



Evaluación del desempeño de métodos de identificación de remolinos de mesoescala

Juan Rojas^{1,2}, Carolina Parada^{1,3}, Odette Vergara^{2,4}

- (1) Departamento de Geofísica, Facultad de Ciencias Físicas y Matemáticas, Universidad de Concepción, Chile.
- (2) Centro de Investigación Oceanográfica Copas Coastal, Departamento de Oceanografía, Universidad de Concepción, Chile.
- (3) Centro de ecología y Manejo de Islas Oceánicas, Facultad de Ciencias del Mar, Universidad Católica del Norte, Chile.
- (4) Simulación y Pronóstico Marino SpA, Chile.

INTRODUCCIÓN

Los remolinos de mesoescala desempeñan parte fundamental en la dinámica oceánica, redistribuyendo energía, calor y nutrientes (Morrow et al., 2004) mediante mezcla, bombeo y advección. Su identificación es crucial, sin embargo, los métodos tradicionales (físicos, geométricos e híbridos) presentan limitaciones (Xing et al., 2021). En este contexto, técnicas de inteligencia artificial (IA) surgen como una alternativa más robusta al basarse en datos de entrenamiento. Se utiliza el producto GLORYS12v1 (Jean-Michel et al., 2021) para evaluar el desempeño de metodologías basadas en inteligencia artificial e identificar remolinos de mesoescala en la zona circundante a la dorsal de Juan Fernández. Se aplicó el método de identificación de Faghmous et al. (2015) y uno propio basado en contornos cerrados (REDA), con los que se generaron dos dataset para entrenar una red neuronal (desarrollada en este estudio).




Fig. 1: Remolinos detectados mediante los métodos tradicionales Faghmous (izquierda) y REDA (derecha) junto con las detecciones obtenidas por IA. Los contornos rojos (anticiclones) y azules (ciclones) muestran las detecciones del método tradicional. Los contornos amarillos (anticiclones) y verdes (ciclones) corresponden a las detecciones de la IA. El sombreado representa la anomalía del nivel del mar (en metros) del día 3 de junio del 2016.

RESULTADOS




Fig. 3: Distribución espacial de la densidad de remolinos detectados por cada método. Los colores representan el número de veces que un remolino fue detectado en cada píxel, indicando las regiones de mayor recurrencia. Se incluyen las trayectorias de remolinos ciclónicos y anticiclónicos con un tiempo de vida mayor a 10 semanas.




Fig. 5: Evolución temporal de las métricas de rendimiento: precisión $\frac{VP}{VP+FP}$, recall $\frac{VP}{VP+FN}$, accuracy $\frac{VP+VN}{VP+VN+FP+FN}$ y F1 score $\frac{2(precisión \cdot recall)}{precisión + recall}$ de las redes neuronales entrenadas durante el periodo 2014 a 2018 junto con su respectiva matriz de confusión que detallan el porcentaje de aciertos sobre el total de detecciones para las clases ciclónico y anticiclónico.

DISCUSIÓN

- Las redes neuronales aprendieron **satisfactoriamente** los patrones espaciales presentes en las detecciones de los métodos tradicionales (fig. 1 y 3), alcanzando elevadas **métricas de desempeño** (fig. 5).
- El algoritmo desarrollado permitió recuperar las principales **propiedades geométricas** de los remolinos detectados por IA y realizar su **seguimiento temporal** (fig. 3 y 4).
- Las redes identificaron estructuras físicamente coherentes **no detectadas** por el método con que fueron entrenadas, pero respaldadas por otros métodos e **indicadores oceanográficos** (fig. 1 y 6).

- Faghmous, J. H., Frenger, I., Yao, Y., Warmka, R., Lindell, A., & Kumar, V. (2015). A daily global mesoscale ocean eddy dataset from satellite altimetry. Scientific data, 2(1), 1-16.
- Jean-Michel, L., Eric, G., Romain, B. B., Gilles, G., Angélique, M., Marie, D., ... & Pierre-Yves, L. T. (2021). The Copernicus global 1/12 oceanic and sea ice GLORYS12 reanalysis. Frontiers in Earth Science, 9, 698876.
- Morrow, R., Birol, F., Griffin, D., & Sudre, J. (2004). Divergent pathways of cyclonic and anti-cyclonic ocean eddies. Geophysical Research Letters, 31(24).
- Xing, T., & Yang, Y. (2021). Three mesoscale eddy detection and tracking methods: Assessment for the South China Sea. Journal of Atmospheric and Oceanic Technology, 38(2), 243-258.

METODOLOGÍA




Fig. 2: Esquema de la arquitectura de la red neuronal. El modelo recibe un mapa de SLA normalizado (156x96x1) y produce un mapa de probabilidades (156x96x3) correspondiente a las clases fondo, anticiclón y ciclón. Durante la etapa de contracción (encoder), las características se extraen mediante bloques Conv2D, Batch Normalization, ReLU y operaciones de MaxPooling. En la etapa de expansión (decoder), la resolución espacial se recupera mediante UpSampling y concatenación de las características provenientes del encoder (skip connections), finalizando con una capa Softmax para la clasificación píxel a píxel.

DATOS:

Variables: Nivel del mar, componentes U y V de la velocidad
Resolución espacial: 1/12°
Resolución temporal: Diaria
Dominio espacial: 30°S-38°S; 84°O-71°O
Dominio Temporal: 1997 - 2018
Profundidad: 1500 metros

Los métodos de Faghmous y REDA se aplicaron a campos de anomalía del nivel del mar (SLA) para **generar máscaras de segmentación semántica** (etiquetas). Lo generado de 1997 a 2008 se empleó para el **entrenamiento**, de 2009 a 2013 para la **validación** y de 2014 a 2018 para el **testeo** (período donde se realizaron análisis de este estudio). A partir de las detecciones obtenidas mediante IA y del campo de SLA asociado, se desarrolló un **algoritmo para estimar las principales propiedades de los remolinos**, incluyendo la posición del núcleo, el radio, la amplitud y el contorno. Posteriormente, se efectuó el **seguimiento temporal** de cada estructura detectada. Además, se calcularon **métricas de rendimiento** para evaluar las redes entrenadas e **índices oceanográficos de la columna de agua** derivados de las componentes de velocidad.




Fig. 4: Comparación de las características de los remolinos detectados por los métodos Faghmous, REDA y las redes entrenadas con las etiquetas de cada uno: Cantidad mensual de remolinos ciclónicos (barras superiores) y anticiclónicos (barras inferiores) detectados por cada método (panel superior) y distribución porcentual de los radios promedio de los remolinos ciclónicos (izquierda) y anticiclónicos (derecha), agrupados en intervalos de tamaño (panel inferior).




Fig. 6: Estructura vertical de un remolino ciclónico (verde) y uno anticiclónico (amarillo) detectados el 3 de junio del 2016 por la red neuronal entrenada con etiquetas del algoritmo REDA. De izquierda a derecha se observan vorticidad relativa $\frac{\partial v}{\partial x} - \frac{\partial u}{\partial y}$, EKE $\frac{1}{2}((U - \bar{U})^2 + (V - \bar{V})^2)$ donde $\bar{U}$ y $\bar{V}$ son climatologías y Okubo-Weiss $\left(\frac{\partial u}{\partial x} - \frac{\partial v}{\partial y}\right)^2 + \left(\frac{\partial v}{\partial x} + \frac{\partial u}{\partial y}\right)^2 - \left(\frac{\partial u}{\partial x} - \frac{\partial v}{\partial y}\right)^2$ usando un umbral de $-5 \times 10^{-12} [s^{-2}]$. Para cada variable, se presentan cortes horizontales a diferentes profundidades y una sección vertical latitudinal, los puntos superiores simbolizan los núcleos de los respectivos remolinos.

CONCLUSIONES

- La metodología es una alternativa rápida y automatizable para la **identificación, caracterización y seguimiento de remolinos de mesoescala**, con potencial para **extenderse a otros productos oceanográficos y conjuntos de datos**.
- La detección de estructuras respaldadas por **distintos métodos e indicadores oceanográficos** sugiere que la red aprendió **características físicas asociadas a los remolinos**, más allá de reproducir las etiquetas de entrenamiento.

Agradecimientos:
DGEO, Copas Coastal (FB210021), CLAP.