

Control de calidad de perfiles hidrográficos mediante redes neuronales artificiales Quality control of hydrographic profiles based on artificial neural networks

M. D. Fong-González ^{a,*}, M. Castro-Liera ^a, I. Castro-Liera ^a, L. Tenorio-Fernández ^{b,c}, E. Romero ^b

^a Tecnológico Nacional de México, campus La Paz, División de Estudios de Posgrado e Investigación, Blvr. Forjadores de Sudcalifornia No. 4720, Col. 8 de Octubre, C.P. 23080, La Paz, Baja California Sur, México.

^b Instituto Politécnico Nacional – Centro Interdisciplinario de Ciencias Marinas, Departamento de Oceanología, Av. Instituto Politécnico Nacional s/n, Col. Playa Palo de Santa Rita, C.P. 23096, La Paz, Baja California Sur, México.

^c CONACHyT, Consejo Nacional de Humanidades Ciencia y Tecnología, Av. Insurgentes Sur No. 1582, Col. Crédito Constructor, Alcaldía Benito Juárez, C.P. 03940, Ciudad de México, México.

Resumen

El programa internacional Argo realiza mediciones de los océanos empleando perfiladores hidrográficos autónomos. Los datos son analizados por un sistema automatizado que les asigna etiquetas de acuerdo a su calidad antes de ser puestos a disposición de la comunidad científica. Después, los datos son revisados por especialistas a través del control de calidad en modo diferido, donde realizan correcciones. Analizar los perfiles en modo diferido resulta difícil debido al aumento de perfiles medidos mensualmente, por lo que este estudio propone una metodología que utiliza redes neuronales artificiales (RNA) para estimar los valores ajustados de los mismos datos para mejorar su calidad. El modelo resultante genera un valor de R^2 superior a 0.99, volviendo la metodología una alternativa viable cuando no se cuenta con datos procesados por el control de calidad en modo diferido.

Palabras Clave: Océanos, Perfiles hidrográficos, Redes neuronales artificiales, Clasificación, Regresión.

Abstract

The international Argo program makes ocean measurements using autonomous hydrographic profilers. The data is analyzed by an automated system that assigns labels according to their quality and are subsequently made available to the scientific community. Later, they are reviewed by specialists through quality control in delayed mode, where they make corrections. Analyzing the profiles in delayed mode is difficult due to the increase in profiles measured monthly, so this study proposes a methodology that uses artificial neural networks (ANN) to estimate adjusted values of the same data to improve its quality. The resulting model generates an R^2 value greater than 0.99, making the methodology a viable alternative when data processed by quality control in delayed mode is not available.

Keywords: Oceans, Hydrographic profiles, Artificial neural networks, Classification, Regression.

1. Introducción

Abarcando alrededor del 70% de la superficie del planeta, los océanos resultan ser fuente de una variedad de recursos, así como ser reguladores climáticos, lo que los vuelve vitales para la supervivencia de los seres vivos. La comprensión de los cambios que ocurren en el océano resulta indispensable para abordar los efectos inducidos por el cambio climático (OceanOPS, 2018).

Argo es un programa internacional que realiza mediciones in-situ de presión, temperatura y conductividad (salinidad) en

la columna de agua de los océanos, empleando perfiladores hidrográficos autónomos. Los datos recolectados por estos perfiladores son puestos a disposición de la comunidad científica para su libre uso.

Estos datos son procesados por el control de calidad en tiempo real, el cual consiste en un sistema automatizado que los clasifica de acuerdo con su nivel de calidad, asignándoles sus banderas de etiqueta correspondientes. Más tarde, estos datos son analizados por el control de calidad en modo diferido por especialistas ubicados en centros de asimilación de datos, que se encargan de realizar ajustes y/o correcciones

*Autor para la correspondencia: m22310005@lapaz.tecnm.mx

Correo electrónico: m22310005@lapaz.tecnm.mx (Marcos Daniel Fong-González), marco.cl@lapaz.tecnm.mx (Marco Antonio Castro-Liera), iliana.cl@lapaz.tecnm.mx (Iliana Castro-Liera), leonardo.tenof@gmail.com (Leonardo Tenorio-Fernández), romeroqe@gmail.com (Emmanuel Romero).

sobre los datos (Argo, 2022). Este control de calidad tiene como objetivo aplicarse dentro de los primeros 12 meses después de su medición. Sin embargo, alcanzar este objetivo es actualmente extremadamente difícil debido al aumento de perfiles que ocurre mes tras mes, lo que en consecuencia aumenta la carga de trabajo sobre los recursos humanos de los centros de asimilación de datos (Roemmich, et al., 2019; Wong et al., 2020). Este aumento en la carga de trabajo ocasiona que, del total de datos recolectados, una gran cantidad no sea revisada en modo diferido, y que, en caso de ser revisada, el tiempo de revisión demore considerablemente.

En la actualidad, se han realizado esfuerzos que han hecho uso de técnicas de aprendizaje automático para trabajar con estos datos hidrográficos, que buscan reducir los tiempos en que se efectúan los controles de calidad, así como reducir el trabajo humano requerido para ello. Tal es el caso de Ono, et al. (2015), quienes usaron mapas autoorganizados para identificar patrones de error en los perfiles hidrográficos. Zhang, et al. (2023) también se enfocaron en encontrar anomalías en los datos, con la diferencia de que su trabajo se enfoca en datos de temperatura in-situ, empleando el modelo probabilístico Gaussian Mixture Model. Sugiura et al. (2020), demostraron que es posible estimar la calidad de datos desconocidos con buenos resultados al representar la forma de los perfiles hidrográficos como integrales iteradas, para luego realizar aprendizaje supervisado usando el método de firma (signature method). Romero, et al. (2021a) utilizaron la técnica de análisis de grupos, K-medias, para filtrar derivas de salinidad dentro de polígonos establecidos. Pérez (2022) desarrolló un modelo de aprendizaje automático con redes neuronales artificiales (RNA) para completar series temporales de datos hidrográficos en un polígono dado.

Por consiguiente, el objetivo de este trabajo es desarrollar una metodología que emplee modelos de RNA tanto para clasificar los datos de temperatura, salinidad y presión de perfiles hidrográficos de acuerdo con su calidad, como para estimar sus valores ajustados, y en consecuencia mejorar su calidad y servir como una alternativa viable para cuando no se cuenta con datos evaluados por el control de calidad en modo diferido.

2. Metodología

2.1. Descarga de los perfiles hidrográficos

Se delimitó un polígono que cubre un área del Pacífico oriental frente a México, así como un rango de fechas que abarca desde el 1 de enero de 2015 al 31 de diciembre de 2020. Los datos de los perfiles hidrográficos se descargaron en formato netCDF desde el servidor FTP de Argo (<ftp://usgodae.org/pub/outgoing/argo>, consultado el 30 de junio de 2023). A través del archivo de directorio de perfiles del Centro de ensamblaje de datos global de Argo, "ar_index_global_prof.txt" se realizó la búsqueda de perfiles medidos dentro del polígono y del espacio temporal establecido, además de haber sido revisados en modo diferido. Después se compilaron los archivos descargados en un solo archivo con el formato separado por comas (CSV) para que la información fuese procesada por los modelos de RNA. Para la creación del polígono y la descarga de datos, se

desarrolló un programa basado en la librería `cluster_qc` (Romero, et al., 2021b).

2.2. Diseño de clases

Argo utiliza un sistema de banderas (Tabla 1) para etiquetar los datos de acuerdo con su nivel de calidad (Argo, 2022).

Tabla 1: Banderas de calidad empleadas por Argo.

No. de bandera	Significado
0	No se realizó control de calidad.
1	Datos buenos.
2	Datos probablemente buenos.
3	Datos malos potencialmente corregibles.
4	Datos malos (no ajustables).
5	Valor cambiado.
6	Bandera no usada.
7	Bandera no usada.
8	Valor estimado.
9	Valor faltante.

Para simplificar el procesamiento de los datos, las banderas 1, 2 y 3, conservaron su propia clase, mientras que los datos etiquetados con el resto de banderas se agruparon en la clase 4. Esto con el objetivo de conservar los datos necesarios para realizar el ajuste de los mismos, y filtrar los datos que no pueden ser ajustados. Las nuevas clases se presentan en la Tabla 2.

Tabla 2: Clases definidas para los modelos de RNA.

No. de banderas	Significado
1	Datos buenos.
2	Datos probablemente buenos.
3	Datos malos potencialmente corregibles.
4	Clase por defecto.

Las clases resultantes se encontraban desbalanceadas (i.e., la clase 1 contenía una mayor cantidad de datos), por lo que, fue necesario filtrar parte de los datos de la clase 1 para balancear el conjunto de datos.

En la Figura 1 se muestra el flujo de la metodología propuesta en este estudio para clasificar y ajustar perfiles de temperatura y salinidad. En el primer paso, un modelo RNA de clasificación binario transformó las cuatro clases definidas para este trabajo en dos. La clase 1 conservó su propia clase, mientras que la 2, 3 y 4 se agruparon en la segunda clase. Se usaron los datos originales para entrenar, validar y probar el modelo binario. Una vez probado, se aplicó el filtro 1 (que al igual que el filtro 2, se encuentra marcado con flechas rojas en la Figura 1), que consistió en eliminar parte de los datos clasificados como datos buenos (i.e. clase 1) por el modelo binario, de los datos originales, balanceando así el conjunto de datos. Los datos filtrados resultantes se usaron para entrenar el modelo de RNA multiclasa, que los clasificó en las cuatro clases definidas previamente. Una vez hecha la clasificación, se aplicó el filtro 2, el cual consistió en eliminar los datos clasificados como la clase por defecto (i.e. clase 4) de los datos a los que ya se les había filtrado la clase 1

previamente, lo que resultó en un conjunto de datos balanceado y solamente con los datos necesarios para entrenar, validar y probar el modelo RNA de regresión que ajustó los datos.

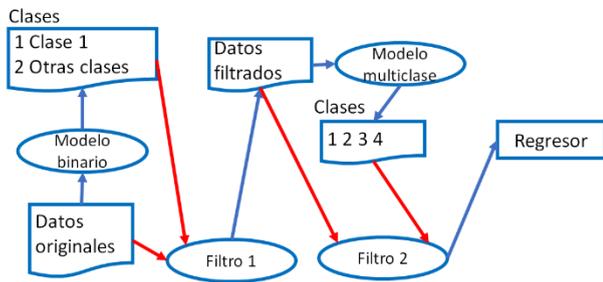


Figura 1: Metodología propuesta. Los elementos utilizados para los filtros se conectan con flechas rojas, mientras que las azules indican el proceso de obtención de los datos clasificados.

2.3. Modelos de RNA

Por medio de la herramienta Talos (disponible para Python) se experimentó con distintas configuraciones de arquitecturas de RNA con el objetivo de encontrar la arquitectura que tuviera el mejor desempeño para cada uno de los modelos de clasificación de los tres tipos de datos diferentes.

La Figura 3 muestra la proporción inicial de las clases. Se observó un desbalance en las cuatro clases, siendo la clase 1 mayoritaria por un alto margen (más del 90%).



Figura 3: Proporción inicial de los datos de los perfiles hidrográficos.

Para evitar que los modelos de RNA presentaran un sesgo hacia la clase mayoritaria (clase 1), se procedió a entrenar modelos de clasificación binarios para filtrar parte de dicha clase, y así balancear las cuatro clases en general, así como los modelos de clasificación multiclase, con Talos. Específicamente se hicieron pruebas utilizando dos capas ocultas, variando únicamente la cantidad de neuronas, probando con un rango de 10 a 60 neuronas por capa y en incrementos de 5.

Los datos usados por los modelos de RNA fueron divididos en tres subconjuntos, que fueron usados para entrenar, validar y probar los modelos (64%, 16% y 20% de los datos, consecutivamente). Los datos que se reservaron para las pruebas consistieron en información hasta ahora desconocida para las RNA, por lo que los experimentos representaron el desempeño de los modelos, utilizando datos que no se les presentaron previamente en el entrenamiento.

Después de las pruebas de clasificación, se filtraron los datos de la clase 4 de los datos originales con el objetivo de usar solamente la información necesaria de las clases restantes (las que sí se podían ajustar) en los modelos de RNA de regresión.

Se utilizó Talos de nueva cuenta para encontrar la mejor arquitectura para los modelos de RNA de regresión, mismos que fueron entrenados usando los datos filtrados. Finalmente, se utilizó el modelo de RNA de regresión con los datos reservados para pruebas para ajustar las mediciones de temperatura, salinidad y presión.

3. Resultados

La búsqueda de perfiles hidrográficos medidos realizada dentro del polígono y del espacio temporal establecidos se muestra en la Figura 2, la cual reveló que 12, 874 perfiles de temperatura, salinidad y presión han sido medidos y revisados por el control de calidad en modo diferido dentro del área de estudio.

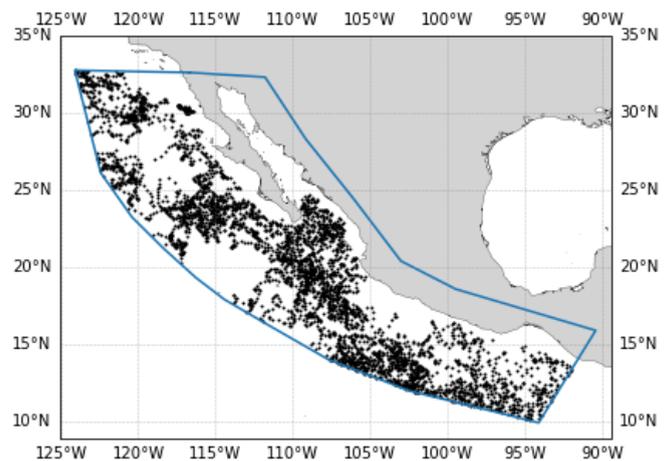


Figura 2: Polígono utilizado como área de estudio.

La Tabla 3 muestra las mejores arquitecturas de las RNA de clasificación que se encontraron.

	Binario		Multiclase	
	Capa oculta 1	Capa oculta 2	Capa oculta 1	Capa oculta 2
Temperatura	30	30	55	55
Salinidad	60	60	60	60
Presión	30	30	55	55

Estas arquitecturas fueron seleccionadas en base a los valores de exactitud binaria de validación obtenidos, en el caso de las RNA binarias, exactitud de validación para las RNA multiclase y error absoluto medio (MAE) para las RNA de regresión. Para los modelos binarios, se escogieron los que presentaron los valores más altos de exactitud binaria de validación y exactitud de validación respectivamente. Para los modelos de regresión, se eligió el que presentó el menor grado de MAE. Las pruebas realizadas con modelos de RNA con menos neuronas mostraron peores resultados.

Como se observa en la tabla, para todos los modelos de RNA de clasificación, dos capas ocultas fueron suficientes para obtener resultados favorables, y en el caso de la salinidad, una mayor cantidad de neuronas.

3.1. Pruebas de RNA de clasificación binaria

Los resultados de las pruebas de clasificación binaria se presentan en las Tablas 4, 5 y 6, las cuales demuestran que una gran cantidad de datos de la clase 1 de perfiles de temperatura, salinidad y presión fueron clasificados correctamente, con un porcentaje de verdaderos positivos de 91.7%, 84.76% y 95.23% respectivamente.

Tabla 4: Matriz de confusión de clasificación binaria de temperatura in-situ.

	1	2
1	6,646,753	601,531
2	1,215	264,460

Tabla 5: Matriz de confusión de clasificación binaria de salinidad práctica.

	1	2
1	5,824,970	1,046,806
2	4,109	637,888

Tabla 6: Matriz de confusión de clasificación binaria de presión.

	1	2
1	6,936,273	346,716
2	261	230,625

Contando con los reportes de clasificación de las Tablas 7, 8 y 9, destacando que los datos de la clase 1 tienen valores altos de precisión y exactitud, demostrando que la clase 1 pudo ser identificada de forma satisfactoria, y que posteriormente pueda ser filtrada correctamente.

Tabla 7: Reporte de clasificación binario de temperatura in-situ.

Clase	Precisión	Sensibilidad
1	1.00	0.92
2	0.31	1.00
Promedio macro	0.65	0.96
Promedio pesado	0.98	0.92
Exactitud	0.92	

Tabla 8: Reporte de clasificación binario de salinidad práctica.

Clase	Precisión	Sensibilidad
1	1.00	0.85
2	0.38	0.99
Promedio macro	0.69	0.92
Promedio pesado	0.95	0.86
Exactitud	0.86	

Tabla 9: Reporte de clasificación binario de presión.

Clase	Precisión	Sensibilidad
1	1.00	0.95
2	0.40	1.00
Promedio macro	0.70	0.98
Promedio pesado	0.98	0.95
Exactitud	0.95	

La Figura 4 ilustra la nueva proporción de las clases (con la clase 1 filtrada). Se puede observar que el conjunto de datos cuenta con un mejor balance general en todas las clases.

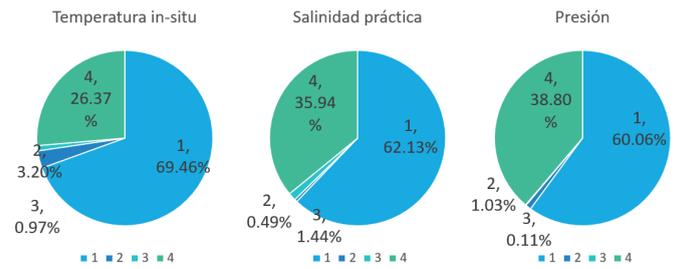


Figura 4: Clases de los perfiles hidrográficos balanceadas.

3.2. Pruebas de RNA de clasificación multiclase

Los resultados de las pruebas de clasificación multiclase se presentan en las Tablas 10, 11 y 12, mostrando en los tres casos que una gran parte de los datos clasificados se mantuvieron en la diagonal de las matrices, siendo los datos erróneamente clasificados menos que los correctamente clasificados. Las clases destinadas a ser ajustadas en la etapa de regresión fueron identificadas de forma satisfactoria.

Tabla 10: Matriz de confusión de clasificación multiclase de temperatura in-situ.

	1	2	3	4
1	531,330	7,166	16,020	47,015
2	140	27,652	3	0
3	69	2	8,342	24
4	11,389	9	1,247	215,582

Tabla 11: Matriz de confusión de clasificación multiclase de salinidad práctica.

	1	2	3	4
1	769,150	10,311	51,837	215,508
2	5	8,254	0	0
3	181	16	23,997	10
4	78,051	22	4,790	522,562

Tabla 12: Matriz de confusión de clasificación multiclase de presión.

	1	2	3	4
1	315,039	4,645	1,868	25,164
2	44	5,890	0	2
3	0	0	649	0
4	25,465	6	0	198,569

Contando con los reportes de clasificación de las Tablas 13, 14 y 15, destacando buenos niveles tanto de sensibilidad como de precisión, lo que demostró que modelos tuvieron un buen desempeño para clasificar las cuatro clases de acuerdo con su calidad.

Tabla 13: Reporte de clasificación multiclase de temperatura in-situ.

Clase	Precisión	Sensibilidad
1	0.98	0.88
2	0.79	0.99
3	0.33	0.99
4	0.82	0.94
Promedio macro	0.73	0.95
Promedio pesado	0.92	0.90
Exactitud	0.90	

Tabla 14: Reporte de clasificación multiclase de salinidad práctica.

Clase	Precisión	Sensibilidad
1	0.91	0.73
2	0.44	1.0
3	0.30	0.99
4	0.71	0.86
Promedio macro	0.59	0.90
Promedio pesado	0.82	0.79
Exactitud	0.79	

Tabla 15: Reporte de clasificación multiclase de presión.

Clase	Precisión	Sensibilidad
1	0.93	0.91
2	0.56	0.99
3	0.26	0.99
4	0.89	0.89
Promedio macro	0.66	0.95
Promedio pesado	0.91	0.90
Exactitud	0.90	

Con el propósito de ejemplificar la relevancia de los modelos de clasificación binaria, a continuación, se muestra el reporte de clasificación multiclase para la temperatura sin haber realizado una clasificación binaria previa (Tabla 16).

Tabla 16: Reporte de clasificación multiclase de temperatura (sin clasificación binaria previa).

Clase	Precisión	Sensibilidad
1	0.99	0.83
2	0.13	0.96
3	0.01	0.93
4	0.22	0.68
Promedio macro	0.31	0.85
Promedio pesado	0.96	0.82
Exactitud	0.82	

Se puede apreciar que las clases 2, 3 y 4 presentan una caída notoria en sus niveles de precisión con respecto a los presentados en la Tabla 13, lo que demuestra que realizar una clasificación binaria para filtrar la clase 1 ayuda a mejorar la precisión para clasificar las demás clases.

3.3. Modelos de RNA de regresión

Se utilizó de nueva cuenta Talos para encontrar las mejores arquitecturas de RNA de regresión, demostradas en la Tabla 17. Para las pruebas de Talos se utilizó el mismo rango de neuronas que en las RNA de clasificación (10 a 60 neuronas por capa y en incrementos de 5). Se destaca que la misma arquitectura funcionó para los tres modelos distintos.

Tabla 17: Arquitectura de RNA de regresión.

	Capa oculta 1	Capa oculta 2
Temperatura	30	30
Salinidad	30	30
Presión	30	30

Al igual que para las RNA de clasificación, solamente fueron necesarias dos capas ocultas, y esta vez la cantidad de

neuronas en cada capa oculta fue la misma para los tres modelos.

3.4. Pruebas de RNA de regresión

A continuación, en la Tabla 18 se muestran los resultados de las pruebas de estimación de los datos ajustados con respecto a los datos reales para el conjunto de datos de validación.

Tabla 18: Resultados de RNA de regresión con datos de prueba.

	R^2	RMS E	MAE	Error máximo
Temperatura	0.9999	0.000	0.0001	0.1211
Salinidad	0.9994	0.013	0.0096	0.1559
Presión	0.9999	0.129	0.0622	5.4696

Los tres modelos de RNA de regresión obtuvieron un valor de R^2 mayor a 0.99, demostrando que pudieron estimar con gran precisión los valores ajustados de los perfiles de temperatura, salinidad y presión.

La revisión de trabajos como el de Zhang, et al. (2023) y los propios resultados de clasificación y regresión obtenidos en este trabajo apuntan a una relación cuasi lineal entre las variables de entrada y salida. La métrica R^2 ayuda a establecer la relación lineal entre los valores esperados y los predichos por los modelos, siendo 1.0 el valor óptimo que indica la capacidad de predecir dicha variable sin cometer errores (Landa, 2021).

Además, se muestran las gráficas de correlación lineal contra datos de validación de las tres variables trabajadas en las Figuras 5, 6 y 7, siendo la gráfica correspondiente a la salinidad la que mostró más inestabilidad, pero que de igual manera contó con un alto rendimiento.

Al graficar los datos esperados respecto a los datos predichos, se observa que se forma una recta bien definida, la cual ayuda a interpretar la métrica de R^2 de forma visual.

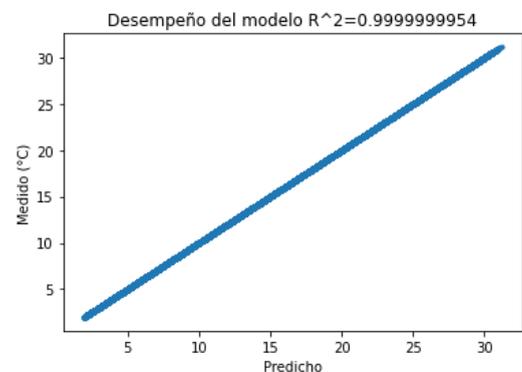


Figura 5: Correlación lineal entre los valores de temperatura predichos y los medidos.

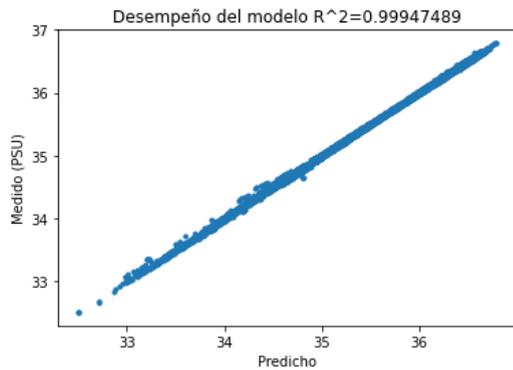


Figura 6: Correlación lineal entre los valores de salinidad predichos y los medidos.

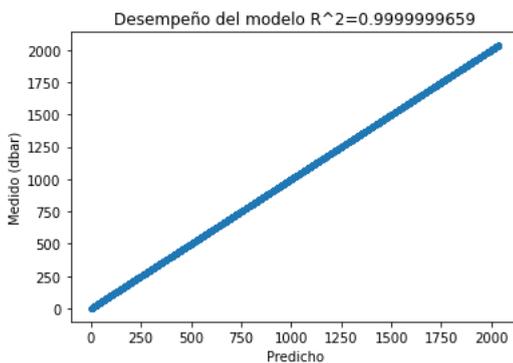


Figura 7: Correlación lineal entre los valores de presión predichos y los medidos.

Aunque los resultados de las pruebas de regresión con las RNA fueron satisfactorios, se probaron modelos de regresión lineal con datos de temperatura, salinidad y presión respectivamente, a modo de comparación con la RNA, dando un valor de R^2 similar al presentado por las RNA.

En la Tabla 19 se detallan los resultados de las pruebas de regresión lineal, con las métricas que se emplearon para evaluar los modelos de RNA de regresión.

Tabla 19: Resultados de regresión lineal con datos de temperatura, salinidad y presión.

	R^2	RMSE	MAE	Error máximo
Temperatura	0.9999	$2.91 \cdot 10^{-14}$	$2.87 \cdot 10^{-14}$	$4.61 \cdot 10^{-14}$
Salinidad	0.9981	0.0262	0.0156	0.2335
Presión	0.9999	0.1908	0.1426	2.4078

Con los resultados de los modelos de regresión lineal, se comprobó que es posible obtener valores similares de R^2 con un modelo más sencillo. Sin embargo, en el caso de las métricas RMSE, MAE y Error máximo, los valores varían dependiendo del tipo de datos que se esté trabajando. En el caso de la temperatura, estos presentan valores de error menores que los presentados por los modelos RNA, a diferencia de la salinidad y la presión, donde los niveles error son más elevados que los presentados por las RNA.

4. Conclusiones

Los resultados demostraron que los modelos de RNA obtenidos mediante la metodología propuesta, cuentan con un adecuado rendimiento para realizar la clasificación de datos de temperatura, salinidad y presión, de acuerdo a su nivel de calidad, presentando una precisión mayor a 0.9.

Por otra parte, observamos una gran precisión en los valores ajustados por el modelo de RNA de regresión, con un valor de R^2 superior a 0.99, así como niveles de error bajos de RMSE, MAE y Error máximo, por lo que se considera que la metodología es una alternativa viable cuando no se cuenta con datos procesados por el control de calidad en modo diferido.

Adicionalmente, es posible adaptar esta metodología de acuerdo a las necesidades de quien la utilice, ya sea para analizar variables diferentes, o para clasificar y ajustar datos de perfiles hidrográficos medidos dentro de un polígono y/o espacio temporal diferentes a los establecidos en este estudio. Lo anterior, siempre y cuando se cuente con la cantidad suficiente de perfiles hidrográficos medidos y revisados por el control de calidad en modo diferido para tener un buen conjunto de datos de entrenamiento.

5. Referencias

Argo. (2022). Argo user's manual. DOI: 10.13155/29825.

Landa, N. (2021). Métricas en regresión. Medium. <https://medium.com/@nicolasarriola/m%C3%A9tricas-en-regresi%C3%B3n-5e5d4259430b>

OceanOPS (2018). Argo: A window into the ocean. OceanOPS. <https://oceanops.maps.arcgis.com/apps/Cascade/index.html?appid=a170a0d522bb42f1a019e4e473cf1bdd>. Accessed: 2022-11-15.

Ono S., Matsuyama H., Fukui Ki., Hosoda S. (2015). A preliminary studio on quality control of oceanic observation data by machine learning methods. In Proceedings in Adaptation, Learning and Optimization (pp. 679-693). DOI: 10.1007/978-3-319-13359-1_52.

Pérez M. (2022). Modelo predictivo de series temporales de datos hidrográficos mediante aprendizaje automático [Tesis de maestría, Tecnológico Nacional de México campus La Paz]. Productos Académicos de la Maestría en Sistemas Computacionales <https://posgrado.lapaz.tecnm.mx/productos.php?id=1>

Roemmich, D., M.H. Alford, H. Claustre, K. Johnson, B. King, J. Moum, P. Oke, W.B. Owens, S. Pouliquen, S. Purkey, and others (2019). On the Future of Argo: A Global, Full-Depth, Multi-Disciplinary Array. *Frontiers in Marine Science* 6:439. DOI: 10.3389/fmars.2019.00439.

Romero E., Tenorio-Fernandez L., Castro I. & Castro M. (2021a). Filtering method based on cluster analysis to avoid salinity drifts and recover Argo data in less time. *Ocean Science*, 17(5), 1273-1284. DOI: 10.5194/os-17-1273-2021.

Romero E., Tenorio-Fernandez L., Castro I. & Castro M. (2021b). *romeroqe/cluster_qc: Filtering Methods based on cluster analysis for Argo Data*. DOI: 10.5281/ZENODO.4597899.

Sugiura N. & Hosoda S. (2020). Machine learning technique using the signature method for automated quality control of Argo profiles. *Earth and Space Science* (Hoboken, N.J.), 7(9). DOI: 10.1029/2019ea001019.

Wong, A.P.S., S.E. Wijffels, S.C. Riseer, S. Pouliquen, S. Hosoda, D. Roemmich, J. Gilson, G.C. Johnson, K. 427 Martini, D.J. Murphy, and others (2020). Argo Data 1999-2019: Two Million Temperature-Salinity Profiles and Subsurface Velocity Observations From a Global Array of Profiling Floats. *Frontiers in Marine Science* 7:700. DOI: 10.3389/fmars.2020.00700.

Zhang Q., Qian C. & Dong C. (2023). A machine learning approach to quality-control Argo temperature data. *Atmospheric and Oceanic Science Letters*, 16(4), 100292. DOI: 10.1016/j.aosl.2022.100292.