

# EVALUACIÓN DE LA SENSIBILIDAD DEL MODELO IA IGP-UHM A LAS CONDICIONES INICIALES

José Obregón<sup>1</sup> y Ken Takahashi<sup>1</sup>

<sup>1</sup> Instituto Geofísico del Perú, Lima, Perú

**Palabras clave:** El Niño, inteligencia artificial, viento zonal, índice E, causalidad

Citar como Obregón, J., & Takahashi, K. (2024). Evaluación de la sensibilidad del modelo IA IGP-UHM a las condiciones iniciales. *Boletín científico El Niño*, Instituto Geofísico del Perú, vol. 11 n.º 12, págs. 13-18

## ¿Cuál es la **contribución** de esta investigación para tomadores de decisiones?\*

El surgimiento del uso de la inteligencia artificial fortalece los servicios basados en información, como los pronósticos climáticos. Sin embargo, esta investigación advierte sobre sus limitaciones, especialmente ante situaciones nuevas, y destaca la necesidad de expertos humanos en su desarrollo, evaluación y mejora, con base en el conocimiento físico de fenómenos como El Niño. Se recomienda que entidades como la Comisión ENFEN, así como los tomadores de decisiones, cuenten con el soporte de científicos expertos para aplicar adecuadamente la inteligencia artificial en la predicción climática.

## Resumen

El modelo de inteligencia artificial IA IGP-UHM predice El Niño usando información climática reciente, por lo que se esperaba que saque provecho de precursores identificados en investigaciones previas, como la alta probabilidad de ocurrencia de eventos El Niño fuerte según el índice E en enero, cuando la anomalía del esfuerzo de viento del oeste en el Pacífico ecuatorial central ( $\text{taux}_c$ ) excede, en agosto previo, un valor crítico (Takahashi & Dewitte, 2015). En este estudio se evalúa la sensibilidad del modelo IA IGP-UHM a algunos precursores seleccionados. Si bien los pronósticos del modelo para el periodo 1981-2023 reproducen aproximadamente la relación empírica entre  $\text{taux}_c$ , en agosto, y el índice E, en el enero siguiente, en experimentos aislados, tras neutralizar o incluso invertir artificialmente los valores de  $\text{taux}_c$  correspondientes a

junio-agosto de 1982, 1997 y 2015, las predicciones del modelo de los eventos El Niño de 1983, 1998 y 2016 presentaron muy poca sensibilidad, manteniendo una alta probabilidad de El Niño, a pesar de la gran importancia esperada de este precursor. Esto sugiere que el entrenamiento no le permitió establecer dicho precursor como una condición importante para El Niño. Más bien, se identificó que el predictor más relevante para el modelo IA es la anomalía de la temperatura superficial del mar (SST', por sus siglas en inglés) en el Pacífico oriental. Estos resultados preliminares sugieren que el modelo IA IGP-UHM no estaría capturando las relaciones físicas causales, las cuales sí están presentes en un modelo climático numérico basado en las leyes de la física, lo cual nos advierte de la necesidad de mantener una posición crítica de los modelos de inteligencia artificial, sobre todo en cuanto a su desempeño en situaciones climáticas novedosas.

## 1. Introducción

El Niño-Oscilación del Sur (ENOS) es un fenómeno climático de gran escala que tiene un impacto significativo en el clima global. La predicción precisa de El Niño es crucial para la toma de decisiones estratégicas en diversos sectores, como la agricultura, la gestión de recursos hídricos y la planificación ante desastres. Sin embargo, los modelos climáticos globales presentan limitaciones sustanciales en simular y predecir adecuadamente el clima en el Pacífico oriental. Para abordar esta problemática, el Instituto Geofísico del Perú (IGP) y la Universidad de Hawái en Manoa (UHM) han desarrollado un modelo de inteligencia artificial (IA) con un módulo de explicabilidad, basado en la propagación de relevancia por capas (LRP, por sus siglas en inglés; Bach et al., 2015), diseñado para la predicción de El Niño (Rivera-Tello et al., 2023). Este modelo de IA ofrece una herramienta complementaria a los productos de pronóstico tradicionales, con la ventaja de facilitar la identificación de las regiones potencialmente relevantes para la predicción del evento.

Un mecanismo clave en el ENOS es la acción de las anomalías del viento del oeste en el Pacífico ecuatorial, las cuales desempeñan un papel central en la retroalimentación de Bjerknes, capaz de amplificar el desarrollo de El Niño. La retroalimentación de Bjerknes se activa cuando los vientos alisios en el Pacífico occidental se debilitan, lo que provoca una reducción en el afloramiento ecuatorial y, en consecuencia, un mayor calentamiento de la superficie del mar en el Pacífico oriental, lo que fortalece el evento El Niño (Bjerknes, 1966; Bjerknes, 1969; Neelin, 1998; Cane, 1985; Capotondi et al., 2018). Por otro lado, los eventos extremos de El Niño, como los de 1983 y 1998, se caracterizaron por un calentamiento anormalmente intenso en el Pacífico oriental (Takahashi et al., 2011), cuyo desarrollo depende de la amplificación no lineal de la retroalimentación de Bjerknes asociada a la activación de la convección profunda atmosférica, cuando la temperatura superficial del mar en el Pacífico oriental alcanza un umbral lo suficientemente alto para sostenerla (Takahashi & Dewitte, 2015; Takahashi et al., 2018), mientras que fuertes vientos del este pueden suprimir un evento El Niño (por ejemplo, Chiodi y Harrison, 2017).

Según el análisis de observaciones y de un modelo climático, una condición determinante para la

ocurrencia de un evento extremo El Niño en enero sería que el valor de la anomalía del esfuerzo de viento del Pacífico ecuatorial central ( $\text{taux}_c$ ), en el agosto previo, supere un umbral crítico, lo que representaría la inversión de los vientos alisios del este (Takahashi & Dewitte, 2015). Si esta condición no se cumple, la probabilidad de un evento extremo El Niño debería reducirse significativamente, por lo que se esperaría que el modelo IA IGP-UHM refleje este comportamiento. En este estudio, se evalúa la sensibilidad de las predicciones del modelo a los valores de  $\text{taux}_c$  mediante experimentos en los que se manipulan los datos de entrada.

## 2. Metodología

En primer lugar, se reprodujeron los resultados de Takahashi y Dewitte (2015) utilizando datos observacionales para los tres predictores más importantes identificados: las anomalías del viento zonal en el Pacífico central ( $U'$ ), en lugar de  $\text{taux}_c$ ; la altura superficial del mar en el Pacífico ecuatorial ( $SSH'$ , por sus siglas en inglés), en reemplazo del contenido de calor oceánico; y el índice E, correspondientes al mes de agosto como predictor del índice E observado en enero del año siguiente. Para ello, se emplearon los datos mensuales observados de GODAS y Reanalysis II.

Dado que el modelo IA IGP-UHM considera como entrada los campos mensuales de vientos zonal ( $U$ ) y meridional ( $V$ ) en superficie, la temperatura superficial del mar ( $SST$ , por sus siglas en inglés) y el nivel del mar ( $SSH$ , por sus siglas en inglés) de los últimos tres meses (Rivera-Tello et al., 2023), se repitió este diagnóstico considerando los predictores de agosto correspondientes a las predicciones de E realizadas con datos de entrada de junio, julio y agosto hasta enero del año siguiente. Asimismo, se evaluó la relevancia de las variables de entrada del modelo IA IGP-UHM mediante el método LRP de explicabilidad de inteligencia artificial. Para obtener el LRP de los pronósticos de los eventos de El Niño fuerte, se utilizaron solo los miembros del *ensemble* que pronosticaron un índice E mayor a 1.5, y se calcularon los promedios sobre los años en los que más del 50 % de los *ensembles* pronosticaron dicha condición. Por otro lado, para el LRP de los eventos de El Niño no fuerte, se consideraron solo los miembros del *ensemble* que pronosticaron un índice

**Tabla 1.** Experimentos realizados.

n.º de experimento	Predicador evaluado	Descripción
1	Um'	U' para junio-agosto de 1982, 1997 y 2015 fue modificado en el Pacífico central (160° E-160° O, 5° S-5° N).
2	SSHm'	SSH' para junio-agosto de 1982, 1997 y 2015 fue modificado en el Pacífico ecuatorial (120° E-80° O, 5° S-5° N).
3	SSTm'	SST' sobre el patrón E fue modificado para junio-agosto de 1982, 1997 y 2015.
4	Um'	Igual que n.º 1, pero manteniendo la SST'm sobre el patrón E en cero.
5	SSTm'	SST' sobre todo el dominio fue modificado para junio-agosto de 1982, 1997 y 2015.
6	Um'	Igual que n.º 1, pero utilizando el dominio (150° E-130° O, 8° S-8° N).
7	Um'	Igual que n.º 4, pero utilizando el dominio (150° E-130° O, 8° S-8° N).
8	Um'	SST', SSH', U' y V' sobre todo el dominio fue modificado para junio-agosto de 1982, 1997 y 2015.

E menor o igual a 1.5, y se promediaron los años en los que más del 50 % de los *ensembles* predijeron esta condición para todos los agostos desde 1981 hasta 2023. Este análisis nos permite conocer el estado medio de la relevancia espacial en el modelo IA e identificar regiones clave para la activación o supresión de El Niño.


Para el análisis de sensibilidad, se adaptó la definición de los predictores de Takahashi y Dewitte (2015) con el fin de controlarlos mediante la modificación de las variables de entrada del modelo IA IGP-UHM (Tabla 1). Los primeros tres experimentos se diseñaron para evaluar la sensibilidad de los predictores U', SSH' y SST'. Tras observar una mayor relevancia de la SST para el modelo, se decidió realizar un cuarto experimento en el que se eliminó la señal de la SST' sobre el patrón E, es decir, se reemplazó su valor por cero en todo el dominio. Para analizar la sensibilidad de todo el campo de la SST', se modificó la totalidad del dominio (experimento n.º 5). En los dos últimos experimentos, se replicaron los experimentos n.º 1 y 4, pero considerando una región más extensa para la modificación de U'.

Las anomalías en las regiones que se describen para cada experimento de la Tabla 1 se intensificaron positiva y negativamente, multiplicándolas por un

coeficiente que variaba en cada corrida entre -3 y 3, con intervalos de 0.5. Sin embargo, para los experimentos 6 y 7, los valores originales fueron reemplazados por una constante espacial sobre el dominio de interés, la cual cambiaba de valor en cada corrida entre -6 y 6, con intervalos de 1. En todos los experimentos, se consideraron los 30 miembros del *ensemble* del modelo IA.

### 3. Resultados

Los datos observados de GODAS y Reanalysis II permitieron reproducir la relación entre el viento del Pacífico central en agosto y el índice E en enero del año siguiente (Figura 1a), según Takahashi y Dewitte (2015). Dado que estas fuentes de datos fueron utilizadas para el ajuste fino (*fine tuning*) del modelo IA IGP-UHM, se espera que este pueda reproducir la misma sensibilidad en sus pronósticos. La Figura 1d permite verificar dicha relación, incluso considerando los pronósticos realizados con datos independientes (*test*) que no estuvieron disponibles para el modelo durante su desarrollo. De manera similar, en las Figuras 1b, 1c, 1e y 1f se verifican relaciones similares a las encontradas por Takahashi y Dewitte (2015), usando el contenido de calor oceánico ecuatorial y el índice E como predictores.




**Figura 1.** Índice E para el siguiente enero observado (a, b y c) y pronosticado por el modelo de IA (d, e y f) versus las anomalías de esfuerzo de viento zonal, altura superficial del mar e índice E de agosto. La línea horizontal punteada indica el umbral de 1.8. Los puntos azules (rojos) indican los años utilizados para el *fine-tuning* (evaluación independiente o test) del modelo de IA.

El estado medio de agosto de la relevancia LRP para los eventos de El Niño fuerte se muestra en la Figura 2. Los contornos azules, con valores de relevancia de  $-3$ , indican regiones relevantes desfavorables para predecir un evento El Niño fuerte en el siguiente enero, mientras que los contornos rojos, con valores de  $6$ , indican regiones relevantes favorables para predecirlo. Los campos sombreados en azul/rojo representan anomalías negativas/positivas estandarizadas para cada predictor. Se observa claramente que las anomalías relevantes en los océanos fuera del Pacífico, así como en el Pacífico noroeste, no contribuyen a la predicción de El Niño, mientras que las observadas en el océano Pacífico ecuatorial sí lo hacen.

El efecto negativo de las anomalías negativas de temperatura superficial en el Pacífico noroeste (al norte de  $40^\circ$  N) sobre la predicción de El Niño fuerte posiblemente esté asociado al *seasonal footprinting mechanism* (SPM) propuesto por Vimont et al. (2003). Según este mecanismo, un patrón de anomalías de

temperatura superficial del mar en el Pacífico norte, establecido por variabilidad atmosférica a través de flujos de calor superficiales en invierno, evolucionaría hacia la región ecuatorial en los siguientes meses, favoreciendo la ocurrencia de El Niño. Sin embargo, dicho patrón se caracteriza por presentar anomalías positivas al norte de  $40^\circ$  N (ver Figura 4a en Vimont et al., 2003), mientras que el promedio de las condiciones que resultaron en un pronóstico de El Niño fuerte en el modelo de IA muestra anomalías negativas. En otras palabras, si bien el patrón de SPM es favorable a El Niño, este no se observó en los casos en los que el modelo pronosticó un evento fuerte; por lo tanto, las anomalías observadas serían consideradas desfavorables para dicho pronóstico.

En cuanto a la relevancia LRP de la SST', se observa que el calentamiento en la región del Pacífico oriental y el litoral peruano es considerado favorable para predecir El Niño (Figura 2b) como La Niña (no mostrado), lo que sugiere que es una región sensible

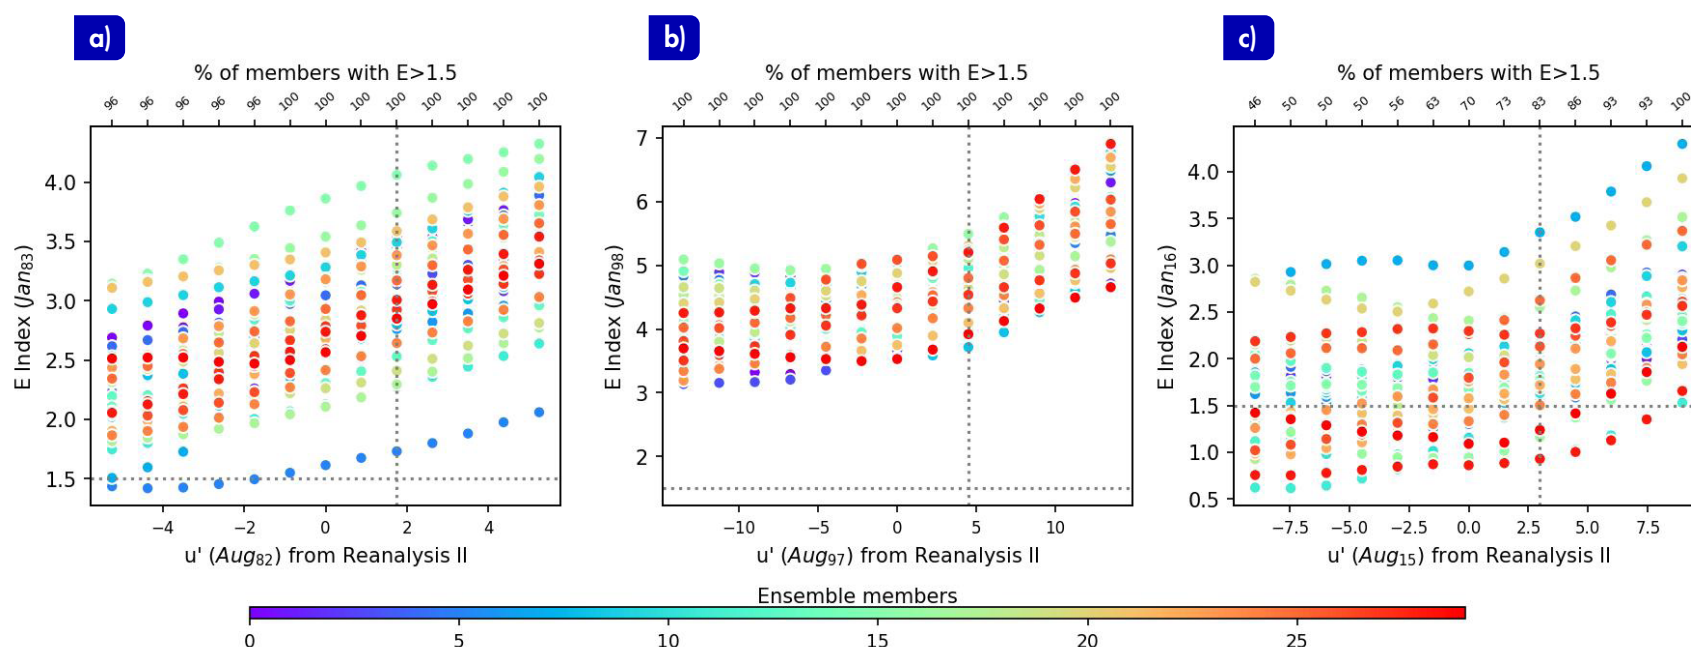


**Figura 2.** Anomalías y relevancia de LRP promedio (periodo 1981 - 2023) para los predictores de agosto que pronosticaron El Niño fuerte ( $E > 1.5$ ) correspondientes a temperatura (a) y altura (b) superficial del mar, viento zonal (c) y meridional (d). Sombreado azul (rojo) indica anomalías negativas (positivas). Los contornos azules punteados (rojos sólidos) indican regiones relevantes según LRP para reducir (incrementar) la predicción de probabilidad de El Niño fuerte en el siguiente enero.

y gatilladora para el modelo de IA (contornos de relevancia con un valor de 6). Para el caso del  $U'$ , se verifica la sensibilidad esperada en el Pacífico occidental ecuatorial; sin embargo, las anomalías negativas no son consideradas desfavorables para predecir El Niño fuerte. No obstante, en la relevancia LRP para los eventos de La Niña (no mostrado), las anomalías de viento zonal del este en el Pacífico ecuatorial occidental no se consideran desfavorables para El Niño, es decir, no presentan relevancia LRP negativa, como se esperaría físicamente. Teniendo

esto en cuenta, se puso a prueba esta hipótesis en los experimentos 1, 3 y 8, los cuales se describen a continuación.

En el experimento n.º 1, se evaluó cómo la anomalía de viento zonal en el Pacífico central, durante junio-agosto, influye en la sensibilidad del pronóstico del índice E en enero en el modelo de IA. En la Figura 3, la línea punteada vertical indica los valores observados del viento zonal en la realidad. Se observa que la intensificación artificial del viento del



**Figura 3.** Diagramas de dispersión para el experimento n.º 1 entre las anomalías estandarizadas del viento zonal del Pacífico central, modificadas para agosto de 1982 (a), 1997 (b) y 2015 (c), como predictores, y la predicción de E para enero siguiente. El eje x superior indica el porcentaje de miembros que pronosticaron  $E > 1.5$ . Cada color representa un miembro del *ensemble*. La línea vertical punteada indica el valor original del predictor. La línea horizontal indica el valor  $E = 1.5$ .

este en el Pacífico occidental (anomalías negativas), si bien reduce ligeramente la magnitud del índice E pronosticado, no logra neutralizar los pronósticos de El Niño de 1983, 1998 y 2016. Es más, en los casos de 1983 y 1998, el modelo persiste en pronosticar El Niño fuerte ( $E > 1.5$ ), incluso con anomalías de viento negativas con más del doble de intensidad que las positivas observadas. Ampliar la región en la que se modificó  $U'$  no incrementó la sensibilidad (experimento 6, no mostrado).


En el experimento n.º 2, se evaluó la sensibilidad de los pronósticos al nivel del mar (*proxy* para el contenido de calor) en el Pacífico ecuatorial inicial en el modelo de IA. Al igual que en el experimento n.º 1, se observa que un menor contenido de calor en el Pacífico ecuatorial disminuye ligeramente la magnitud del índice E, pero tampoco logra neutralizar los pronósticos de los eventos de El Niño de 1983, 1998 y 2016 (no mostrado). Es decir, que el contenido de calor del Pacífico ecuatorial tampoco es un predictor dominante de E en el modelo de IA. También se hizo un experimento (no mostrado) donde tanto la  $U'$  como la  $SSH'$  fueron reducidas simultáneamente; sin embargo, la modificación de ambos predictores tampoco contribuyó significativamente a la neutralización de los pronósticos de los eventos El Niño evaluados.

En el experimento n.º 3 se evaluó la sensibilidad del pronóstico de E a la temperatura superficial del mar inicial en la región principal del patrón E. Se observó una sensibilidad de alrededor de 1:1 entre

los valores iniciales del índice E, en junio-agosto, y los pronosticados en enero siguiente, aunque esta relación se saturó para valores negativos (Figura 4). Esto indica que la temperatura superficial del mar en el Pacífico oriental es el predictor dominante para el modelo de IA entre los tres evaluados.

Para evaluar si la sensibilidad a los otros predictores sería mayor en ausencia del fuerte calentamiento preexistente en el Pacífico oriental, en el experimento n.º 4 se reemplazó la  $SST'$  inicial sobre el patrón E con el valor de cero y se volvió a evaluar la sensibilidad del pronóstico al viento del Pacífico occidental. En general, los valores de E pronosticados se redujeron, por lo que en los casos con las mayores anomalías negativas de viento zonal se logra neutralizar El Niño de 2016, mas se mantiene el pronóstico de El Niño en 1983 y 1998 (no mostrado). Incrementar la región en la que se modificó  $U'$  permitió neutralizar parcialmente los pronósticos de los eventos El Niño para los casos en los que las anomalías del viento del este tuvieron magnitudes menores de  $-2$ ; sin embargo, no fue del todo claro (experimento 6 y 7, no mostrados). Aparentemente, la sensibilidad del pronóstico a  $U'$  no es sustancialmente distinta al modificar  $SST'$ , es decir, que los efectos de ambos predictores se estarían combinando de forma aproximadamente lineal en el pronóstico.

En el quinto experimento se modificó el predictor  $SST'$  en todo el dominio, no solo en el Pacífico oriental (no mostrado). A diferencia del experimento n.º 3



**Figura 4.** Igual que la Figura 3, pero para el experimento n.º 3, modificando la temperatura superficial del mar en la región de E ( $SST'$ ) como predictor.

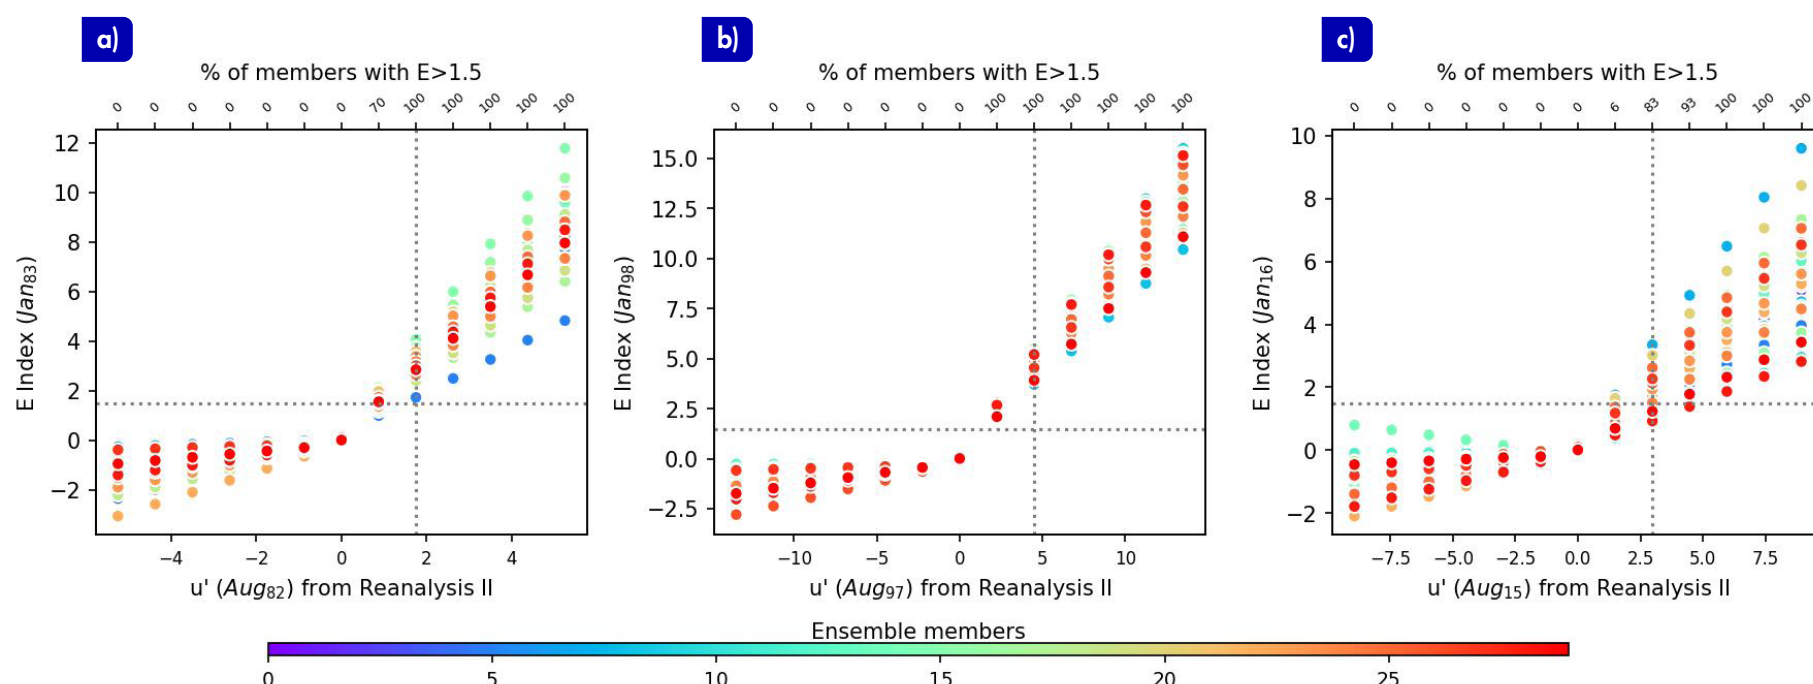


Figura 5. Igual que la Figura 3, pero para el experimento n.º 8, modificando la SST, SSH, U y V en todo el dominio.

(Figura 4), donde los valores negativos pronosticados eran cercanos a cero, en este experimento se logró convertir los pronósticos de los tres eventos El Niño en pronósticos de La Niña. Esto indica que, si bien el Pacífico oriental es la región de mayor relevancia en cuanto a SST', el modelo de IA considera más relevantes los patrones del dominio completo.

En el experimento n.º 8 (Figura 5), se modificaron simultáneamente todos los predictores (SST, SSH, U y V), multiplicándolos por el mismo coeficiente en todo el dominio. Se evidenció una sensibilidad mucho mayor a los patrones con coeficiente positivo, los cuales producen valores positivos de E, en comparación con los de coeficiente negativo, que generan pronósticos negativos de E. En ese sentido, la respuesta del modelo se asemeja a la función de activación "leaky RELU", con el punto de quiebre en cero. En este experimento se observa la variación no lineal del índice E cuando la señal de los predictores del modelo se amplifica positiva y negativamente en agosto.

## 4. Conclusiones

Este estudio evalúa la capacidad del modelo IA IGP-UHM para reproducir la sensibilidad de sus pronósticos a aquellos aspectos de las condiciones iniciales que son considerados precursores clave y que son identificados a partir de la investigación científica de los mecanismos físicos de ENOS. Para ello, se expuso el modelo a situaciones artificiales en las condiciones iniciales, cuyo efecto en el pronóstico es

fácilmente anticipado cualitativamente sobre la base del conocimiento de la física de ENOS. Sin embargo, los resultados sugieren que dicho conocimiento no habría sido inferido solo a partir de la identificación de patrones con los datos con los que se entrenó al modelo.

Si bien los datos de los predictores y pronósticos del modelo de IA para el periodo 1981-2023 reproducen, en general, la fuerte relación no lineal entre el viento zonal en el Pacífico ecuatorial central (índice  $U'$ ) de agosto y el índice E en enero —lo que sugiere una alta probabilidad de un evento de El Niño fuerte cuando  $U'$  es positivo y supera un valor umbral, en concordancia con Takahashi y Dewitte (2015)— los experimentos en los que se modificaron artificialmente los predictores en junio-agosto de 1982, 1997 y 2015 mostraron una baja sensibilidad del valor de E pronosticado a valores ampliamente distintos de  $U'$ . En particular, ante los valores fuertemente negativos de  $U'$  impuestos al modelo, era de esperarse pronósticos de condiciones neutras o frías ( $E \leq 0$ ). No obstante, el modelo mantuvo el pronóstico de un evento de El Niño fuerte ( $E > 1.5$ ) en el verano, lo que implica que no identificó la relevancia física de dicho predictor. Del mismo modo, el modelo tampoco asignó mayor relevancia al contenido de calor oceánico ecuatorial, otro predictor clave que sustenta el modelo carga-descarga de ENOS.

En contraste, la temperatura superficial del mar (SST') en el Pacífico oriental (región núcleo del patrón E) en junio-agosto emergió como el predictor más

relevante para el pronóstico de E en enero siguiente para el modelo IA. Desde un punto de vista físico, la temperatura superficial por sí sola no refleja memoria en el sistema climático, ya que se puede modificar rápidamente, a diferencia del contenido de calor, que cambia lentamente, o los vientos zonales ecuatoriales, que generan ondas Kelvin que evolucionan en escala de meses y, por lo tanto, tienen un efecto retardado.

Los resultados ilustrarían una limitación fundamental de los modelos de *machine learning*, los cuales no son capaces de identificar relaciones de causalidad, solo de correlación o asociación. En contraste, los humanos logran hacerlo a través del entendimiento teórico/conceptual de los fenómenos, así como del proceso inductivo, que consiste en generalizar a partir de lo particular. Este estudio plantea inquietudes sobre la capacidad de los modelos de IA para realizar predicciones correctas cuando se enfrentan a situaciones novedosas, en las que las relaciones correlacionales pueden fallar. En estos casos, es fundamental que los modelos se basen en relaciones causales, que sí mantienen su validez. Esto subraya la importancia de mantener una perspectiva crítica sobre el desempeño de los modelos de IA en la predicción climática, así como la necesidad de encontrar formas de incorporar el conocimiento experto en su desarrollo.

## Referencias

- Bach, S., Binder, A., Montavon, G., Klauschen, F., Müller, K.-R., & Samek, W. (2015). On Pixel-Wise Explanations for Non-Linear Classifier Decisions by Layer-Wise Relevance Propagation. *PLOS ONE*, 10(7), e0130140. <https://doi.org/10.1371/journal.pone.0130140>
- Bjerknes, J. (1966). A possible response of the atmospheric Hadley circulation to equatorial anomalies of ocean temperature. *Tellus*, 18(4), 820–829. <https://doi.org/10.1111/j.2153-3490.1966.tb00303.x>
- Bjerknes, J. (1969). Atmospheric Teleconnections from the Equatorial Pacific. *Monthly Weather Review*, 97(3), 163–172. [https://doi.org/10.1175/1520-0493\(1969\)097<0163:ATFT EP>2.3.CO;2](https://doi.org/10.1175/1520-0493(1969)097<0163:ATFT EP>2.3.CO;2)
- Cane, M. A., & Zebiak, S. E. (1985). A Theory for El Niño and the Southern Oscillation. *Science*, 228(4703), 1085–1087. <https://doi.org/10.1126/science.228.4703.1085>
- Chiodi, A. M. & Harrison, D. E. (2017). Observed El Niño SSTA Development and the Effects of Easterly and Westerly Wind Events in 2014/15. *Journal of Climate*, 1505–1519. <https://doi.org/10.1175/JCLI-D-16-0385.1>
- Fang, X., Dijkstra, H., Wieners, C., & Guardamagna, F. (2024). An overlooked aspect concerning the effect of the spatial pattern of zonal wind stress anomalies on El Niño evolution and diversity. *Climate Dynamics*, 62(8), 7037–7047. <https://doi.org/10.1007/s00382-024-07264-5>
- Neelin, J. D., Battisti, D. S., Hirst, A. C., Jin, F.-F., Wakata, Y., Yamagata, T., & Zebiak, S. E. (1998). ENSO theory. *Journal of Geophysical Research: Oceans*, 103(C7), 14261–14290. <https://doi.org/10.1029/97JC03424>
- Rivera Tello, G. A., Takahashi, K., & Karamperidou, C. (2023). Explained predictions of strong eastern Pacific El Niño events using deep learning. *Scientific Reports*, 13(1). <https://doi.org/10.1038/s41598-023-45739-3>
- Takahashi, K., Montecinos, A., Goubanova, K., & Dewitte, B. (2011). ENSO regimes: Reinterpreting the canonical and Modoki El Niño. *Geophysical Research Letters*, 38(10). <https://doi.org/10.1029/2011GL047364>
- Takahashi, K., & Dewitte, B. (2015). Strong and moderate nonlinear El Niño regimes. *Climate Dynamics*, 46(5–6), 1627–1645. <https://doi.org/10.1007/s00382-015-2665-3>
- Takahashi, K., Karamperidou, C., & Dewitte, B. (2018). A Theoretical Model of Strong and Moderate El Niño Regimes. *Climate Dynamics*, 52, 12, 7477–7493. <https://doi.org/10.1007/s00382-018-4100-z>
- Vimont, D. J., Wallace, J. M., & Battisti, D. S. (2003). The Seasonal Footprinting Mechanism in the Pacific: Implications for ENSO. *Journal of Climate*, 16(16), 2668–75. [https://doi.org/10.1175/1520-0442\(2003\)016<2668:TSMIT>2.0.CO;2](https://doi.org/10.1175/1520-0442(2003)016<2668:TSMIT>2.0.CO;2)
- Wang, Y.-L., Jin, F.-F., Wu, C.-R., & Qiu, B. (2024). Northwestern Pacific Oceanic circulation shaped by ENSO. *Scientific Reports*, 14(1). <https://doi.org/10.1038/s41598-024-62361-z>