

## AVANCE DE INVESTIGACIÓN

# DISEÑO DE UNA RED NEURONAL CONVOLUCIONAL PARA EL PRONÓSTICO DEL ÍNDICE EL NIÑO 3.4

**Gerardo Rivera Tello<sup>1</sup> y Ken Takahashi<sup>1</sup>**

## RESUMEN

Los modelos neuronales convolucionales son capaces de aprender patrones complejos que los modelos dinámicos no son capaces de reproducir totalmente, en gran parte debido a la naturaleza no lineal de los eventos. El presente trabajo explora el modelo desarrollado por Ham et al. (2019, 2021), en donde, usando anomalías de temperatura superficial del mar y contenido de calor, se logra pronosticar el índice El Niño 3.4 con tiempos de antelación de hasta 14 meses. La modificación presentada no usa la técnica *transfer-learning*, por lo que los resultados de las correlaciones son menores que la del estudio citado. Sin embargo, se logra notar un potencial incremento en la habilidad de pronóstico para tiempos de antelación mayores al incluir la estacionalidad en la capa de entrada, lo que indicaría un mejor aprendizaje en la red.

**Palabras clave:** El Niño, ENSO, redes neuronales convolucionales, pronóstico de TSM

## AFILIACIÓN:

1. Instituto Geofísico del Perú, Lima, Perú.

Citar como Rivera, G., y Takahashi, K. (2022). Diseño de una red neuronal convolucional para el pronóstico del índice El Niño 3.4. *Boletín científico El Niño*, Instituto Geofísico del Perú, vol. 9 n.º 07, págs. 14-20.

## INTRODUCCIÓN

El diagnóstico y evolución de un evento El Niño está usualmente ligado a la observación de índices climáticos que permiten conocer de manera resumida el estado actual del sistema en cuestión. Uno de los índices ampliamente usados para conocer el estado del océano Pacífico ecuatorial es el índice Niño 3.4 (N34) (Rasmusson y Carpenter, 1982), el cual consiste en la media corrida de 3 meses de las anomalías mensuales de la temperatura superficial del mar (TSM) en la región que lleva el mismo nombre. Diversos estudios usan este índice para describir la evolución de eventos El Niño (Capotondi et al., 2015; Izumo et al., 2019; McPhaden, 2020). Es debido a esto que se busca pronosticar este índice con meses de antelación (L'Heureux et al., 2017), con la finalidad de alertar de manera oportuna ante la ocurrencia de un evento El Niño, el cual, como se sabe, genera impactos negativos en muchos países y, en especial, en el Perú. Para dicho fin, normalmente, se hacen uso de modelos dinámicos o estadísticos que buscan obtener un pronóstico con alta confiabilidad, pero que dificultan en reproducir características estacionales dentro de la misma dinámica, resultando usualmente en pronósticos no tan acertados en 6 meses a más. Recientemente se han explorado métodos de inteligencia artificial (Ham et al., 2019, 2021; Mamalakis et al., 2022; Ye et al., 2021) que aprovechan la gran cantidad de datos disponibles para aprender estructuras complejas —que los modelos dinámicos no pueden representar en su totalidad— y ofrecen muchas veces resultados más acertados que los modelos convencionales. Ham et al. (2019, 2021) desarrolló una red neuronal convolucional capaz de pronosticar el índice N34 con tiempos de hasta 13 meses de antelación. La red neuronal desarrollada por Ham et al. (2019) tomó como predictores los valores de 3 meses de las anomalías de la TSM y del contenido de calor dentro de los 300 m de profundidad para diseñar una red convolucional tradicional con una salida: N34 pronosticado. En el estudio de Ham et al. (2021) se continuó el desarrollo del modelo con la finalidad de incluir la estacionalidad en el proceso de aprendizaje, desarrollando una nueva red convolucional (H21 a partir de ahora) con dos salidas: N34 pronosticado y el mes de inicialización del modelo. El presente avance de investigación busca explorar un diseño similar a lo propuesto por ambos estudios, pero incorporando la estacionalidad como un predictor en la red neuronal, resultando en una red neuronal convolucional de arquitectura heterogénea con entrada mixta.

# DATOS Y METODOLOGÍA

## DATOS

Los datos de entrenamiento (*train*) y desarrollo (*dev*) están conformados por anomalías de TSM y contenido de calor (promedio de temperatura de los primeros 300 m de profundidad) del proyecto CMIP5 (Taylor et al., 2012), específicamente de 21 modelos que conforman las corridas históricas, para el periodo comprendido entre 1861 y 2001. Para el conjunto *dev*, que se usa para calcular la métrica durante el proceso de entrenamiento, se tomaron 2 miembros de las corridas del *ensemble* para 6 de los 21 modelos seleccionados, resultando en un total de 12 miembros usados exclusivamente como conjunto de desarrollo. Finalmente, los datos del conjunto de pruebas (*test*), que contienen las mismas variables, fueron obtenidos del *reanalysis* observacional GODAS (Behringer et al., 1998) para el periodo comprendido entre 1980 y 2017.

La cantidad total de muestras de *train* fue de 35 532, mientras que la cantidad de muestras de *dev* sumaron los 20 304. El conjunto de datos usado en este estudio es el mismo que fue usado en el modelo H21, el cual puede ser fácilmente descargado desde el repositorio adjunto en Ham et al. (2021).

Una muestra de *train* está comprendida por 3 valores de anomalías tanto de TSM como de contenido de calor. Estos 3 valores se definen por un mes inicial y los dos meses anteriores al mismo, es decir, si el mes de inicialización es marzo, los datos de anomalías de ambas variables para el mes de enero, febrero y marzo son provistos al modelo.

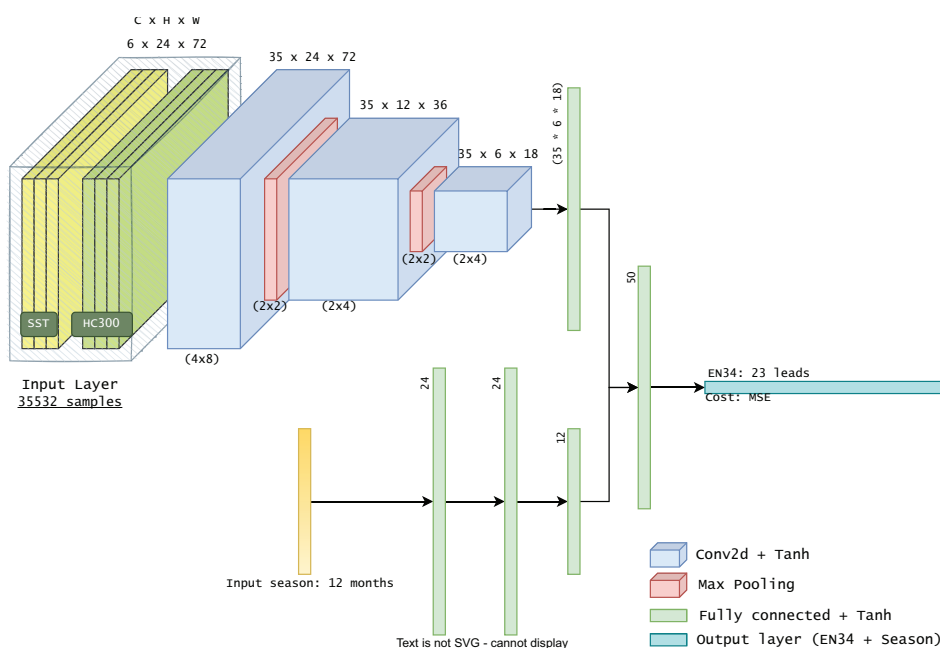


Figura 1. Arquitectura modificada del modelo desarrollado por Ham et al. (2021). Cada capa contiene información sobre las dimensiones de los datos de entrada en la parte superior, así como del tamaño de kernel en la parte inferior.

## ARQUITECTURA DEL MODELO

El modelo sigue una estructura convolucional similar a H21, el cual se compone de 3 capas convolucionales, 2 capas de *max-pooling*, y 2 capas totalmente conectadas (Figura 1). A diferencia de la red H21, en la que se tienen dos variables de salida (N34 pronosticado y el mes de inicialización), la red usada en este estudio contiene solo una variable de salida. Esta modificación se hizo con la finalidad de evaluar la inclusión explícita de la estacionalidad como una variable de entrada. Esta adición convierte a la red en una combinación de un modelo convolucional con una neurona *perceptrón* multicapa, los cuales se combinan luego de la primera capa totalmente conectada de la red convolucional, compartiendo de esta manera una capa final antes de obtener los 23 valores de salida en forma de regresión para la variable N34. La cantidad de canales convolucionales usada en el modelo es 35 (dos primeras capas) y 50 (última capa) con un *kernel* 2x2 y un *stride* igual a 1, lo cual mantiene a las dimensiones de los datos de entrada sin modificaciones. La reducción en la dimensionalidad viene por parte de las 2 capas de *max-pooling* con un *kernel* 2x2, reduciendo las dimensiones a la mitad en cada pasada. El *perceptrón* multicapa tiene dos capas escondidas de 24 neuronas con una capa de salida con 12 elementos, la cual es concatenada con la salida de la primera capa totalmente conectada de la red convolucional. La elección de la cantidad de neuronas para la rama del *perceptrón* multicapa no fue escogida siguiendo algún criterio en particular, dejando espacio a optimizaciones futuras mediante la técnica de optimización de hiperparámetros. Durante la etapa de aprendizaje, el modelo usa el algoritmo *Adam optimization* y un error cuadrático medio ponderado (RMSE) como función de costo (*loss*) para el problema de regresión. Las iteraciones de aprendizaje son controladas mediante *early-stopping* como método de regularización para evitar el sobreajuste con una "paciencia" de 200 épocas, o sea que evalúa las últimas 200 épocas de entrenamiento en busca de mejoras antes de detener el aprendizaje. Finalmente, el modelo fue configurado para entrenar durante 1000 épocas con un *batch size* de 400 y una tasa de aprendizaje de 0.005. La cantidad total de parámetros aprendibles es 219 810.

## ENTRENAMIENTO Y EVALUACIÓN DEL MODELO

El ajuste inicial de los parámetros del modelo se hizo sobre el conjunto de datos de *train*. Durante cada bucle de entrenamiento, se evalúa la métrica de regresión RMSE con el conjunto de datos *dev*. Según el valor de esta métrica MSE se detiene el aprendizaje mediante la técnica *early-stopping*, que consiste en mantener un registro de la métrica de aprendizaje de la época anterior y compararla con la época actual a fin de detener el aprendizaje si este último no indica mejoras del modelo. El método de *early-stopping* considera las métricas de las últimas 200 épocas de aprendizaje antes de detener la fase de entrenamiento.

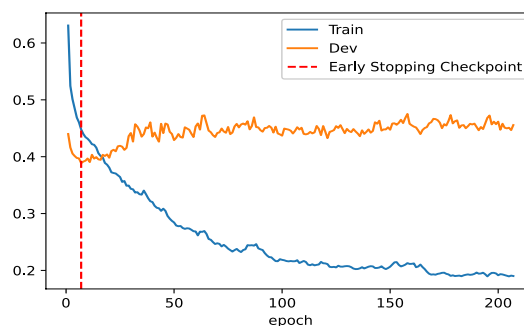


Figura 2. Métrica del modelo (RMSE) en función de las épocas de entrenamiento. La línea azul (naranja) representa la evolución de la función de costo sobre la base de datos de entrenamiento (desarrollo) con el paso de las épocas. La línea punteada roja indica la época en la cual la función de costo evaluada en los datos de desarrollo alcanzó su mínimo, sin mejoras en al menos 200 épocas consecutivas.

Posterior a la fase de entrenamiento, se realiza la evaluación de este con el conjunto de datos test independientes provenientes del *reanalysis* GODAS. El índice N34 pronosticado por el modelo se compara con el calculado a fin de obtener una métrica de rendimiento del modelo.

## RESULTADOS

La fase de entrenamiento del modelo con esta arquitectura tuvo su mejor iteración en la época número 10, sin mostrar mejoras en las siguientes 200 épocas (Figura 2). Esto puede indicar que los hiperparámetros usados para esta arquitectura no son los óptimos, por lo que se requiere aplicar métodos de optimización. Por otro lado, la salida del modelo modificado H21 se compara en forma de correlación con los datos calculados obtenidos por GODAS, el cual a su vez es comparado con 4 corridas del modelo original sin modificaciones. La correlación obtenida (Figura 3) con este modelo muestra un incremento en la habilidad del pronóstico con tiempo de anticipación crecientes, lo cual podría dar mejores resultados si se aplicara una técnica de transferencia de aprendizaje a otra red con datos de simulaciones que asimilen datos observados. Cabe resaltar que la red ha sido ajustada con datos de modelos climáticos, por lo que la evaluación con datos de *reanalysis* puede dar resultados inferiores a los que daría un conjunto de datos de prueba solamente conformado por modelos climáticos.

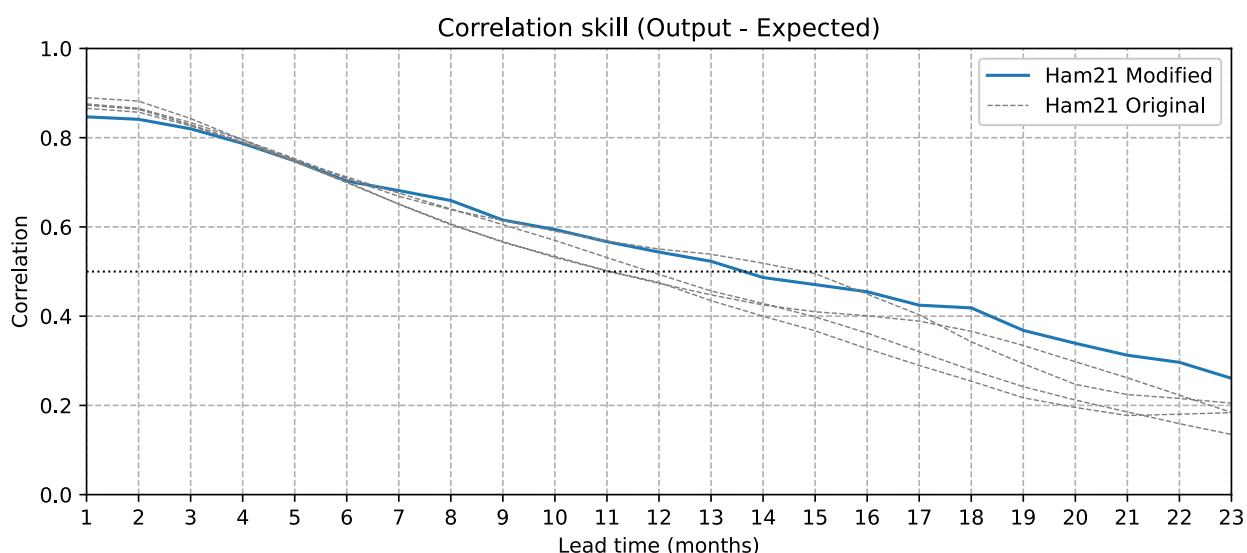


Figura 3. (Línea sólida) Correlación entre valores pronosticados por el modelo desarrollado en este estudio ("Ham 21 Modified") y valores esperados para la base de datos de pruebas GODAS. (Línea punteada) Correlación entre valores obtenidos con la implementación original del modelo H21. La línea punteada horizontal marca el valor 0.5 de correlación.

## COMENTARIOS

El modelo desarrollado mediante la modificación de la red neuronal H21 indica que la habilidad del modelo en el pronóstico del índice N34 puede incrementarse si se proporciona al modelo información de la estacionalidad como entrada en vez de forzar algún tipo de aprendizaje al tener dicha variable como salida. La facilidad con la que estos modelos pueden ser desarrollados permite una rápida iteración sobre diferentes arquitecturas, cada una especializada en detectar características específicas dentro del tema a investigar. Esta ventaja sobre los modelos dinámicos se debe principalmente a la cantidad de datos recolectados hasta la fecha, por lo que es de vital importancia reforzar los programas de observación que hacen posible este tipo de estudios. Finalmente, este trabajo se centró en explorar los posibles resultados obtenidos de modificar algunos parámetros en una red neuronal convolucional, mostrando que aún hay mejoras por realizar con bases de datos más recientes.

## REFERENCIAS

Behringer, D. W., Ji, M., y Leetmaa, A. (1998). An Improved Coupled Model for ENSO Prediction and Implications for Ocean Initialization. Part I: The Ocean Data Assimilation System. *Monthly Weather Review*, 126(4), 1013–1021. [https://doi.org/10.1175/1520-0493\(1998\)126<1013:AICMFE>2.0.CO;2](https://doi.org/10.1175/1520-0493(1998)126<1013:AICMFE>2.0.CO;2)

Capotondi, A., Wittenberg, A. T., Newman, M., Di Lorenzo, E., Yu, J.-Y., Braconnot, P., Cole, J., Dewitte, B., Giese, B., Guilyardi, E., Jin, F.-F., Karnauskas, K., Kirtman, B., Lee, T., Schneider, N., Xue, Y., y Yeh, S.-W. (2015). Understanding ENSO Diversity. *Bulletin of the American Meteorological Society*, 96(6), 921–938. <https://doi.org/10.1175/BAMS-D-13-00117.1>

Ham, Y.-G., Kim, J.-H., Kim, E.-S., y On, K.-W. (2021). Unified deep learning model for El Niño/Southern Oscillation forecasts by incorporating seasonality in climate data. *Science Bulletin*, 66(13), 1358–1366. <https://doi.org/10.1016/j.scib.2021.03.009>

Ham, Y.-G., Kim, J.-H., y Luo, J.-J. (2019). Deep learning for multi-year ENSO forecasts. *Nature*. <https://doi.org/10.1038/s41586-019-1559-7>

Izumo, T., Lengaigne, M., Vialard, J., Suresh, I., y Planton, Y. (2019). On the physical interpretation of the lead relation between Warm Water Volume and the El Niño Southern Oscillation. *Climate Dynamics*, 52(5–6), 2923–2942. <https://doi.org/10.1007/s00382-018-4313-1>

L'Heureux, M. L., Takahashi, K., Watkins, A. B., Barnston, A. G., Becker, E. J., Di Liberto, T. E., Gamble, F., Gottschalck, J., Halpert, M. S., Huang, B., Mosquera-Vásquez, K., y Wittenberg, A. T. (2017). Observing and Predicting the 2015/16 El Niño. *Bulletin of the American Meteorological Society*, 98(7), 1363–1382. <https://doi.org/10.1175/BAMS-D-16-0009>

Mamalakis, A., Barnes, E. A., y Ebert-Uphoff, I. (2022). Investigating the Fidelity of Explainable Artificial Intelligence Methods for Applications of Convolutional Neural Networks in Geoscience. *Artificial Intelligence for the Earth Systems*, 1(4), e220012. <https://doi.org/10.1175/AIES-D-22-0012.1>

McPhaden, M. J. (Ed.). (2020). *El Niño southern oscillation in a changing climate* (First edition). Wiley-American Geophysical Union.

Rasmusson, E. M., y Carpenter, T. H. (1982). Variations in Tropical Sea Surface Temperature and Surface Wind Fields Associated with the Southern Oscillation/El Niño. *Monthly Weather Review*, 110(5), 354–384. [https://doi.org/10.1175/1520-0493\(1982\)110<0354:VITSST>2.0.CO;2](https://doi.org/10.1175/1520-0493(1982)110<0354:VITSST>2.0.CO;2)

Taylor, K. E., Stouffer, R. J., y Meehl, G. A. (2012). An Overview of CMIP5 and the Experiment Design. *Bulletin of the American Meteorological Society*, 93(4), 485–498. <https://doi.org/10.1175/BAMS-D-11-00094.1>

Ye, M., Nie, J., Liu, A., Wang, Z., Huang, L., Tian, H., Song, D., y Wei, Z. (2021). Multi-Year ENSO Forecasts Using Parallel Convolutional Neural Networks With Heterogeneous Architecture. *Frontiers in Marine Science*, 8, 717184. <https://doi.org/10.3389/fmars.2021.717184>