

Sistema de Pronóstico Meteorológico Marítimo de Alta Resolución Utilizando IA y Datos de Fuentes Abiertas¹

Ruiz. Alejandra, Torres. Alberto
alejaguz30@gmail.com, albertorres9102@gmail.com

Este trabajo aborda la necesidad crítica de la Armada de Colombia de contar con pronósticos climáticos marítimos precisos y oportunos. Se presenta el desarrollo de un sistema de pronóstico de alta resolución para las aguas del Pacífico y Atlántico colombiano, basado en técnicas de Aprendizaje Profundo. La metodología se centró en la recopilación y procesamiento de datos históricos del reanálisis ERA5 para una región de interés estratégico, para capturar fenómenos climáticos clave como ENSO. Se desarrolló un modelo predictivo para pronosticar un "tablero de control" de variables operativas, incluyendo altura de ola, viento y temperatura. El rendimiento del modelo se evalúa contra métricas estándar como Loss, MAE y RMSE. Como entregable final, se propone un modelo integrado en un contenedor Docker y expuesto mediante una API RESTful para su uso operativo, proporcionando a la Armada una herramienta robusta y específica para sus áreas de operación.

Aprendizaje Profundo, ENSO, Pronóstico Meteorológico, Seguridad Marítima, Series de Tiempo.

I. INTRODUCCIÓN

La creciente complejidad del modelado climático marítimo, impulsada por los efectos del cambio climático, ha generado una necesidad apremiante de modelos predictivos precisos para diversas aplicaciones, incluyendo la gestión de recursos marinos, la navegación y la planificación de infraestructuras costeras [1].

Tradicionalmente, estos retos han sido afrontados con modelos de Predicción Numérica del Tiempo (NWP, por sus siglas en inglés), los cuales se basan en ecuaciones físicas que describen la dinámica y termodinámica de la atmósfera. Agencias como el Centro Europeo de Previsiones Meteorológicas a Plazo Medio (ECMWF) con su modelo Integrated Forecast System (IFS) han sido el estándar de oro [2]. Sin embargo, estos modelos requieren una enorme capacidad de cómputo, lo que limita su uso a actores con altos recursos y los hace complejos de desarrollar. En este contexto, el aprendizaje automático (ML) y el aprendizaje profundo (DL) emergen como herramientas poderosas para mejorar las capacidades de los modelos climáticos tradicionales, aprovechando grandes conjuntos de datos para capturar relaciones no lineales complejas y ofrecer predicciones más exactas y oportunas [3].

La Armada de Colombia, garante de la soberanía marítima y fluvial, se enfrenta a un gran desafío: la influencia del clima en sus operaciones y la toma de decisiones. La capacidad de predecir con precisión las condiciones meteorológicas no es solo una ventaja táctica, sino una necesidad fundamental para garantizar la seguridad de las tripulaciones, la integridad de los equipos y el éxito de misiones críticas como operaciones de interdicción, búsqueda y rescate [4]. Vientos fuertes, olas elevadas y niebla densa pueden poner en peligro a las embarcaciones, dificultar las maniobras y comprometer el éxito operativo.

En respuesta a esta necesidad, este trabajo se enfoca en el desarrollo de un sistema de pronóstico de alta resolución, diseñado específicamente para las necesidades operativas de la Armada de Colombia, utilizando técnicas de inteligencia artificial y datos de fuentes abiertas.

Documento recibido el xx de xx de xx.

R. A. Universidad Icesi, Cali, Valle del Cauca, Colombia (e-mail: alejaguz30@gmail.com).

T. A. Universidad Icesi, Cali, Valle del Cauca, Colombia (e-mail: albertorres9102@gmail.com).

II. MATERIALES Y MÉTODOS

El campo de la predicción meteorológica está experimentando una transformación gracias a la IA. Mientras que los modelos NWP como el IFS-HRES de ECMWF representan la línea base por su consistencia física y fiabilidad, modelos basados en IA han demostrado capacidades competitivas o incluso superiores en diversas métricas, con una velocidad de inferencia órdenes de magnitud mayor [5] [6] [7] [8] [9].

Modelos como GraphCast (Google DeepMind), basado en Redes Neuronales Gráficas (GNN), ha superado al IFS-HRES en más del 90% de las variables evaluadas y ha mostrado una habilidad significativamente mayor para predecir trayectorias de ciclones. Aurora (Microsoft), un modelo Transformer de Difusión, destaca por su flexibilidad y alta resolución, buscando superar al IFS en horizontes de 5 a 10 días. Otros modelos como Pangu-Weather (Huawei) y FourCastNet (NVIDIA) también han demostrado ser pioneros, logrando precisiones similares o superiores a los modelos NWP con velocidades de pronóstico hasta 45,000 veces más rápidas. A continuación, se comentan brevemente los modelos de referencia:

IFS-HRES (ECMWF)

Es el modelo de referencia global, basado en la Predicción Numérica del Tiempo (NWP) [2]. No es un modelo de Inteligencia Artificial, sino un sistema fisicomatemático que asimila continuamente datos de observaciones reales (satélites, boyas, estaciones) para resolver las ecuaciones que gobiernan la atmósfera. Su principal fortaleza es su consistencia física y fiabilidad, siendo el modelo operativo más preciso del mundo y la línea base (Gold Standard) contra la que se comparan todos los demás modelos.

Aurora (Microsoft)

Es un modelo de Inteligencia Artificial fundamentado en una arquitectura Transformer de Difusión. Fue pre-entrenado con aproximadamente un millón de horas de simulaciones climáticas, lo que le confiere una comprensión profunda de la dinámica atmosférica. Su diseño le permite ser flexible y afinado (fine-tuned) para tareas específicas y de alta resolución, buscando superar al IFS en horizontes de pronóstico de 5 a 10 días [10].

GraphCast (Google DeepMind)

Este modelo utiliza una arquitectura de Red Neuronal Gráfica (GNN). Representa la Tierra como una malla de grafos, lo que le permite aprender interacciones espaciales complejas de manera eficiente. GraphCast es famoso por superar al IFS-HRES en más del 90% de las 1380 variables evaluadas y, crucialmente, por su habilidad superior para predecir la trayectoria de ciclones tropicales, un área de inmenso impacto [11].

Pangu-Weather (Huawei)

Su arquitectura se basa en un Transformer 3D, una innovación que le permite capturar relaciones espaciales y temporales complejas simultáneamente. Este enfoque le otorga una alta precisión y eficiencia, demostrando superar al IFS-HRES en precisión para pronósticos de hasta 7 días [12].

FourCastNet (NVIDIA)

Es un modelo pionero que demostró la viabilidad de la Inteligencia Artificial en este campo. Utiliza una arquitectura de Fourier Neural Operator (FNO), que procesa la información en el dominio de la frecuencia, lo que lo hace extremadamente rápido. Logró una velocidad de pronóstico aproximadamente 45,000 veces superior a los modelos NWP tradicionales [13].

La siguiente tabla resume algunas características fundamentales de estos modelos de referencia, tanto el modelo fisicomatemático, como los de arquitectura de IA.

TABLA 1
MODELOS REFERENTES EN LA INDUSTRIA

Modelo (Compañía)	Métrica	Variable Clave	Horizonte de Pronóstico	Valor Reportado	Comparación Clave
IFS-HRES (ECMWF)	RMSE	Z500 (Geopotencial 500 hPa)	5 días	~280-300 m	Línea base.
	ACC	Z500	5 días	~0.95	Línea base.
Aurora (Microsoft)	RMSE	Z500	5 días	~265 m	Supera al IFS-HRES.
	ACC	Z500	5 días	~0.96	Supera al IFS-HRES.
GraphCast (Google)	RMSE	T850 (Temperatura 850 hPa)	5 días	~1.13 K	Supera al IFS-HRES en un 15.6%.
	Error de Seguimiento	Ciclones Tropicales	3 días	~90 km	Mejora significativa, reduciendo error en ~30 km.
Pangu-Weather (Huawei)	RMSE	Z500	5 días	~292 m	Ligeramente mejor o comparable al IFS-HRES.
	Velocidad	Tiempo de Inferencia	24h	~1.4 segundo	10,000 veces más rápido que el IFS-HRES
FourCastNet (NVIDIA)	RMSE	Z500	5 días	~340 m	Ligeramente peor que el IFS-HRES en su momento.
	ACC	Z500	5 días	~0.93	Comparable, pero ligeramente inferior

Nota: RMSE (Error Cuadrático Medio) se da en las unidades de la variable. Un número más bajo es mejor. ACC (Coeficiente de Correlación de Anomalía) es una puntuación de 0 a 1. Un número más alto es mejor.

Con el fin de asegurar la replicabilidad del proyecto, a continuación, se detallan las herramientas utilizadas para la extracción, transformación y procesamiento de datos. Lenguaje Python en Visual Studio Code. El proceso se ejecutó en un computador portátil Dell con un procesador Intel Core i7, memoria de almacenamiento SSD 512 Gb, 16Gb de RAM, tarjeta gráfica integrada, sistema operativo Windows 11 Home de 64 bits.

Los datos de entrenamiento se extrajeron mediante la Interfaz de Programación de Aplicaciones (API) del Almacén de Datos Climáticos (CDS) de Copernicus, utilizando específicamente el dataset “ERA5 post-processed daily statistics on pressure levels from 1940 to present”, “ERA5 post-processed daily statistics on single levels from 1940 to present” y “ECMWF wave data”. Estos datasets son reanálisis atmosféricos globales de alta resolución de los cuales se extrajeron los datos con pasos de tiempo de 6hrs en formato NetCDF (.nc). La decisión sobre la zona geográfica se tomó basándose en la jurisdicción de la Armada de Colombia en el Océano Pacífico y Atlántico. Se recopilieron datos en el siguiente marco geográfico: 15° Norte hasta 6° Sur, 83° Oeste hasta 62° Oeste. A esta zona de estudio se le denominó "Norte de Sudamérica y el Caribe Sur" con el fin de abarcar mínimamente la jurisdicción marítima colombiana. Ver imagen 1.



Imagen 1. Zona "Norte de Sudamérica y el Caribe Sur"

Para este modelo inicial, se seleccionó un conjunto de variables de entrada que cubren los fenómenos atmosféricos clave y su interacción con la superficie marina. Estas variables, disponibles en los datasets de ERA5, se exponen a continuación:

TABLA 2

SELECCIÓN DE VARIABLES

Variable (Nombre en Dataset)	Unidades	Descripción
Temperatura a 2 metros (t2m)	K	Este parámetro es la temperatura del aire a 2 metros sobre la superficie (tierra, mar o aguas interiores). Se calcula interpolando entre el nivel más bajo del modelo y la superficie terrestre. Sus unidades son Kelvin (K).
Componente U del Viento a 10m (u10)	m s ⁻¹	Componente zonal (Este-Oeste) del viento a 10 metros. Representa la velocidad horizontal del aire que se mueve hacia el este. La combinación con la componente V (v10) permite obtener el vector de viento completo
Componente V del Viento a 10m (v10)	m s ⁻¹	Componente meridional (Norte-Sur) del viento a 10 metros. Representa la velocidad horizontal del aire que se mueve hacia el norte. Se combina con la componente U (u10) para definir el vector de viento
Presión a Nivel Medio del Mar (msl)	Pa	Presión atmosférica en la superficie, ajustada a la altura media del nivel del mar. Es una medida del peso de la columna de aire y se utiliza para identificar sistemas de alta y baja presión. Sus unidades son Pascales (Pa)
Temperatura Superficial del Mar (sst)	K	Temperatura del agua del mar cerca de la superficie. En ERA5, corresponde a una temperatura de base (foundation SST), lo que implica que no presenta variaciones por el ciclo diario del sol. Sus unidades son Kelvin (K)
Temperatura a Niveles de Presión (t)	K	Temperatura del aire en la atmósfera, disponible en múltiples niveles de presión (ej. 850, 500 hPa). Controla la densidad del aire y es un motor termodinámico clave
Humedad Específica (q)	kg kg ⁻¹	Masa de vapor de agua por kilogramo de aire húmedo. Es el "combustible" para la formación de nubes y precipitación, representando la humedad disponible en la atmósfera
Geopotencial (z)	m ² s ⁻²	Energía potencial gravitacional de una masa de aire por unidad de masa, relativa al nivel del mar. La altura geopotencial (Geopotencial / g) se utiliza para trazar mapas a niveles de presión constante e identificar vaguadas y dorsales
Componentes del Viento a Niveles de Presión (u, v)	m s ⁻¹	Componentes zonales (u, Oeste-Este) y meridional (v, Norte-Sur) del viento en diferentes niveles de presión. Describen el momento y las corrientes en chorro, siendo fundamentales para el transporte de calor y humedad
Altura Significativa de la Ola (swh)	m	Promedio de la altura del tercio de olas más altas en un registro de oleaje. Es el principal indicador del estado del mar y del peligro para la navegación. Proviene del dataset de olas de ECMWF
Máscara Tierra-Mar (lsm)	Adimensional	Parámetro (0 a 1) que indica la proporción de tierra en una celda de la grilla. Un valor cercano a 1 representa tierra y 0 representa agua. Permite al modelo distinguir entre superficies oceánicas y continentales

El estudio se centrará en la predicción del clima en las franjas marítimas del Pacífico y Caribe (Atlántico) frente a la costa colombiana. Con una resolución espacial de 0.25° , un paso de pronóstico de 6 horas y un horizonte temporal de 18 horas atrás. Son necesarios cuatro pasos de tiempo para hacer una predicción de un día. Las mismas variables de entrada son las variables de salida.

Los datos fueron preprocesados una vez fueron descargados de la base de datos ERA5. Para ello, se utilizó la librería xarray siguiendo los pasos:

1. **Fusión de datos:** los datos se descargaron separados, según cada uno de los datasets que contenía la variable de interés, y se realizó un merge de los diferentes frames en un único dataset.
2. **Ingeniería de variable temporal:** Para tratar la discontinuidad cíclica de la hora del día (el paso de 23:00 a 00:00), la variable temporal se transformó en dos dimensiones continuas utilizando funciones seno y coseno:

$$hour_sin = \sin(2\pi * hora/24) \quad (1)$$

$$hour_cos = \cos(2\pi * hora/24) \quad (2)$$

Con la conversión realizada, se obtienen dos dimensiones con rangos de salida entre -1 y $+1$, donde $hour_sin \in [-1, 1]$ y $hour_cos \in [-1, 1]$. De esta manera, la pareja $(hour_sin, hour_cos)$ describe un punto en el círculo unitario, lo que permite que las 23:00 y las 0:00 horas queden muy próximas geoméricamente. Finalmente, se filtraron los datos nulos encontrados en el dataset.

3. **Normalización:** Cada variable fue normalizada para escalar los datos a un rango común.
4. **Formato del Tensor:** Los datos se estructuraron en tensores con la forma $[batch, time_steps, features]$, un formato que permite capturar dependencias temporales y facilita el cómputo vectorizado en GPU.

La problemática fue abordada utilizando un modelo basado en redes neuronales con una arquitectura LSTM (Long Short-Term Memory), reconocida por su capacidad para capturar dependencias a largo plazo en series de datos temporales.

El proceso de entrenamiento fue el siguiente:

1. **División de Datos:** El dataset se dividió en conjuntos de entrenamiento y validación.
2. **Función de Pérdida:** Se implementó una función de pérdida basada en el Error Cuadrático Medio (`torch.nn.MSELoss`):

$$torch.nn.MSELoss() + sqrt() \quad (3)$$

3. **Dataloader:** Se diseñó un dataloader para encapsular los datos en lotes, mezclar las muestras en cada época y paralelizar la lectura de datos.
4. **Early Stopping:** Se implementó un mecanismo de detención temprana con una paciencia de 5 épocas para finalizar el entrenamiento si la pérdida en el conjunto de validación no mostraba mejora.

Despliegue y Consumo del Modelo:

Para facilitar el uso operativo del modelo, se planea su contenedorización utilizando Docker. Esto encapsula el modelo y todas sus dependencias en un entorno aislado y reproducible. El modelo contenedorizado se

expondrá a través de una API RESTful, permitiendo que sea consumido de manera sencilla por otras aplicaciones para obtener predicciones del clima marítimo.

El modelo LSTM realiza la predicción para cada punto latitud/longitud pasando su ventana de tiempo más reciente. Es decir, dado que para una misma hora existen diferentes coordenadas (longitud/latitud), el modelo recibe para los diferentes puntos (según la resolución definida) las ventanas de tiempo definidas. El modelo devuelve h valores que reconstruimos en un documento JSON por punto.

III. RESULTADOS

El modelo A-LSTM fue evaluado a través de dos métricas, el Error Absoluto Medio (Mean Absolute Error-MAE) y la Raíz del Error Cuadrático Medio (Root Mean Squared Error-RSME). Estas medidas de magnitud nos permiten hacer los primeros acercamientos al comportamiento del modelo.

Como se puede observar en el gráfico 1, izquierda, los valores de pérdida (Loss) para entrenamiento y validación pese a tener tendencia a decrecer, no llegan a estar lo suficientemente cerca. El Loss de entrenamiento tiene el comportamiento esperado, comienza en un valor alto y comienza a disminuir de manera constante. Con esta información se podría decir que el modelo tiene la capacidad de aprender los patrones. Por otra parte, el Loss de validación, pese a que logra mejorar, los picos de crecimiento y decrecimiento muestra que el modelo no es capaz de aplicar a los datos nuevos los patrones que encontró.

Es clave entender que la brecha entre ambas pérdidas indica que el modelo es muy experto con los datos de entrenamiento, pero no es capaz de ir más allá de los datos “memorizados”. Se exploraron diferentes alternativas para mejorar esta métrica y los expuestos son los mejores resultados obtenidos. Se implementó un “feature engineering”, ingeniería de características, a través de un XGBoost; sin embargo, los resultados indican que todas las variables incluidas en el modelo son relevantes. Se implementó “early stopping” con una paciencia de 5 en la fase de entrenamiento.

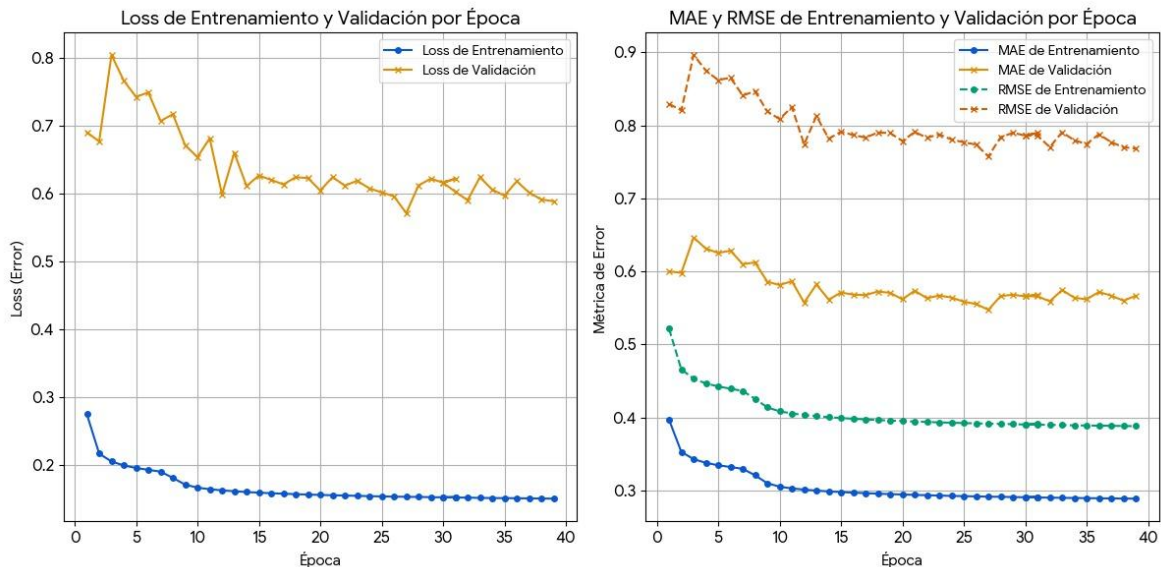


Gráfico 1. A la izquierda, Loss de Entrenamiento y Validación por época. A la derecha, MAE y RMSE de Entrenamiento y Validación por época.

Por otra parte, en el gráfico 1, derecha, las gráficas para MAE y RMSE confirman lo expuesto anteriormente por la función de pérdida: el modelo está sobre ajustado. Ambas curvas, de MAE y RMSE, muestran un aprendizaje exitoso, comienzan en un valor alto y bajan suavemente hasta estabilizarse en valores bajos. Sin embargo, con los datos de validación, el modelo A-LSTM tienen valores muy altos que no mejoran a lo largo del tiempo. Nuevamente, la brecha entre el entrenamiento y la validación nos muestra que el modelo está sobre

ajustado. El problema ha sido claramente identificado, el modelo es muy bueno memorizando, pero no entendiendo las dinámicas subyacentes en los datos.

IV. DISCUSIÓN

El modelo A-LSTM fue configurado para tener la capacidad de predecir el clima en la jurisdicción marítima colombiana haciendo uso de IA para tal fin. Se estimó esta zona geográfica (ver imagen 1) dado que la Armada de Colombia tiene competencia en dicho territorio. Sin embargo, los resultados de la evaluación sugieren que el modelo A-LSTM es capaz de memorizar los datos, pero no de aplicar los patrones aprendidos a nuevos datos. Es decir, el modelo puede informar sobre lo ocurrido en el pasado, pero no es lo suficiente robusto para comprender por qué en el Pacífico (chocó) llueve excesivamente. Esto es, la capacidad de “comprender” la realidad del modelo alcanza para “ver” los cambios de presión entre el Caribe y el Pacífico y cómo este “embudo” creado por la geografía influye en las lluvias del Pacífico.

Las tres medidas utilizadas para evaluar el modelo “Loss”, “MAE” y “RSME”, confirman que el modelo tiene un sobre ajuste que no le permite una apropiada capacidad de generalización. Con el fin de enriquecer la discusión, se proponen mejoras en diferentes frentes para así ganar terreno en la creación de un modelo competitivo de predicción del clima.

El desarrollo del modelo A-LSTM inicial, aunque fundamental como prueba de concepto, revela limitaciones inherentes a su diseño que abren la puerta a mejoras estratégicas. La siguiente discusión, se centra en interpretar estas limitaciones y proponer una evolución del modelo para convertirlo en una herramienta de pronóstico robusta y operativamente relevante para la Armada de Colombia. Esta sección va más allá de los resultados preliminares, explorando el significado y la relevancia de las decisiones de diseño del modelo. En primer lugar, se abordará el dominio geográfico ampliado, en segundo lugar, se discutirán nuevas variables de relevancia operativa, en tercer lugar, se discutirá un nuevo enfoque en el input y output para el modelo B, en cuarto lugar, se abordará un enfoque de resolución temporal mejorado y, finalmente, se expondrá la necesidad de incluir la medición Coeficiente de Correlación de Anomalía (Anomaly Correlation Coefficient -ACC) para que el modelo B sea comparable con el estándar de la industria.

Dominio geográfico ampliado

El modelo A-LSTM fue utilizado para un área geográfica denominada “Norte de Sudamérica y el Caribe Sur” centrada en la jurisdicción marítima inmediata de Colombia. Este enfoque resulta lógico dado que se busca una herramienta que sirva a la predicción del clima para la zona operativa de la Armada de Colombia. Sin embargo, el marco geográfico definido limita la capacidad del modelo para aprender las *teleconexiones climáticas*, que son fenómenos a gran escala que se originan lejos pero que determinan el clima local. La literatura científica respalda firmemente la necesidad de un dominio geográfico más amplio [14] [15].

Por ejemplo, investigaciones sobre la formación e intensificación de ciclones tropicales demuestran la importancia de capturar la temperatura de la superficie del mar y los patrones de viento a gran escala que actúan como precursores [16]. El modelo A-LSTM, con su límite este 83°W, no puede “ver” el nacimiento de las ondas del este africanas, las “semillas” de la mayoría de los huracanes del Caribe. De manera similar, un límite oeste más amplio es crucial para capturar las anomalías de temperatura en las regiones Niño 3 y 3.4, el corazón del fenómeno ENSO, que es el principal modulador del clima en Colombia.

Por este motivo, se discute la posibilidad de un trabajo a futuro en el que el límite geográfico sea ampliado hasta la zona conocida como el “Cinturón Tropical de las Américas” 30°N, 120°W, 20°S y 15°W. Ver imagen 2.



Imagen 2. Zona “Cinturón Tropical de las Américas”.

Límite 120°W

El fenómeno climático ENSO (El Niño/La Niña) es clave para el clima en Colombia ya que modifica drásticamente los patrones de lluvia y temperatura en todo el país. Es un fenómeno a escala del Pacífico. Por tanto, el límite Oeste de 120°W es fundamental ya que le permite al modelo ver las anomalías de temperatura en la superficie del mar en las regiones Niño 3 y 3.4, que son el corazón de ENSO. El modelo aprenderá la conexión entre un Pacífico cálido y una sequía en Colombia.

Límite 15°W

Por otra parte, el fenómeno de Ondas del Este Africanas, como ya se mencionó, son las "semillas" de la mayoría de los huracanes y ondas tropicales que afectan el Caribe. Se forman sobre África y viajan hacia el oeste. El límite Este de 15°W captura la costa de África. El modelo puede "ver" nacer estas ondas 5-10 días antes de que lleguen al Caribe, dándole una capacidad predictiva real.

El límite Este (15°W) y Norte (30°N)

El fenómeno conocido como “Anticiclón de las Azores” es el "motor" semi-permanente de alta presión en el Atlántico que impulsa los vientos alisios hacia el Caribe. La fuerza y posición de este anticiclón determina la intensidad de los vientos y el transporte de humedad. El límite Este (15°W) y Norte (30°N) permiten que el modelo vea la parte sur y oeste de este sistema de alta presión, entendiendo la fuente de los vientos.

El límite Norte de 30°N

De Norteamérica bajan frentes fríos. En la temporada seca (diciembre-marzo), los frentes fríos que bajan desde EE. UU. empujan la Zona de Convergencia Intertropical (ZCIT) hacia el sur, trayendo vientos y oleaje al Caribe colombiano. El límite Norte de 30°N permite al modelo ver estos frentes descendiendo por el Golfo de México, anticipando su llegada a la costa colombiana.

Corriente en chorro del Chocó/Panamá

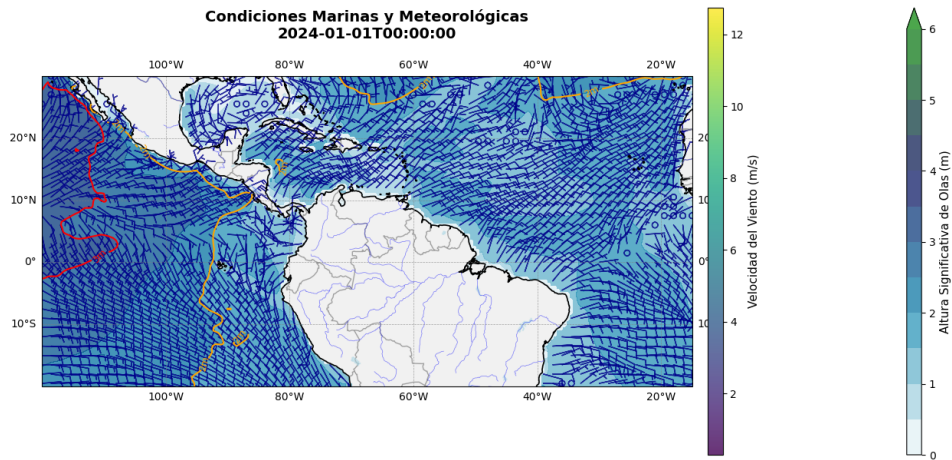
Es un chorro de viento a baja altitud que fluye más cerca de la superficie, atrapado por la geografía. Esta “cinta transportadora” es propulsada por un gradiente de presión. En el Caribe, suele haber un sistema de alta presión de manera semi-permanente, mientras que, en el Pacífico, cerca del Ecuador, se forma la Zona de

Convergencia Intertropical (ZCIT), esto es, un cinturón de baja presión propulsada a través de un “embudo” de Panamá. Con estas piezas, el modelo puede aprender por qué en la zona del Pacífico llueve tanto y así anticipar lluvias en la costa Pacífica.

El límite Sur de 20°S

La corriente fría que sube por la costa de Perú y Ecuador influye fuertemente en la temperatura del Pacífico sur. Por tanto, el límite Sur de 20°S asegura que el modelo vea la influencia de esta corriente y su interacción con el sistema ENSO.

El clima no es un evento aislado y Colombia no es la excepción. Es necesario ampliar la zona geográfica para poder hacer predicciones más precisas [17].



Densidad viento: 1/6 | Datos: -120.0°-15.0°E, -20.0°-30.0°N

Gráfico 2. Condiciones de viento y olas. Gráfico para instante de tiempo 01.01.2024 en 00 horas 00 minutos 00 segundos.

VARIABLES DE RELEVANCIA OPERATIVA

El modelo A-LSTM se enfocó en 11 variables de las cuáles, la literatura nos indica que podemos refinar [18]. La variable resonancia de la ola es tan crítica como la altura de la ola. Esto se debe a que el periodo de la ola puede inducir resonancia y movimientos de balanceo violentos a la embarcación. De igual forma, la dirección de la ola es vital, pues las olas de través (de costado) presentan un riesgo mayor para la embarcación y por ende para la tripulación. Manuales operativos como el "Commander's Handbook on Naval-Air Environmental Services" del "Network Manager Operations Centre" (NMOC) detallan cómo la visibilidad, afectada por la niebla o la lluvia intensa, degrada el rendimiento de sensores clave como el sonar y el radar, y compromete la seguridad de las operaciones en cubierta [19].

Por tanto, en el trabajo a futuro, se debe incluir estas variables de suma importancia operativa. A saber, periodo de la ola (*mwp*), dirección de la ola (*mwd*) y visibilidad.

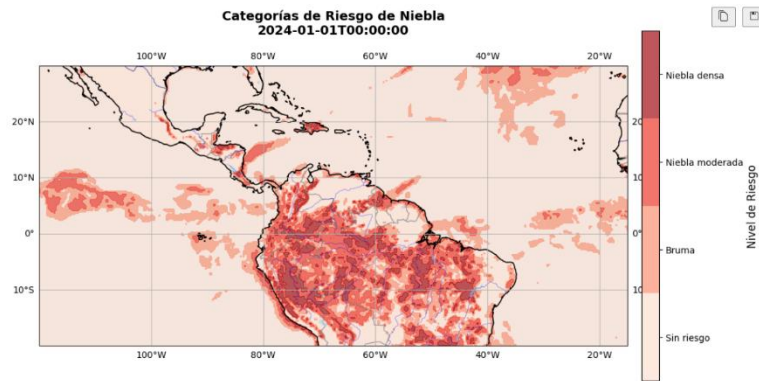


Gráfico 3. Categorías de riesgo de niebla por zonas. Gráfico para instante de tiempo 01.01.2024 en 00 horas 00 minutos 00 segundos.

VARIABLES BASE Y EFECTO

El diseño inicial del modelo A-LSTM, si bien es funcional, opera bajo un paradigma predictivo simple; esto es, recibir todas las variables de un tiempo t , y predecir todas las variables en un periodo $t+1$. Este enfoque autorregresivo multivariado, incentiva al modelo a aprender correlaciones temporales simples en lugar de “*causas y efectos*” complejos. Lo que se busca es entrenar un modelo B en el que se pueda separar las variables en *base y efecto* y, por tanto, que pueda comprender las complejas interacciones físicas subyacentes [17].

Para lograr este objetivo, se propone:

VARIABLES DE BASE:

Las variables de base (o los predictores), son aquellas que describen el estado fundamental y completo del sistema océano-atmósfera. Incluyen parámetros como la presión a nivel del mar, la temperatura y humedad en diferentes niveles de la atmósfera, el geopotencial y los campos de viento. Estas variables representan la “*causa*” o el “*motor*” del sistema climático. Son la única información que se proporciona al modelo como entrada.

VARIABLES DE EFECTO:

Las variables de efecto (las predichas), son aquellas variables que son el resultado directo de la interacción de las variables de base y representan el impacto tangible y medible en las operaciones navales. Estas variables son: la altura, periodo y dirección de las olas, el viento en superficie y el riesgo de baja visibilidad.

Con este nuevo enfoque de inputs y outputs, se espera que el modelo reciba las variables de base como una secuencia temporal y su única tarea sea predecir las nuevas variables de base (las que seguirán sirviendo para las nuevas predicciones) y las variables de efecto. Las variables de efecto nunca serán reintroducidas como variables de entrada para predicciones futuras. Esto con el fin de que el modelo no se vuelva “*perezoso*”.

Por ejemplo, para predecir la altura de la ola (swh) en 6 horas, el modelo no puede usar el valor de swh actual; debe inferirlo a partir de la física que aprende de la secuencia de vientos ($u10/v10$), presión (msl), etc. Esto obliga a aprender la relación física entre el viento y la generación de oleaje, en lugar de simplemente extrapolar el valor anterior de la ola.

A continuación, se resumen las variables propuestas para el trabajo futuro.

TABLA 3

VARIABLES BASE			
Tipo	Variable	Nombre en el dataset	Descripción
3D atmosférica	Geopotencial	z	Impulsa el viento y la dirección de las tormentas en altura.
	Temperatura	t	Motor termodinámico; controla la densidad del aire.
	Humedad Específica	q	"Combustible" para la formación de nubes y precipitación.
	Viento Zonal (Oeste-Este)	u	Describe el momento y las corrientes en chorro.
	Viento Meridional (Norte-Sur)	v	Describe el transporte de calor y humedad.
2D Superficie	Presión a Nivel del Mar	msl	Condición de presión fundamental que experimentamos.
	Temperatura a 2 metros	$t2m$	Temperatura del aire en la capa límite.
	Punto de Rocío a 2 metros	$d2m$	Clave para calcular la humedad relativa y el riesgo de niebla.
	Viento a 10m (Componente U)	$u10$	Interacción directa del viento con la superficie del mar.
	Viento a 10m (Componente V)	$v10$	Interacción directa del viento con la superficie del mar.
	Temperatura Superficie del Mar	sst	Principal fuente de calor y humedad para la atmósfera.
	Agua Precipitable Total	$tcwv$	Medida integrada de toda la humedad; predictor de lluvias intensas.
2D Estática	Máscara Tierra-Mar	lsm	Le dice al modelo qué es tierra y qué es mar.
	Orografía (Elevación)	$orography$	Modifica los patrones de viento y precipitación.

TABLA 4

VARIABLES EFECTO			
Categoría	Variable	Nombre en el dataset	Utilidad operativa
Viento	Viento a 10 metros	<i>u10, v10</i>	Evaluar la manejabilidad del buque y el estrés sobre la carga.
	Altura Significativa de la Ola	<i>swh</i>	Principal indicador de peligro para la estructura y estabilidad del buque.
	Periodo Medio de la Ola	<i>mwp</i>	Evaluar el riesgo de resonancia y movimientos violentos de balanceo.
Olas	Dirección Media de la Ola	<i>mwd</i>	Determinar el ángulo de impacto de las olas (olas de través son peores).
Visibilidad	(Proxy de) Baja Visibilidad	<i>riesgo_baja_visibilidad</i>	Evaluar el riesgo de colisión por niebla (calculado a partir de t2m y d2m).
Peligros	Precipitación Total	<i>tp</i>	Indicar baja visibilidad por lluvia intensa y posible daño a la carga.
Atmosfera	Presión a Nivel del Mar	<i>msl</i>	Alertar sobre la aproximación de tormentas (tendencia a la baja).

La visibilidad se definió a través de una variable calculada (proxy) a partir del diferencial (spread) entre la temperatura del aire y la temperatura de punto de rocío. Para ello se aplica la siguiente lógica, la niebla se forma cuando el aire se satura de humedad. Esto ocurre cuando la temperatura del aire baja y se acerca a su punto de rocío. Cuanto más pequeña es la diferencia entre estas dos temperaturas, más cerca está el aire de la saturación (100% de humedad relativa) y mayor es el riesgo de niebla.

Para el cálculo aproximado se necesita tener en el dataset consolidado las siguientes variables (ambas provenientes de reanalysis-era5-single-levels): 1. Temperatura a 2 metros (La temperatura del aire cerca de la superficie, en grados Kelvin) y 2. Temperatura de punto de rocío a 2 metros (La temperatura a la que el aire se saturaría, también en grados Kelvin).

$$riesgo_baja_visibilidad = t2m - d2m \quad (4)$$

Resolución temporal mejorada

El modelo A-LSTM, usó el paso de tiempo de 6 horas, estándar en muchos reanálisis globales. Este paso de tiempo es adecuado para capturar fenómenos de escala sinóptica (sistemas de alta y baja presión que evolucionan a lo largo de días). Sin embargo, este intervalo es demasiado grande para resolver fenómenos de mesoescala, críticos para las operaciones navales diaria.

Un paso de tiempo de 1 hora permitiría al modelo aprender y predecir el ciclo diurno, como la formación de brisas marinas y terrestres, o la rápida intensificación de tormentas eléctricas por la tarde. Estos fenómenos, que ocurren en escalas de tiempo de pocas horas, son promediados y perdidos en una resolución de 6 horas [20]. Al proporcionarle al modelo datos más frecuentes, no solo se mejora la precisión a corto plazo, sino que se le permite aprender la física subyacente de estos procesos de rápido desarrollo, en lugar de solo su ocurrencia estadística. Esto es fundamental para la planificación táctica de misiones que duran menos de un día. Adicionalmente, considerando la cantidad de datos utilizada por los modelos de alto desempeño mencionados anteriormente, se recomienda ampliar los años utilizados para entrenamiento.

Anomaly Correlation Coefficient-ACC

Incluir esta medición es de alta relevancia si el modelo B va a ser comparable con los modelos referentes de la industria. El ACC se calcula para un campo o mapa 2D, para una variable específica en un momento de pronóstico determinado.

Cálculos necesarios:

1. Campo de pronóstico (F): el mapa del modelo es una cuadrícula o grilla de valores (para temperatura, por ejemplo) para una fecha y hora futura.
2. Campo de análisis (A): el mapa de “verdad”. Es la mejor estimación para lo que ocurrió en esa misma fecha y hora.
3. Campo climatológico (C): el mapa del promedio histórico para esa fecha del año.

La anomalía es la desviación del estado “normal”.

Anomalía del pronóstico:

$$F' = F - C \quad (5)$$

Anomalía del análisis:

$$A' = A - C \quad (6)$$

Una vez se tiene las dos anomalías, se calcula la correlación de Pearson entre las anomalías:

$$ACC = Cov(F', A') / (\sigma_{F'} * \sigma_{A'}) \quad (7)$$

Donde:

- $Cov(F', A')$ es la covarianza entre los campos de anomalías de pronóstico y análisis.
- $\sigma_{F'}$ es la desviación estándar del campo de anomalías del pronóstico.
- $\sigma_{A'}$ es la desviación estándar del campo de anomalías del análisis.

Adicionalmente, se debe considerar la ponderación de cada cuadrícula en el cálculo del ACC; esto es, las grillas cercanas al Ecuador son más grandes que las cercanas a los polos, por consiguiente, representan más área. La fórmula en su aplicación práctica sería la siguiente:

$$ACC = \frac{\sum [w(i) * (F'(i) - \mu_{F'}) * (A'(i) - \mu_{A'})]}{\sqrt{\sum [w(i) * (F'(i) - \mu_{F'})^2] * \sum [w(i) * (A'(i) - \mu_{A'})^2]}} \quad (8)$$

Donde:

- i es el índice de cada punto de la cuadrícula
- $w(i)$ es el peso del área.

$$w(i) = \cos(\text{latitud}(i)) \quad (9)$$

- $\mu_{F'}$ y $\mu_{A'}$ son los promedios ponderados por área de los campos de anomalías.

Para que el cálculo del ACC sea comparable entre el modelo B y los modelos de la industria, se debe considerar lo siguiente:

- El estándar de datos es la base de datos ERA5.
- Uso de resolución estándar, típicamente $0.25^\circ \times 0.25^\circ$.
- La climatología debe basarse en el mismo dataset ERA5.
- Considerar los periodos estándar para la evaluación, típicamente 30 años.
- Para cada día del año y para cada hora, se calcula el valor promedio sobre el periodo de años. Normalmente se calcula para día 1 (24h), día 3 (72h), día 5 (120h), día 7 (168h), día 10 (240h).
- Se debe calcular el ACC para variables relevantes, típicamente, “Altura Geopotencial a 500 hPa (Z500)”, “Temperatura a 850 hPa (T850)”, “Temperatura a 2 metros (T2m)”, “Velocidad del Viento (U y V)” a varios niveles, “Presión a Nivel del Mar (MSLP)”.
- El cálculo del ACC no se calcula globalmente sino en regiones específicas con dinámicas atmosféricas coherentes (hemisferio norte, sur, trópicos).

El modelo A-LSTM tuvo que ser planteado, diseñado, entrenado y optimizado en un tiempo muy corto, menor a dos meses. Todos los hallazgos a partir del modelo inicial han ido sumando a la creación de un modelo mucho más avanzado con capacidades que aún están por descubrirse. Se espera que en el futuro se pueda implementar el modelo B, con todas las mejoras y la experiencia aquí mencionadas.

V. CONCLUSIONES

El modelo A-LSTM fue entrenado como una herramienta para la Armada de Colombia con el fin de generar pronósticos del clima haciendo uso de la arquitectura de IA. Los resultados del abordaje realizado muestran que el modelo aun está en una fase de ajuste y desarrollo. Medidas de evaluación del modelo como el MAE y el RMSE demostraron que el modelo A-LSTM es capaz de memorizar, pero aún no tiene capacidad de generalización. Esta situación se debe a que la predicción del clima tiene grandes implicaciones subyacentes, como las dinámicas atmosféricas locales y globales.

El modelo referente IFS-HRES (ECMWF) es un modelo fisicomatemático que resuelve las ecuaciones que gobiernan el clima y de esa forma hace pronósticos fiables. Existen modelos que utilizan arquitecturas de IA que “simplifican” la misión de predicción, logrando incluso métricas superiores que el IFS-HRES. Esta nueva ventana en los métodos para predecir el clima ha abierto el camino que se ha recorrido en este trabajo. Sin embargo, dados los resultados obtenidos, es necesario que se hagan ajustes pertinentes para continuar avanzando hacia un modelo robusta y funcional para la Armada.

A partir de los resultados y el análisis hecho del modelo A-LSTM, se recomienda: 1. Hacer un ajuste a la zona geográfica, expandiéndola al cinturón tropical de las Américas. 2. Incluir variables de relevancia operativa como la dirección de la ola y periodo de la ola. 3. Cambiar el paradigma de predicción de uno simple (autorregresivo multivariado) a uno complejo (causa y efecto). 4. Resolución temporal mejorada de pasos de 6 horas a pasos de 1 hora, incluyendo un periodo de tiempo de entrenamiento basado en la bibliografía. 5. Incluir la métrica ACC para tener punto de comparación del modelo B con los modelos de la industria.

En conclusión, el modelo A-LSMT es un modelo concepto que ha abierto el camino para comenzar el entendimiento y desarrollo de modelos mucho más robustos y complejos que sean competitivos en la predicción del clima. Se recomienda aplicar los hallazgos del presente documento para trabajos futuros y así avanzar en el logro del desarrollo del mejor modelo posible.

RECONOCIMIENTO

Agradecer a la Armada de Nacional de Colombia por la confianza depositada en nuestro conocimiento y persistencia para lograr las metas propuestas.

A la Universidad Icesi por brindar el espacio en el que se conjugan las personas y sus saberes en pro de la mejora y desarrollo continuo.

REFERENCIAS

- [1] NOAA Fisheries. (2024, January). Targeted Climate Research Can Benefit Marine Resource Management in the Northeast United States. [Online]. Available: <https://www.fisheries.noaa.gov/feature-story/targeted-climate-research-can-benefit-marine-resource-management-northeast-united>.
- [2] A. Allen, et al., "End-to-end datadriven weather prediction," Nature, Mar. 2025.
- [3] A. Denvil-Sommer. (2024, December). Advancing Mesoscale Process Representation in Ocean Models with Machine Learning. Weather and Climate @ Reading [Online]. Available: <https://blogs.reading.ac.uk/weather-and-climate-at-reading/2024/advancing-mesoscale-process-representation-in-ocean-models-with-machine-learning/>
- [4] Armada de la República de Colombia, Informe de Gestión 2024. 2024. [Online]. Available: <https://www.armada.mil.co/sites/default/files/varios/Informe%20de%20Gestion%20ARC%202024.pdf>
- [5] G. Bonino, G. Galimberti, S. Masina, R. McAdam, and E. Clementi, "Machine learning methods to predict sea surface temperature and marine heatwave occurrence: a case study of the Mediterranean Sea," Ocean Sci., vol. 20, pp. 417–432, Mar. 2024.
- [6] Z. Ouyang, Y. Gao, X. Zhang, X. Wu, and D. Zhang, "Significant Wave Height Forecasting Based on EMD-TimesNet Networks," J. Mar. Sci. Eng., vol. 12, p. 536, Mar. 2024.
- [7] J. Zhang, et al., "Improving wave height prediction accuracy with deep learning," Ocean Modelling, vol. 188, p. 102312, Apr. 2024.
- [8] J. P. Mishra, S. Sharda, S. Vyas, R. Parashar, and Y. Sharma, "Machine Learning-Based Approach for Predicting Ocean Surface Temperature," Research Square, [Preprint], Jul. 2024. Available: <https://doi.org/10.21203/rs.3.rs-4501938/v1>
- [9] F. C. Minuzzi and L. Farina, "A deep learning approach to predict significant wave height using long short-term memory," Ocean Modelling, p. 102151, Dec. 2022.
- [10] C. Bodnar, et al., "A Foundation Model for the Earth System," arXiv preprint arXiv:2405.13063, 2024.
- [11] R. Lam. (2023, November). GraphCast: AI model for faster and more accurate global weather forecasting. Google DeepMind [Online]. Available: <https://deepmind.google/discover/blog/graphcast-ai-model-for-faster-and-more-accurate-global-weather-forecasting/>
- [12] K. Bi, L. Xie, H. Zhang, X. Chen, X. Gu, and Q. Tian, "Accurate medium-range global weather forecasting with 3D neural networks," Nature, vol. 619, pp. 533–538, Jul. 2023.
- [13] J. Pathak, et al., "FourCastNet: A Global Data-Driven High-Resolution Weather Model Using Adaptive Fourier Neural Operators," arXiv preprint arXiv:2202.11214, Feb. 2022.
- [14] I. Hoyos, G. Poveda, et al., "The hydroclimatology of Colombia: A synthesis of the authors' contributions," in The Geology of Colombia. Servicio Geológico Colombiano, 2011, pp. 531-561.
- [15] G. Poveda and O. J. Mesa, "On the existence of the Chocó jet in the pacific coast of Colombia," Estudios Geográficos, vol. 61, no. 238, pp. 177-188, 2000.
- [16] T. A. Smith, et al., "Ocean-wave coupled modeling in COAMPS-TC: A study of Hurricane Ivan (2004)," Ocean Modelling, vol. 69, pp. 181-194, 2013.
- [17] J. Marshall and R. A. Plumb, Atmosphere, Ocean, and Climate Dynamics: An Introductory Text. Burlington, MA: Elsevier Academic Press, 2008.
- [18] A. R. J. M. Lloyd, Seakeeping: Ship Behaviour in Rough Weather. Chichester: Ellis Horwood, 1989.
- [19] Department of the Navy, U.S. Marine Corps, and U.S. Coast Guard, *The Commander's Handbook on the Law of Naval Operations*. Mar. 2022. [Online]. Available: https://usnwc.edu/Portals/2/documents/stockton/nwcs-review/2022_Commanders_Handbook_Naval_Operations.pdf
- [20] Bi, K., Xie, L., Zhang, H., Chen, X., Gu, X., & Tian, Q. (2023). Accurate medium-range global weather forecasting with 3D neural networks. Nature, 619, 533-538.