor probabilidad (entre 10-20 % más) encontrar vientos débiles a escala diaria en condiciones de cambio climático (Figuras 26e-h) frente a la costa norte del Perú. Esto impactaría en el ecosistema sobre todo durante el verano, donde los vientos de por sí son más débiles y donde eventos como las olas de calor marina son más propensos (Pietri et al. 2021). Cabe resaltar que estamos considerando como viento

débil a aquel que esté por debajo del percentil 25 histórico por latitud y mes. Para los resultados al sur de 10° S, la probabilidad de vientos débiles se mantiene; salvo al sur de 16° S durante el verano, donde esta probabilidad se reduce en un 5 %, indicando vientos ligeramente más intensos (Figuras 26e-h).

En cuanto al *curl* del *stress* del viento, los cambios para el futuro cercano e intermedio según la media multimodelo apenas rondan el 5 %, además de que estos cambios son poco robustos. Para el futuro lejano el *curl* se hace menos negativo (10-20 %) al norte de 15° S, resultado robusto salvo durante febrero-marzo. Esto se corresponde con los resultados de Belmadani et al. (2014) al norte de 15° S. La principal contradicción se da entre 15°-18° S, donde Belmadani et al. (2014) muestra valores más positivos (15-20 %) del *curl*, en comparación a la tendencia a valores más negativos (hasta 10% durante invierno) alrededor de 17° S. No obstante, cabe resaltar que frente a la costa peruana entre 14°-18° S, la representación del *curl stress* del viento mostrada por Belmadani et al. (2014) mediante la aplicación del modelo LMDz-ESP05 sobre el escenario PI (ver su Figura 7) muestra diferencias con nuestra representación al aplicar el modelo estadístico sobre el escenario histórico multimodelo (Figura 27), siendo la última en mención la que más se asemeja a las observaciones ASCAT (Figura suplementaria 1b). Esto se puede explicar a partir de las diferencias entre la simulación de control LMDz-ESP05 y los datos de SCOW (2000-2008), con un *drop-off* del viento más pronunciado entre 12°-14° S y menos pronunciado entre 14°-17° S a partir de SCOW, y contrario a LMDz-ESP05 (ver contornos en su Figura 4b, c), haciendo que el modelo LMDz-ESP05 muestre un *curl* más negativo

entre 14°-17° S. Además de que la caída en la intensidad del viento desde la parte oceánica hacia la costa se interrumpe con LMDz-ESP05 entre de 14°-17° S (en contraste con SCOW), generando una lengua de valores positivos del *curl* entre 100-200 km frente a la costa.

En lo que se refiere al transporte y bombeo de Ekman, estudios previos han evaluado el posible impacto del cambio climático en el afloramiento frente a Perú a través del uso de modelos de regionalización dinámicos (Oerder et al. 2015; Echevin et al. 2020) y estadísticos (Goubanova y Ruiz 2010; Echevin et al. 2011). Echevin et al. (2011) utiliza un modelo dinámico, forzado por los vientos resultantes del *downscaling* estadístico de Goubanova et al. (2011), mostrando una reducción en el transporte durante el verano (10-20 %) y un aumento durante el invierno (5-10 %). Salvo en la región norte y durante el verano, esto no se corresponde con lo mostrado según la media multimodelo durante el futuro lejano; por el contrario, para el modelo IPSL-CM6A-LR en el futuro lejano y en la región centro-sur se muestra un aumento de ~5 % en verano y una disminución de hasta 10 % en invierno (Tabla 7). Asimismo, Oerder et al. (2015) realiza un *downscaling* dinámico del IPSL-CM4 frente a Perú-Chile, mostrando una reducción en el transporte de ~22 % entre 7°-13° S durante todo el ciclo estacional para el escenario 4xCO₂. Este resultado es congruente con la reducción del transporte según la media multimodelo (~12 %) y el IPSL-CM6A-LR (~25 %) en la región norte durante el periodo futuro lejano. Oerder et al. (2015) también analizan los cambios en el bombeo de Ekman, evidenciando una reducción de ~16 % entre 7°-13° S bajo el escenario 4xCO₂; consecuente con la reducción del bombeo en la región norte para

la media multimodelo ($\sim 7\%$) y el IPSL-CM6A-LR ($\sim 8\%$). Por otra parte, el análisis multimodelo presentado en Goubanova y Ruiz (2010) indica un incremento en el transporte de hasta 6% frente a Perú (todo el litoral) durante el invierno bajo el escenario SRES A2, contrario a nuestros resultados. Según Echevin et al. (2020), el transporte de Ekman entre 7° - 13° S muestra un debilitamiento con los modelos CNRM-CM5 (12 %) e IPSL-CM5-MR (11 %) bajo el escenario RCP8.5, en consistencia con la reducción en la región norte con los modelos CNRM-ESM2-1 ($\sim 20\%$) e IPSL-CM6A-LR ($\sim 25\%$) durante el periodo futuro lejano. Para el modelo GFDL-ESM4 el transporte disminuye un 13% durante el futuro lejano, en contraste con el fortalecimiento de 2 % obtenido a partir del GFDL-ESM2M mostrado en Echevin et al. (2020).




Figura 39. Perfil del transporte total (panel izquierdo, en $\text{m}^2 \text{s}^{-1}$, transporte de Ekman + bombeo de Ekman) para el periodo histórico (negro) y futuros cercano (azul), intermedio (verde) y lejano (rojo), según el promedio multimodelo. Cambios relativos proyectados (colores $\text{m}^2 \text{s}^{-1}$ y contornos en %) en el ciclo estacional promedio del transporte total para los periodos futuro cercano, intermedio y lejano, según el promedio multimodelo. Los valores no sombreados indican robustez en los cambios.




Figura 40. Gráfico de barras del transporte total (en $\text{m}^2 \text{s}^{-1}$, transporte de Ekman + bombeo de Ekman) mensual según la media multimodelo durante los periodos histórico (gris) y futuros cercano (azul), intermedio (verde) y lejano (rojo) según el promedio multimodelo, para la región **(a)** norte ($3.25^\circ\text{-}8^\circ \text{S}$) y **(b)** sur ($8^\circ\text{-}18.5^\circ \text{S}$). La porción de las barras rellena indica el transporte, mientras que la porción rayada indica el bombeo. Debajo del gráfico de barras se indica el porcentaje de contribución del transporte de Ekman al transporte total.

De manera adicional a los análisis individuales del transporte y bombeo de Ekman, se calculó un índice conjunto de transporte total (Figura 39, similar a Messié et al. 2009). Los cambios en el futuro cercano no superan el 5 %, mientras que para el futuro intermedio el transporte total se reduce en $\sim 5\%$ al norte de 6°S durante

verano (no robusto) e invierno (robusto). Para el futuro lejano, la región norte (al norte de 8° S) muestra una reducción del transporte total superior al 10 % (robusto), llegando al 15 % durante el verano. En la zona central (entre 8°-12° S) los cambios son mínimos (<5 %) y poco robustos, mientras que alrededor de 17° S se evidencia un incremento del ~5 % durante invierno-primavera (robusto). Esto se corresponde con los cambios proyectados en la intensidad y el *curl* del viento, así como con los resultados de Oerder et al. (2015).

A pesar de los cambios proyectados en el transporte y bombeo de Ekman, su contribución al transporte total no se ve afectada a lo largo del periodo futuro de evaluación (Figura 40). En ese sentido se mantienen las condiciones históricas: una contribución casi equitativa durante el verano, y un aporte de ~70 % del transporte de Ekman durante el invierno.

5.4. INFLUENCIA DE LA TENDENCIA DE LOS MODELOS GLOBALES

Como se explicó en la Sección 3.4.b, la tendencia original de los modelos globales fue removida debido a que los modelos estadísticos de redes neuronales no lograban adaptarse a las condiciones extremas de cambio climático propias de las variables predictoras bajo el escenario pesimista (SSP5-8.5). Estos datos de tendencia se almacenaron y se interpolaron (bilinealmente) a la grilla objetivo de 25 km, para ser agregada a la salida del modelo C-D de *downscaling*. En ese sentido, es preciso analizar si los cambios encontrados en las Secciones 4.2 y 4.3 son influenciados por la tendencia añadida luego de la regionalización (cambios a escala global) o si se deben más a los modelos estadísticos (cambios a escala regional).

Con esta idea en mente, se replicaron algunos de los análisis sobre el viento costero frente a la costa peruana (ver Sección 4.2) para la salida de los modelos estadísticos sin agregar la tendencia de los modelos globales. Además, nos enfocamos en comparar los cambios proyectados en el viento (entre las salidas con y sin tendencia añadida) para el periodo futuro lejano (2081-2100).




Figura 41. (a), (b), (c) y (d) Cambios absolutos en la media del viento *alongshore* para la salidas del *downscaling* agregando la tendencia de los modelos globales (rojo) y sin agregar la tendencia (morado), durante el futuro lejano por estación y latitud.

Para el viento *alongshore*, los cambios en la zona norte (al norte de 8°-9° S) según los datos con tendencia (curvas rojas en la Figura 41) no se reproducen a partir de los datos sin tendencia (curvas moradas en la Figura 41), donde se muestra una ligera intensificación ($\sim 0.1 \text{ m s}^{-1}$) durante primavera y verano entre 4°-6° S (contrario al debilitamiento de $\sim 0.4\text{-}0.3 \text{ m s}^{-1}$ para los datos con tendencia). En la zona centro-sur las variaciones en el viento son similares entre los datos con y sin tendencia (a pesar de que estos cambios son pequeños); salvo durante el verano entre 12°-16° S, donde los cambios son opuestos: una ligera intensificación según las salidas con tendencia ($\sim 0.1 \text{ m s}^{-1}$) y un ligero debilitamiento según las salidas sin tendencia ($\sim 0.1 \text{ m s}^{-1}$).




Figura 42. (a), (b), (c) y (d) Cambios absolutos en la media del *curl stress* del viento para la salidas del *downscaling* agregando la tendencia de los modelos globales (rojo) y sin agregar la tendencia (morado), durante el futuro lejano por estación y latitud.

Para el *curl stress* del viento, la comparación resulta semejante. Al norte de $\sim 10^\circ$ S las salidas sin tendencia prácticamente no muestran cambios a lo largo del ciclo estacional (curvas moradas en la Figura 42), contrario al debilitamiento mostrado a partir de los datos con tendencia (curvas rojas en la Figura 42). Para la región centro-sur, ambos conjuntos de datos muestran cambios similares en el *curl stress* del viento; salvo durante el otoño alrededor de 17° S, donde el fortalecimiento (de $\sim 0.1 \times 10^{-7} \text{ N m}^{-3}$) según los datos con tendencia no coincide con la condición de poco cambios a partir de los datos sin tendencia.

Tanto para el *curl stress* del viento como para el viento *alongshore*, la baja amplitud de la nube de dispersión intermodelo, correspondiente a los cambios según las salidas sin agregar la tendencia global, evidencia los pocos cambios a partir de cada salida individual (sin agregar la tendencia global). No obstante, optamos por

realizar un análisis complementario sobre las salidas con y sin tendencia para 3 modelos globales particulares: CNRM-ESM2-1, GFDL-CM4 e IPSL-CM6A-LR.




Figura 43. Diagramas Hovmöller de los cambios en la intensidad del viento frente a la costa peruana (primer punto de grilla) mensual promedio para los datos originales (columna izquierda), con la tendencia de los modelos globales añadida (columna central) y sin agregar la tendencia (columna derecha); correspondientes a los modelos CNRM-ESM2-1 (fila superior), GFDL-CM4 (fila central) e IPSL-CM6A-LR (fila inferior).

La Figura 43 muestra los cambios estacionales de la intensidad del viento en una franja costera de 100 km para la data original de los modelos globales mencionados, y para las correspondientes salidas del *downscaling* con y sin tendencia añadida. Debido a la gruesa resolución de los modelos globales, los resultados mostrados para la data original corresponden al punto de grilla más cercano a la costa.




Figura 44. Mapas cambios en la intensidad del viento promedio para los datos originales (columna izquierda), con la tendencia de los modelos globales añadida (columna central) y sin agregar tendencia (columna derecha); correspondientes a los modelos globales CNRM-ESM2-1 (fila superior), GFDL-CM4 (fila central) e IPSL-CM6A-LR (fila inferior).

En general podemos decir que los patrones de cambio para los datos con tendencia se corresponden con los cambios de los modelos globales (excepto para el modelo CNRM-ESM2-1 durante el verano-otoño). Para CNRM-ESM2-1 los datos sin tendencia son los que tienen menos relación con los cambios a partir de la data original, apenas reproduciendo la intensificación alrededor de 4° S durante el verano y entre 12°-18° S durante octubre, aunque de hecho estos cambios son los más importantes según los datos sin tendencia para este modelo. Con GFDL-CM4

las salidas sin tendencia muestran cambios similares a la data original en la zona centro-sur, mientras que al norte la intensificación del viento durante primavera-verano (entre 5-10 %) a partir del *downscaling* sin tendencia se opone a los cambios en el modelo original (de hecho, se puede ver la influencia de la salida sin tendencia sobre la data final alrededor de 5° S durante febrero). Con IPSL-CM6A-LR se muestran resultados análogos con la data sin tendencia en la zona centro-sur entre mayo-diciembre; alrededor de 17° S y durante febrero-marzo las salidas sin tendencia muestran una intensificación de hasta 10% que impacta en las salidas finales. En la zona norte, las salidas sin tendencia muestran un aumento (~5 %) durante verano y pocos cambios en invierno (<5 %).

Además de analizar los vientos costeros, verificamos que los cambios en los vientos oceánicos obtenidos a partir de *downscaling* se correspondan con los cambios proyectados según los modelos globales, ya que a esta escala los resultados de los GCM deberían mantenerse. Notamos que para el caso particular de los modelos globales evaluados previamente esto si ocurre. Los cambios en la intensidad del viento para las salidas al agregar la tendencia se corresponden en signo y magnitud con los cambios según los modelos originales (Figura 44), aunque en algunos casos se sobreestima levemente la reducción del viento (zona oceánica entre 6°- 14° S para CNRM-ESM2-1 y entre 0°-5° N para IPSL-CM6A-LR). Los datos sin tendencia mantienen cambios en el viento por debajo de 0.25 m s⁻¹ en la zona oceánica frente a Perú para los 3 modelos evaluados; mostrando en todos los casos una ligera intensificación frente a la costa peruana y la zona ecuatorial.

Finalmente, buscamos explicar la ligera intensificación de los vientos de verano (principalmente en los extremos norte y sur de Perú) según la data sin agregar tendencia, ya que esta se estaría debiendo a procesos más allá de la señal a largo plazo del cambio climático. Asociado a la temperatura (uno de nuestros predictores), sabemos que el viento frente a Perú generalmente se intensifica durante eventos El Niño, mientras que se debilitan durante eventos La Niña (Chamorro et al. 2018, Yari et al. 2023). En ese sentido, para los 3 modelos globales particulares, se realizó un análisis simple de los cambios en la cantidad de este tipo de eventos durante el periodo futuro. Se construyeron series de anomalías mensuales de TSM sin tendencia (media móvil de 3 meses) sobre la región Niño3.4 relativo a una climatología histórica de 35 años (1980-2014), para un periodo histórico (1980-2014) y futuro (2066-2100). La tendencia para la TSM se removió con el mismo método que para los predictores previo al *downscaling* (*Loess*, ver Sección 3.4.b). Cabe resaltar que la TSM como tal no es una de las variables predictoras (sino temperatura del aire a 2 m), por lo que se realizó la descarga correspondiente de los datos mensuales para cada modelo global. Las anomalías de intensidad del viento promedio mensual por latitud se muestran debajo de cada serie de tiempo para los periodos correspondientes.

Para CNRM-ESM2-1, la cantidad de periodos cálidos y fríos se incrementan en cantidad e intensidad durante el futuro, especialmente para los últimos 20 años de cada periodo de evaluación (Figuras 45a, c). Los cambios más relevantes en los vientos de verano son una mayor probabilidad de vientos fuertes (~5 %, Figura 45e) alrededor de 4° S y una mayor probabilidad de vientos débiles (~5 %, Figura 45f)

entre 12°-14° S; esto relación también a los pocos cambios mostrados por este modelo para el futuro lejano (Figura 43). Por su parte, el modelo GFDL-CM4 muestra la misma cantidad de periodos cálidos en el histórico y futuro. Sin embargo, los últimos años del futuro muestran periodos de calentamiento más intensos que los últimos años del histórico (Figura 46a, c), coincidentes con anomalías positivas del viento (alrededor de 2093 y 2096, Figura 46d). Esto podría explicar el incremento en la incremento de hasta 10% en la probabilidad de viento fuertes durante el verano del futuro lejano en la zona norte de Perú (Figura 46f). En cuanto a los periodos fríos, si bien para el futuro encontramos una mayor cantidad, estos no son muy intensos ni duraderos; no existiendo un periodo similar al que si encontramos en el histórico durante 2009 (seguido de un debilitamiento del viento, Figura 46a, b). Así, apenas notamos un ligero incremento (<5 %) en la probabilidad de viento débiles durante el invierno (Figura 46e). Para el IPSL-CM6A-LR encontramos una mayor cantidad de periodos calientes durante los últimos 20 años del futuro en comparación con los últimos 20 años del histórico (Figura 47a, c). Además, para durante el futuro los periodos cálidos muestran una intensidad alta (cerca de 2° C de anomalía o más), dentro de los cuales se encuentran asociados a una intensificación de los vientos a los correspondientes a los años 2081, 2084 y 2099 (Figura 47d). La cantidad de periodos fríos se mantiene en el futuro, destacando el periodo del 2083 (coincidente con un debilitamiento del viento al norte de ~15° S, Figura 47d). En consecuencia, encontramos un incremento en la probabilidad de viento fuertes en verano (5-10 %) y en la probabilidad de vientos débiles en invierno (5-10 % al norte de 11° S).

Si bien no se realizaron estos últimos análisis para todos los modelos globales, a partir de los evaluados podemos especular que: el ligero incremento en la intensidad de los vientos de verano frente al norte de Perú estaría relacionado a una mayor cantidad y/o intensidad de los periodos cálidos según la serie de tiempo de anomalías de la TSM sobre la región Niño3.4 para el periodo futuro, junto con condiciones similares de cantidad/intensidad de periodos fríos entre el histórico y futuro. No obstante, para los 3 modelos evaluados, esta intensificación es pequeña en comparación al debilitamiento derivado de la tendencia a largo plazo correspondiente a los vientos de los modelos globales.




Figura 45. Serie de tiempo anomalías de SST sobre la región Niño3.4 (media móvil de 3 meses) indicando los periodos por encima/debajo (rojo/azul) de los umbrales 0.5/-0.5 °C por al menos 5 meses consecutivos, para los periodos **(a)** histórico y **(c)** futuro para el modelo CNRM-ESM2-1. Debajo de cada serie de tiempo se muestra la anomalía de intensidad del viento mensual por latitud para los periodos **(b)** histórico y **(d)** futuro. **(e)** Probabilidad de encontrar vientos diarios por debajo del P25 histórico, y **(f)** por encima del P75 histórico durante el periodo futuro lejano (2081-2100).




Figura 46. Análogo a la Figura 45, pero para el modelo GFDL-CM4.




Figura 47. Análogo a la Figura 45, pero para el modelo IPSL-CM6A-LR.

5.5. LIMITACIONES

La principal limitación del *downscaling* estadístico es que asume que las relaciones que encuentra entre predictor y predictante durante el periodo de entrenamiento se

mantendrán para otro periodo. Es posible que esto no siempre ocurra y más aún ante escenarios de cambio climático. En ese sentido, la remoción de la tendencia facilitó la aplicación de nuestros modelos estadísticos a los datos futuros de los modelos globales del CMIP6; sin embargo, se asume que los cambios proyectados en los vientos (variable objetivo) se deben principalmente a la señal a largo plazo removida (ver Sección 5.4).

Otra limitación de nuestros modelos estadísticos es que hemos trabajado con datos predictores de resolución gruesa (~100 km), lo cual no permite percibir los cambios en procesos a mesoescala que puedan afectar el comportamiento de los vientos costeros (Goubanova et al. 2011). Esta limitante se debe a la resolución gruesa de los modelos globales empleados (en algunos casos de hasta 500 km); sin embargo, existen algunos modelos del CMIP6 con resolución fina (al menos para variables relevantes como la TSM), haciendo viable el utilizar este tipo de datos para un futuro trabajo.

En cuanto al análisis de los cambios en el afloramiento, la principal limitante fue el no considerar la contribución del transporte geostrófico, principalmente debido a que este estudio se centra en el análisis de los vientos costeros y del transporte generado a partir de los mismos. Sin embargo, estudios previos han mostrado la importancia de considerar el aporte de las corrientes geostróficas (además de los vientos) para la estimación del transporte vertical (Colas et al. 2008; Jacox et al. 2018). Asimismo, Oerder et al. (2015) mostraron como el transporte de Ekman sobreestima (hasta en un tercio) el transporte vertical total a lo largo del año para diferentes simulaciones histórica y escenarios de cambio climático, siendo

compensado por el transporte transversal geostrófico. Análogamente, se mostró una subestimación de hasta un 30 % de la velocidad vertical en la base de la capa de Ekman por parte de la velocidad vertical calculada a partir del *curl* del viento (y del cual se deriva el bombeo de Ekman en este trabajo), compensada en buena medida por la velocidad vertical derivada del flujo geostrófico. Por otro lado, y en consistencia con lo recién explicado, Echevin et al. (2020) encontró una compensación promedio de ~50 % del transporte de Ekman por parte del transporte geostrófico (para sus tres simulaciones regionales), además de que esta compensación se incrementaba en el tiempo (hasta 2100). En ese sentido, es necesario complementar este estudio con uno en donde se analice también la contribución del flujo geostrófico sobre el afloramiento.

6. CONCLUSIONES

6.1. ENFOQUE METODOLÓGICO Y DESEMPEÑO DEL MODELO

Se implementó el *downscaling* estadístico basado en redes neuronales convolucionales (CNN) para regionalizar las proyecciones de vientos costeros de 12 modelos globales CMIP6 bajo el escenario SSP5-8.5. El modelo de arquitectura *coding-decoding* (modelo C-D) destacó por su adaptación a distintas bases de datos predictoras, en comparación a los modelos de arquitectura lineal (modelos CNN 1 y CNN 2). La profunda abstracción de los datos por parte del modelo C-D permitió una mejor representación de los vientos (cada componente) para los diferentes modelos globales. Los predictores más relevantes fueron: ambas componentes del viento, presión superficial y temperatura superficial.

6.2. PROYECCIONES DEL CAMBIO EN EL VIENTO

Los cambios en el viento (intensidad y rotacional) son mínimos para los periodos futuro cercano (2021-2040) e intermedio (2046-2065), y empiezan a hacerse evidentes a partir el futuro lejano (2081-2100). El análisis multimodelo nos permitió identificar una proyección robusta de debilitamiento del viento frente al norte de Perú (más intenso durante el verano en términos porcentuales), consistente con la señal a gran escala (que destaca frente a otros procesos locales que sugieren una ligera intensificación, <5 %) y acorde con la hipótesis planteada. Para la zona central se muestran cambios débiles y poco robustos en la intensidad del viento. En la región sur los vientos se intensifican ligeramente, vinculado a la tendencia forzada por la señal de gran escala y factores locales. De manera similar, la mayoría de modelos del CMIP6 (al menos 8 de 6) proyectan un rotacional del esfuerzo del

viento menos negativo (desfavorable al afloramiento) en el norte (entre 5-10 %). Para la región central, los cambios en el rotacional del viento son menores y no robustos. Para la región sur el *curl* se refuerza durante el invierno de manera robusta. La probabilidad de días con viento débil (por debajo del percentil 25 histórico) se incrementa al norte de 8° S, alrededor de 20 % para el futuro lejano, en especial durante el verano (~25 %). Asimismo, alrededor de 17° S la probabilidad de vientos fuertes (por encima del percentil 75 histórico) se incrementa en ~10 %.

6.3. PROYECCIONES DEL CAMBIO EN EL AFLORAMIENTO **(TRANSPORTE Y BOMBEO DE EKMAN)**

A partir de la media multimodelo y para la región norte de Perú durante el futuro lejano (2081-2100), se estima una reducción en el transporte (10-20 %) y bombeo de Ekman (~10 %), estos resultados son robustos desde la perspectiva multimodelo y validan nuestra hipótesis sobre esta región. La proporción entre transporte y bombeo de Ekman (aporte de ~50 % del transporte de Ekman durante verano y de ~70% durante invierno) se mantiene bajo el escenario de cambio climático y a lo largo de los periodos futuros. Esto permite decir que se espera un debilitamiento del afloramiento costero para el futuro lejano, afectando también la productividad frente a Perú; aunque el hecho de que existan factores no considerados, como cambios en la estratificación o en la circulación oceánica, y que compensen este posible impacto, hacen necesarios investigaciones complementarias.

7. PERSPECTIVAS Y RECOMENDACIONES

El *deep learning* viene en constante crecimiento, por lo que resulta interesante explorar alternativas a la arquitectura CNN tipo *coding-decoding*, mediante variantes como: U-net, U-net++, R2U-net, GAN-U-net, etc. (Siddique et al. 2021, Ummadi 2022) las cuales son adaptables para la regionalización del viento costero frente a Perú, tal y como se viene realizando para otras variables y sobre otras regiones (Nguyen et al. 2023, Annau et al. 2023, Harder et al. 2025).

El presente estudio se centró en el escenario más pesimista del CMIP6 (SSP5-8.5). Sería relevante realizar el *downscaling* del viento para escenarios intermedios (como SSP2-4.5) o de mitigación (como SSP1-2.6), con el fin de comparar trayectorias alternativas del cambio climático y sus efectos sobre los vientos en el sistema de afloramiento peruano.

Una forma de reducir la limitación implícita del *downscaling* estadístico (ver Sección 5.5) es expandir el periodo de entrenamiento. No obstante, los datos de observaciones a alta resolución durante el periodo histórico no se extienden por más de 15-20 años. Otra alternativa es regionalizar las observaciones históricas disponibles (de resolución gruesa) mediante un modelo regional (*downscaling* dinámico), en lo que se conoce como *downscaling* híbrido (Walton et al. 2015). Estas opciones expanden los datos predictores únicamente durante el periodo histórico, lo cual es lógico desde que los predictores deben componerse de datos observacionales; sin embargo, esto no cambia el hecho de que el modelo estadístico no sería capaz de aprender más allá de las relaciones históricas. Aceptando cierta

flexibilidad, es posible considerar el uso de regionalizaciones dinámicas de modelos globales bajo escenarios de cambio climático durante periodos futuros estratégicos, de manera que el modelo estadístico tenga la posibilidad de aprender bajo contextos distintos al periodo histórico.

Finalmente, se recomienda realizar simulaciones oceánicas adicionales que consideren las diferencias entre los vientos originales de los GCM y los vientos regionalizados, a fin de cuantificar el valor agregado del *downscaling* estadístico en términos oceanográficos.

Referencias

Al-Behadili, H. N. K., Ku-Mahamud, K. R., and Sagban, R. (2018). Rule pruning techniques in the ant-miner classification algorithm and its variants: A review. *IEEE Symposium on Computer Applications & Industrial Electronics (ISCAIE)* | IEEE Xplore. <https://ieeexplore.ieee.org/document/8405448>

Albert, A., Echevin, V., Lévy, M., and Aumont, O. (2010). Impact of nearshore wind stress curl on coastal circulation and primary productivity in the Peru upwelling system. *Journal of Geophysical Research Atmospheres*, 115(C12). <https://doi.org/10.1029/2010jc006569>

Alpaydin, E. (2020). *Introduction to Machine Learning, fourth edition*. MIT Press.

Annau, N. J., Cannon, A. J., and Monahan, A. H. (2023). Algorithmic Hallucinations of Near-Surface Winds: Statistical Downscaling with Generative Adversarial Networks to Convection-Permitting Scales. *Artificial Intelligence for the Earth Systems*, 2(4). <https://doi.org/10.1175/aies-d-23-0015.1>

Aszemi, N. M., and Dominic, P. (2019). Hyperparameter Optimization in Convolutional Neural Network using Genetic Algorithms. *International Journal of Advanced Computer Science and Applications (IJACSA)*, 10(6). <https://doi.org/10.14569/ijacsa.2019.0100638>

Bakun, A. (1990). Global climate change and intensification of coastal ocean upwelling. *Science*, 247(4939), 198–201. <https://doi.org/10.1126/science.247.4939.198>

Baño-Medina, J., Manzananas, R., and Gutiérrez, J. M. (2020). Configuration and intercomparison of deep learning neural models for statistical downscaling. *Geoscientific Model Development*, 13(4), 2109–2124. <https://doi.org/10.5194/gmd-13-2109-2020>

Baño-Medina, J., Manzanas, R., Cimadevilla, E., Fernández, J., González-Abad, J., Cofiño, A. S., and Gutiérrez, J. M. (2022). Downscaling multi-model climate projection ensembles with deep learning (DeepESD): contribution to CORDEX EUR-44. *Geoscientific Model Development*, 15(17), 6747–6758. <https://doi.org/10.5194/gmd-15-6747-2022>

Belmadani, A., Echevin, V., Codron, F., Takahashi, K., and Junquas, C. (2013). What dynamics drive future wind scenarios for coastal upwelling off Peru and Chile? *Climate Dynamics*, 43(7–8), 1893–1914. <https://doi.org/10.1007/s00382-013-2015-2>

Bravo, L., Ramos, M., Astudillo, O., Dewitte, B., and Goubanova, K. (2016). Seasonal variability of the Ekman transport and pumping in the upwelling system off central-northern Chile ($\sim 30^\circ$ S) based on a high-resolution atmospheric regional model (WRF). *Ocean Science*, 12(5), 1049–1065. <https://doi.org/10.5194/os-12-1049-2016>

Burke, E. J., Zhang, Y., and Krinner, G. (2020). Evaluating permafrost physics in the Coupled Model Intercomparison Project 6 (CMIP6) models and their sensitivity to climate change. *The Cryosphere*, 14(9), 3155–3174. <https://doi.org/10.5194/tc-14-3155-2020>

Camarena, D. (2022). *Variabilidad de alta frecuencia del viento en el sistema de afloramiento peruano bajo escenarios de cambio climático*. Tesis de maestría, Universidad Peruana Cayetano Heredia. Repositorio Institucional Universidad Peruana Cayetano Heredia. <https://hdl.handle.net/20.500.12866/12851>

Capet, X. J., Marchesiello, P., and McWilliams, J. C. (2004). Upwelling response to coastal wind profiles. *Geophys. Res. Lett.*, 31(13). <https://doi.org/10.1029/2004gl020123>

Chamorro, A., Echevin, V., Colas, F., Oerder, V., Tam, J., and Quispe-Ccalluari, C. (2018). Mechanisms of the intensification of the upwelling-favorable winds during El Niño 1997–1998 in the Peruvian upwelling system. *Climate Dynamics*, 51(9–10), 3717–3733.
<https://doi.org/10.1007/s00382-018-4106-6>

Chamorro, A., Echevin, V., Dutheil, 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.
<https://doi.org/10.1007/s00382-021-05689-w>

Chavez, F. P., and Messié, M. (2009). A comparison of Eastern Boundary Upwelling Ecosystems. *Progress in Oceanography*, 83(1–4), 80–96.
<https://doi.org/10.1016/j.pocean.2009.07.032>

Chavez, F. P., Bertrand, A., Guevara-Carrasco, R., Soler, P., and Csirke, J. (2008). The northern Humboldt Current System: Brief history, present status and a view towards the future. *Progress in Oceanography*, 79(2–4), 95–105.
<https://doi.org/10.1016/j.pocean.2008.10.012>

Colas, F., Capet, X., McWilliams, J., and Shchepetkin, A. (2008). 1997–1998 El Niño off Peru: A numerical study. *Progress in Oceanography*, 79(2–4), 138–155.
<https://doi.org/10.1016/j.pocean.2008.10.015>

Doury, A., Somot, S., Gadat, S., Ribes, A., and Corre, L. (2022). Regional climate model emulator based on deep learning: concept and first evaluation of a novel hybrid downscaling approach. *Climate Dynamics*, 60(5–6), 1751–1779.
<https://doi.org/10.1007/s00382-022-06343-9>

Echevin, V., Gévaudan, M., Espinoza-Morriberón, D., Tam, J., Aumont, O., Gutiérrez, D., and Colas, F. (2020). Physical and biogeochemical impacts of RCP8.5 scenario in the Peru upwelling system. *Biogeosciences*, 17(12), 3317–3341. <https://doi.org/10.5194/bg-17-3317-2020>

Echevin, V., Goubanova, K., Belmadani, A., and Dewitte, B. (2011). Sensitivity of the Humboldt Current system to global warming: a downscaling experiment of the IPSL-CM4 model. *Climate Dynamics*, 38(3–4), 761–774. <https://doi.org/10.1007/s00382-011-1085-2>

Edwards, P. N. (2010). History of climate modeling. *Wiley Interdisciplinary Reviews Climate Change*, 2(1), 128–139. <https://doi.org/10.1002/wcc.95>

Espinoza-Morriberón, D., Echevin, V., Colas, F., Tam, J., Ledesma, J., Vásquez, L., and Graco, M. (2017). Impacts of El Niño events on the Peruvian upwelling system productivity. *Journal of Geophysical Research Oceans*, 122(7), 5423–5444. <https://doi.org/10.1002/2016jc012439>

Fan, X., Miao, C., Duan, Q., Shen, C., and Wu, Y. (2021). Future climate change hotspots under different 21st century warming scenarios. *Earth S Future*, 9(6). <https://doi.org/10.1029/2021ef002027>

Fowler, H. J., Blenkinsop, S., and Tebaldi, C. (2007). Linking climate change modelling to impacts studies: recent advances in downscaling techniques for hydrological modelling. *International Journal of Climatology*, 27(12), 1547–1578. <https://doi.org/10.1002/joc.1556>

Garreaud, R. D., and Falvey, M. (2008). The coastal winds off western subtropical South America in future climate scenarios. *International Journal of Climatology*, 29(4), 543–554. <https://doi.org/10.1002/joc.1716>

Georgiou, T., Liu, Y., Chen, W., and Lew, M. (2019). A survey of traditional and deep learning-based feature descriptors for high dimensional data in computer vision. *International Journal of Multimedia Information Retrieval*, 9(3), 135–170. <https://doi.org/10.1007/s13735-019-00183-w>

Giorgi, F., and Gutowski, W. J. (2015). Regional Dynamical Downscaling and the CORDEX initiative. *Annual Review of Environment and Resources*, 40(1), 467–490. <https://doi.org/10.1146/annurev-environ-102014-021217>

Gómez-Navarro, J. J., Raible, C. C., García-Valero, J. A., Messmer, M., Montávez, J. P., and Martius, O. (2019). Event selection for dynamical downscaling: a neural network approach for physically-constrained precipitation events. *Climate Dynamics*, 58(9–10), 2863–2879. <https://doi.org/10.1007/s00382-019-04818-w>

González-Abad, J., Baño-Medina, J., and Gutiérrez, J. M. (2023). Using explainability to inform statistical downscaling based on deep learning beyond standard validation approaches. *Journal of Advances in Modeling Earth Systems*, 15(11). <https://doi.org/10.1029/2023ms003641>

Goodfellow, I., Bengio, Y., and Courville, A. (2016). *Deep Learning*. MIT Press.

Goubanova K., and Ruiz C. (2010). Impact of climate change on wind-driven upwelling off the coasts of Peru-Chile in a multi-model ensemble. In: *duPenhoat Y, Kislov AV (eds)*

Climate variability in the tropical Pacific: mechanisms, modelling and observations. Maks-Press, Moscow, pp 194-201.

Goubanova, K., Echevin, V., Dewitte, B., Codron, F., Takahashi, K., Terray, P., and 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(7–8), 1365–1378. <https://doi.org/10.1007/s00382-010-0824-0>

Graco, M. I., Purca, S., Dewitte, B., Castro, C. G., Morón, O., Ledesma, J., Flores, G., and Gutiérrez, D. (2017). The OMZ and nutrient features as a signature of interannual and low-frequency variability in the Peruvian upwelling system. *Biogeosciences*, 14(20), 4601–4617. <https://doi.org/10.5194/bg-14-4601-2017>

Halpern, D. (2002). Offshore Ekman transport and Ekman pumping off Peru during the 1997–1998 El Niño. *Geophysical Research Letters*, 29(5). <https://doi.org/10.1029/2001gl014097>

Harder, P., Schmidt, L., Pelletier, F., Ludwig, N., Chantry, M., Lessig, C., Hernandez-Garcia, A., and Rolnick, D. (2025, July 7). *RainShift: a benchmark for precipitation downscaling across geographies*. arXiv.org. <https://arxiv.org/abs/2507.04930>

Hastie T., Tibshirani R., and Friedman J. (2009). The Elements of Statistical Learning: Data Mining, Inference, and Prediction. *Springer Series in Statistics*, second edition.

Hinton, G., and Tieleman, T. (2012). Lecture 6.5-rmsprop: Divide the gradient by a running average of its recent magnitude. *Technical report, COURSERA: Neural networks for machine learning*.

Intergovernmental Panel on Climate Change (IPCC). (2022). *Climate Change 2022 – Impacts, Adaptation and Vulnerability: Working Group II Contribution to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change*. Cambridge: Cambridge University Press. <https://doi.org/10.1017/9781009325844>

Iturbide, M., Bedia, J., Herrera, S., Baño-Medina, J., Fernández, J., Frías, M., Manzanar, R., San-Martín, D., CimaDevilla, E., Cofiño, A., and Gutiérrez, J. (2018). The R-based climate4R open framework for reproducible climate data access and post-processing. *Environmental Modelling & Software*, 111, 42–54. <https://doi.org/10.1016/j.envsoft.2018.09.009>

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 U.S. West coast. *Journal of Geophysical Research Oceans*, 123(10), 7332–7350. <https://doi.org/10.1029/2018jc014187>

Jang, S., and Kavvas, M. L. (2013). Downscaling Global Climate Simulations to Regional Scales: Statistical Downscaling versus Dynamical Downscaling. *Journal of Hydrologic Engineering*, 20(1). [https://doi.org/10.1061/\(asce\)he.1943-5584.0000939](https://doi.org/10.1061/(asce)he.1943-5584.0000939)

Kingma, D. P., and Ba, J. (2014). Adam: A method for stochastic optimization.

Konar, J., Khandelwal, P., and Tripathi, R. (2020). Comparison of various learning rate scheduling techniques on convolutional neural network. *2020 IEEE International Students' Conference on Electrical, Electronics and Computer Science (SCEECS)*, 1–5. <https://doi.org/10.1109/sceecs48394.2020.94>

Kriegeskorte, N., and Golan, T. (2019). Neural network models and deep learning. *Current Biology*, 29(7), R231–R236. <https://doi.org/10.1016/j.cub.2019.02.034>

Maraun, D. (2016). Bias Correcting Climate Change Simulations - A Critical review. *Curr. Climate Change Reports*, 2(4), 211–220. <https://doi.org/10.1007/s40641-016-0050-x>

Mearns, L.O., Giorgi, F., Whetton, P., Pabon, D., Hulme, M. and Lal, M. (2003). Guidelines for use of climate scenarios developed from Regional Climate Model experiments. *IPCC Task Group on Scenarios for Climate Impact Assessment (TGCI)*.

Mendo, J., Pizarro, L., and Castillo, S. (1987). Monthly turbulence and Ekman transport indexes 1953 to 1985, based on local wind records from Trujillo and Callao, Peru. *The Peruvian anchoveta and its upwelling ecosystem: three decades of change*, p. 75-88. ICLARM Studies and Reviews 15.

Messié, M., Ledesma, J., Kolber, D. D., Michisaki, R. P., Foley, D. G., and Chavez, F. P. (2009). Potential new production estimates in four eastern boundary upwelling ecosystems. *Progress in Oceanography*, 83, 151–158. <https://doi.org/10.1016/j.pocean.2009.07.018>

Mogollón, R., and Calil, P. H. (2017). On the effects of ENSO on ocean biogeochemistry in the Northern Humboldt Current System (NHCS): A modeling study. *Journal of Marine Systems*, 172, 137–159. <https://doi.org/10.1016/j.jmarsys.2017.03.011>

Nguyen, T., Brandstetter, J., Kapoor, A., Gupta, J. K., and Grover, A. (2023, January 24). *ClimaX: A foundation model for weather and climate*. arXiv.org. <https://arxiv.org/abs/2301.10343>

O'Neill, B. C., Tebaldi, C., Van Vuuren, D. P., Eyring, V., Friedlingstein, P., Hurtt, G., Knutti, R., Kriegler, E., Lamarque, J., Lowe, J., Meehl, G. A., Moss, R., Riahi, K., and Sanderson, B. M. (2016). The Scenario Model Intercomparison Project (ScenarioMIP) for CMIP6. *Geoscientific Model Development*, 9(9), 3461–3482. <https://doi.org/10.5194/gmd-9-3461-2016>

Oerder, V., Colas, F., Echevin, V., Codron, F., Tam, J., and Belmadani, A. (2015). Peru-Chile upwelling dynamics under climate change. *Journal of Geophysical Research Oceans*, 120(2), 1152–1172. <https://doi.org/10.1002/2014jc010299>

Parvathi, V., Suresh, I., Lengaigne, M., Izumo, T., and Vialard, J. (2017). Robust projected weakening of winter monsoon winds over the Arabian Sea under climate change. *Geophysical Research Letters*, 44(19), 9833–9843. <https://doi.org/10.1002/2017gl075098>

Pickett, M. H., and Paduan, J. D. (2003). Ekman transport and pumping in the California Current based on the U.S. Navy's high-resolution atmospheric model (COAMPS). *Journal of Geophysical Research Atmospheres*, 108(C10). <https://doi.org/10.1029/2003jc001902>

Pietri, A., Colas, F., Mogollon, R., Tam, J., and Gutiérrez, D. (2021). Marine heatwaves in the Humboldt current system: from 5-day localized warming to year-long El Niños. *Scientific Reports*, 11(1). <https://doi.org/10.1038/s41598-021-00340-4>

Quesada-Chacón, D., Barfus, K., and Bernhofer, C. (2022). Repeatable high-resolution statistical downscaling through deep learning. *Geoscientific Model Development*, 15(19), 7353–7370. <https://doi.org/10.5194/gmd-15-7353-2022>

Riahi, K., Van Vuuren, D. P., Kriegler, E., Edmonds, J., O'Neill, B. C., Fujimori, S., Bauer, N., Calvin, K., Dellink, R., Fricko, O., Lutz, W., Popp, A., Cuaresma, J. C., Ke, S., Leimbach, M., Jiang, L., Kram, T., Rao, S., Emmerling, J., . . . Tavoni, M. (2016). The Shared Socioeconomic Pathways and their energy, land use, and greenhouse gas emissions implications: An overview. *Global Environmental Change*, 42, 153–168. <https://doi.org/10.1016/j.gloenvcha.2016.05.009>

Rummukainen, M. (2009). State-of-the-art with regional climate models. *Wiley Interdisciplinary Reviews Climate Change*, 1(1), 82–96. <https://doi.org/10.1002/wcc.8>

Rykaczewski, R. R., Dunne, J. P., Sydeman, W. J., García-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 Research Letters*, 42(15), 6424–6431. <https://doi.org/10.1002/2015gl064694>

Schwing, F. B., O'Farrell, M., Steger, J. M., and Baltz, K. (1996). *Coastal upwelling indices, west coast of North America 1946–1995*. Washington, DC: NOAA. NOAA Technical Memorandum NMFS-SWFSC-231

Siddique, Nahian (2021). *U-net based deep learning architectures for object segmentation in biomedical images*. Purdue University Graduate School, Thesis. <https://doi.org/10.25394/PGS.15094422.v1>

Tran Anh, Q. and Taniguchi, K. (2018). Coupling dynamical and statistical downscaling for high-resolution rainfall forecasting: case study of the Red River Delta, Vietnam. *Progress in Earth and Planetary Sci.*, 5(1). <https://doi.org/10.1186/s40645-018-0185-6>

Ummadi, V. (2022, April 17). *U-Net and its variants for Medical Image Segmentation : A short review*. arXiv.org. <https://arxiv.org/abs/2204.08470>

Walton, D. B., Sun, F., Hall, A., and Capps, S. (2015). A Hybrid Dynamical–Statistical Downscaling Technique. Part I: Development and Validation of the Technique. *Journal of Climate*, 28(12), 4597–4617. <https://doi.org/10.1175/jcli-d-14-00196.1>

Wilby, R., Charles, S., Zorita, E., Timbal, B., Whetton, P., and Mearns, L. (2004). Guidelines for Use of Climate Scenarios Developed from Statistical Downscaling Methods. *IPCC Task Group on Scenarios for Climate Impact Assessment (TGCI)*. Zenodo. <https://doi.org/10.5281/zenodo.1438320>

Xu, Z., Han, Y., and Yang, Z. (2018). Dynamical downscaling of regional climate: A review of methods and limitations. *Science China Earth Sciences*, 62(2), 365–375. <https://doi.org/10.1007/s11430-018-9261-5>

Yari, S., Mohrholz, V., and Bordbar, M. H. (2023). Wind variability across the North Humboldt Upwelling System. *Frontiers in Marine Science*, 10. <https://doi.org/10.3389/fmars.2023.1087980>

Zhang, G., Nan, Z., Hu, N., Yin, Z., Zhao, L., Cheng, G., and Mu, C. (2022). Qinghai-Tibet plateau Permafrost at risk in the late 21st century. *Earth's Future*, 10(6). <https://doi.org/10.1029/2022ef002652>

APÉNDICE A. HIPERPARÁMETROS EN LAS REDES NEURONALES

CONVOLUCIONALES

En general, el autor desconoce de manera inmediata cuál debería ser la arquitectura óptima para un modelo determinado, o bajo qué condiciones se debe realizar el entrenamiento. Las variables inmersas en estas configuraciones se denominan hiperparámetros, y son externas al modelo, es decir su valor no se puede estimar a partir de los datos (Aszemi and Dominic 2019).

I. Optimizadores en el *deep learning*

Dentro del proceso de entrenamiento de una red neuronal, se busca minimizar una función de costo, pérdida o error F definida a partir de los parámetros del modelo de redes neuronales. Para lograr esto, se hace uso del método del gradiente. Sean θ_t los parámetros que definen el modelo de redes neuronales en la iteración t , el método del gradiente nos indica como actualizar los parámetros para la siguiente iteración:

$$\theta_{t+1} = \theta_t - \eta \nabla F(\theta_t), \quad (\text{A.1})$$

donde η es la tasa de aprendizaje y $\nabla F(\theta_t)$ es el gradiente de F en la iteración t .

A su vez, a partir de este método del gradiente, los últimos años han surgido variaciones que mejoran la velocidad de convergencia de los algoritmos, a partir de regular o adaptar el valor de la tasa de aprendizaje teniendo en cuenta información de la iteraciones previas. Entre los métodos más destacados se

encuentran: RMSProp (*root mean square propagation*) y Adam (*adaptive momentum*).

RMSProp

Introducido en Hinton and Tieleman (2012). Utiliza un promedio ponderado con caída exponencial a fin de regular la tasa de aprendizaje restándole peso a los gradientes de las iteraciones iniciales:

$$\theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{r_t}} \nabla F(\theta_t),$$

$$r_t = \beta r_{t-1} + (1 - \beta) \nabla F(\theta_t) \odot \nabla F(\theta_t),$$

donde $\beta \in \langle 0,1 \rangle$ (usualmente $\beta = 0.99$, Alpaydin 2020), $\frac{\eta}{\sqrt{r_t}}$ se calcula realizando la división y la raíz cuadrada para cada elemento de r_t , y $\odot$ es la operación de multiplicación elemento-elemento.

Adam

Introducido en Kingma and Ba (2014). Además de regular la tasa de aprendizaje (RMSProp), regula la dirección de en la que se actualizan los parámetros (originalmente, la dirección del gradiente):

$$\theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{\hat{r}_t}} \hat{s}_t,$$

$$\hat{s}_t = \frac{s_t}{1-\alpha^t}, \quad \hat{r}_t = \frac{r_t}{1-\beta^t},$$

$$s_t = \alpha s_{t-1} + (1 - \alpha) \nabla F(\theta_t), \quad r_t = \beta r_{t-1} + (1 - \beta) \nabla F(\theta_t) \odot \nabla F(\theta_t),$$

donde $\alpha, \beta \in \langle 0,1 \rangle$.

II. Tasa de aprendizaje y decaimiento

La tasa de aprendizaje (ecuación A.1) regula la actualización de los pesos luego de cada iteración durante la optimización. En otras palabras, determina que tan grande o pequeño debe ser el cambio en el modelo en relación al error encontrado cada vez que se actualizan los parámetros del modelo.

Existen diferentes formas de seleccionar la tasa de aprendizaje inicial. Un enfoque básico es seleccionar aleatoriamente diferentes valores, y elegir el que proporcione un menor error sin renunciar a la velocidad de entrenamiento. Otro enfoque es comenzar el entrenamiento con una tasa de aprendizaje alta e ir reduciendo su valor gradualmente utilizando algún mecanismo, lo que se conoce como decaimiento (Konar et al. 2020).




Figura A.1. Diferentes casos para diferentes valores de tasa de aprendizaje: **(a)** cuando el aprendizaje es demasiado pequeño, **(b)** cuando la tasa de aprendizaje es óptima, **(c)** cuando la tasa de aprendizaje es demasiado grande (extraído de Konar et al. 2020).

Elegir una tasa de aprendizaje óptima (Figura A.1.b) es una tarea complicada. Una tasa de aprendizaje demasiado pequeña (Figura A.1.a) puede dar como resultado un proceso de entrenamiento muy largo y lento, que puede quedarse estancado.

Un valor de tasa de aprendizaje demasiado grande (Figura A.1.c) puede dar como resultado una desviación del punto óptimo en lugar de converger hacia él.

Ajuste de la tasa de aprendizaje

- **Tasa Constante:** En el mecanismo de tasa de aprendizaje constante, fijamos la tasa de aprendizaje del modelo en un valor numérico dado. Elegir este valor fijo resulta una tarea compleja, pero se puede determinar mediante procedimientos de prueba-error para diferentes valores constantes.
- **Decaimiento a pasos:** En esta técnica, se inicializa con una tasa grande, la cual se reduce progresivamente luego de un determinado número de “épocas” (el concepto de épocas se revisa en la Sección IV de este apéndice). La expresión matemática del decaimiento a pasos es dada por

$$\eta = \eta_0 \cdot \text{decay_rate}^{\left\lfloor \frac{\text{epoch}}{\text{decay_steps}} \right\rfloor},$$

donde η es la tasa de aprendizaje en la época actual, η_0 es la tasa inicial, decay_rate es un factor constante que determina la reducción de la tasa, decay_steps es el número de épocas luego de las cuales la tasa se reduzca, epoch es el número de época correspondiente y $\lfloor \cdot \rfloor$ es la función máximo entero.

- **Decaimiento exponencial:** En este caso la tasa de aprendizaje se reduce progresivamente de manera exponencial. La expresión matemática del decaimiento exponencial es dada por:

$$\eta = \eta_0 \cdot \text{decay_rate}^{\left(\frac{\text{epoch}}{\text{decay_steps}}\right)},$$

donde η , η_0 , $decay_rate$, $decay_steps$ y $epoch$ son los mismos parámetros explicados en el decaimiento a pasos.

- **Decaimiento inverso:** Se utiliza un factor inversamente proporcional al número de épocas para reducir la tasa de aprendizaje. La expresión matemática del decaimiento exponencial es dada por:

$$\eta = \eta_0 \cdot \frac{1}{1 + \left(decay_rate \cdot \frac{epoch}{decay_steps} \right)},$$

donde η , η_0 , $decay_rate$, $decay_steps$ y $epoch$ son los mismos parámetros explicados en el decaimiento a pasos y exponencial.

III. Tamaño del minibatch

Los algoritmos de optimización que utilizan el conjunto de entrenamiento completo en cada se denominan “métodos de gradiente deterministas”. Cuando el conjunto de entrenamiento se divide en partes o *mini-batches* usamos en término “gradiente estocástico”. Por otro lado, los algoritmos de optimización que utilizan un solo elemento del conjunto de entrenamiento a la vez se denominan métodos estocásticos de una muestra (*one-sample*).

Los tamaños del minibatch suelen depender de los siguientes factores

(Goodfellow et al. 2016):

- Los *batches* más grandes proporcionan una estimación más precisa del gradiente, pero con retornos menos que lineales.

- Si todos los elementos del *batch* se deben procesar en paralelo (como es usual en el procesamiento de redes neuronales), entonces la cantidad de memoria incrementa con el tamaño del *batch*. Para muchas configuraciones de *hardware*, este es el factor limitante en el tamaño del *batch*.
- Algunos tipos de *hardware* logran un mejor tiempo de ejecución con arreglos de tamaño específico. Especialmente cuando se utilizan GPU, es común que los tamaños de *batch* de potencia de 2 ofrezcan un mejor tiempo de ejecución. Los tamaños de *batch* de potencia de 2 típicos varían de 32 a 256, y a veces se intentan de 16 para modelos grandes.
- Los *batches* pequeños pueden ofrecer un efecto de regularización. El error de generalización suele ser mejor para un tamaño de *batch* de 1. El entrenamiento con un tamaño de *batch* tan pequeño puede requerir una tasa de aprendizaje pequeña para mantener la estabilidad debido a la alta varianza en la estimación del gradiente. En dicho sentido, el tiempo de ejecución total puede ser muy elevado, tanto por la tasa de aprendizaje reducida como por la necesidad de realizar más pasos para recorrer completamente el conjunto de entrenamiento.

IV. Número de épocas

El número de épocas es un hiperparámetro que define el número de veces que el algoritmo recorre el conjunto de entrenamiento en su totalidad. Así, una época implica que cada elemento del conjunto de entrenamiento haya sido considerado en la actualización de parámetros internos del modelo. En el caso del método de gradiente estocástico, una época se compone de uno o más *batches*, dependiendo del tamaño de *batch* y del tamaño del conjunto de entrenamiento.

El número total de épocas en el algoritmo se puede establecer entre uno e infinito. Usualmente se estipula un número máximo (total) de épocas durante el entrenamiento, de manera que se garantice que el algoritmo se detenga. La cantidad de épocas es generalmente grande (cientos, miles), permitiendo que el algoritmo de aprendizaje se ejecute hasta que el error del modelo se haya minimizado lo suficiente.

Por otro lado, las iteraciones se refieren a la cantidad de *batches* necesarios para completar una época (recorrer la totalidad de los datos). La cantidad de iteraciones (igual a la cantidad de *batches* en una época) se calcula dividiendo el tamaño del conjunto de entrenamiento entre el tamaño del *batch*. Las iteraciones desempeñan un papel crucial en el proceso de entrenamiento, ya que determinan la cantidad de actualizaciones que se realizan en los parámetros del modelo durante cada época.




Figura A.2. Diferentes particiones de los datos para el entrenamiento según el tamaño del *mini-batch*. Se indica también el número de iteraciones por época en relación a este hiperparámetro.

V. Subconjunto de validación y criterios de detención temprana

Con el objetivo de evitar un sobre-ajuste de parámetros durante el entrenamiento de las redes neuronales (*overfitting*), los algoritmos emplean una especie de regla o criterio (usualmente ligados a la función de costo) detención temprana (Hastie et al. 2009). Para definir estos criterios, se subdividen los datos de entrenamiento en dos subconjuntos disjuntos: conjunto de entrenamiento (aunque puede confundirse con el conjunto mayor de datos utilizado para todo el proceso de entrenamiento) y conjunto de validación. Normalmente, se utiliza aproximadamente el 80 % de los datos de entrenamiento para el entrenamiento y el 20 % para la validación (Goodfellow et al. 2016).

Durante el entrenamiento, a menudo observamos que el error de entrenamiento va disminuyendo progresivamente con el tiempo, pero el error del conjunto de validación comienza a aumentar su valor luego de cierto momento (Figura A.3). Esto significa que podemos obtener un modelo con un mejor error del conjunto de validación (y, por lo tanto, generalizando, un modelos más eficiente) volviendo a la configuración de parámetros en el momento con el menor error del conjunto de validación. Cada vez que el error del conjunto de validación mejora, se almacena una copia de los parámetros del modelo. La detención temprana establece un límite para la NO mejora del error en la validación; así, el algoritmo finaliza cuando ningún parámetro ha mejorado con respecto al mejor error de validación registrado durante un número preestablecido de iteraciones (“paciencia”), y

cargándose los últimos parámetros guardados (los correspondientes al mejor error del conjunto de validación) para definir el modelo (Goodfellow et al. 2016).




Figura A.3. Comparación los errores de entrenamiento y de prueba puede ayudar a determinar si un modelo está subajustado, óptimamente ajustado o sobreajustado. (extraído de Al-Behadili et al. 2018).

VI. Sobre la configuración de hiperparámetros

De manera general, no existen reglas sobre cómo configurar los hiperparámetros mencionados. En ese sentido, se suelen ejecutar entrenamientos de prueba a fin de determinar la mejor combinación de valores. La experiencia del autor y el conocimiento del modelo a entrenar son fundamentales para determinar buenos hiperparámetros.

APÉNDICE B. FIGURAS SUPLEMENTARIAS




Figura suplementaria 1. Mapas promedio de **(a)** intensidad del viento, **(b)** curl stress del viento, **(c)** viento zonal y **(d)** viento meridional según la data satelital de ASCAT durante el periodo 2008-2022.




Figura suplementaria 2. Perfil del viento *alongshore* promedio para una franja de hasta 150 km frente a la costa (panel izquierdo) para el periodo histórico (negro) y futuros cercano (azul), intermedio (verde) y lejano (rojo), según cada modelo seleccionado del CMIP6. Cambios relativos proyectados (colores en m s^{-1} y contornos en %) en el ciclo estacional promedio de los vientos paralelos a la costa (en una franja costera de 150 km) para los periodos futuro cercano, intermedio y lejano, según cada modelo seleccionado del CMIP6 (continúa).




Figura suplementaria 2. Continuación.




Figura suplementaria 2. Continuación (final).




Figura suplementaria 3. Perfil del *curl stress* del viento promedio desde los 25 km hasta los 150 km frente a la costa (panel izquierdo) para el periodo histórico (negro) y futuros cercano (azul), intermedio (verde) y lejano (rojo), según cada modelo seleccionado del CMIP6. Cambios relativos proyectados (sombreado de color en $\text{m } 10^{-7} \text{ N m}^{-3}$ y contornos en %) en el ciclo estacional promedio del *curl stress* del viento (en una franja costera entre 25 a 150 km) para los periodos futuro cercano, intermedio y lejano, según cada modelo seleccionado del CMIP6 (continúa).




Figura suplementaria 3. Continuación.




Figura suplementaria 3. Continuación (final).