

AVANCES CIENTÍFICOS

DESCUBRIMIENTO E INFERENCIA CAUSAL PARA LA PREDICCIÓN DE EL NIÑO

José Obregón Yataco¹ y Ken Takahashi¹

¹ Instituto Geofísico del Perú (IGP), Perú

Palabras clave: El Niño, Inteligencia artificial, viento zonal, Índice E, causalidad

Citar como Obregón, J., & Takahashi, K. (2025). Descubrimiento e inferencia causal para la predicción de El Niño. Boletín científico El Niño, Instituto Geofísico del Perú, vol. 12 n.º 07, págs. 15-21.

¿Cuál es la contribución de esta investigación para los tomadores de decisiones?

Ante la urgencia de pronosticar El Niño con antelación y anticiparse a los impactos, esta investigación evalúa la capacidad de un modelo de inteligencia artificial para analizar cómo los precursores climáticos influyen en la temperatura del océano Pacífico oriental. El estudio indica que, si bien el modelo reconoce patrones relevantes, presenta dificultades bajo ciertas condiciones, lo cual indica que situaciones futuras inusuales podrían ser un desafío para este, por lo que es necesario continuar con la investigación para su mejora. Si bien la inteligencia artificial ofrece grandes oportunidades, en el caso de problemas complejos como El Niño es necesario contar con conocimiento humano experto para fortalecer la gestión del riesgo ante eventos climáticos adversos.

Resumen

En un análisis previo se evaluó la sensibilidad de los pronósticos de El Niño mediante el modelo de inteligencia artificial IGP-UHM a la condición inicial. En este estudio, se exploran las posibles relaciones de causalidad representadas por dicho modelo entre los precursores de agosto, identificados en investigaciones previas, y el índice E en el siguiente enero, utilizando la técnica de descubrimiento causal Peter and Clark Momentary Conditional Independence (PCMCI). Se consideró el período 1981-2024 y, para evaluar la robustez de las relaciones, se perturbaron las condiciones iniciales, invirtiendo los valores de los precursores en agosto de 1982, 1997 y 2015, y reemplazando los resultados para enero de 1983, 1998 y 2016 obtenidos por el modelo. El método de PCMCI se aplicó a 8 000 muestras de remuestreo con el fin de obtener un único grafo causal para los datos observados, la corrida control y los experimentos, junto con una estimación de la incertidumbre en cada caso. Asimismo, se calculó la métrica F1 para evaluar la similitud entre los grafos causales.

Los resultados preliminares muestran que usando los datos de re-pronóstico del modelo de IA se reproduce una red causal razonable, por ejemplo, el viento del oeste en el Pacífico central en agosto como un predictor relevante para el calentamiento en enero. Sin embargo, usando re-pronósticos con condiciones iniciales perturbadas (p. ej., vientos zonales invertidos del Pacífico ecuatorial central en agosto de 1982, 1997 y 2015), se obtuvo como resultado una red causal marcadamente distinta en la que el viento del oeste dejó de ser un predictor relevante. En conjunto, estos hallazgos sugieren que el modelo IGP-UHM de IA podría no capturar de manera adecuada las relaciones físicas causales, las cuales tienden a estar explícitamente representadas en un modelo climático numérico. Esto resalta la necesidad de mantener una posición crítica frente al uso de los modelos de IA, en particular respecto a su desempeño en situaciones novedosas. Además, la técnica de descubrimiento causal PCMCI es sensible a qué conjunto de datos son usados, aún cuando son todos generados por el mismo modelo.

1. Introducción

El Niño-Oscilación del Sur (ENOS) es un fenómeno climático de gran escala que impacta significativamente en el clima global. Una predicción más precisa de El Niño resulta fundamental para la toma de decisiones estratégicas en diversos sectores como la agricultura, la gestión de recursos hídricos y la gestión del riesgo de desastres. Sin embargo, los modelos climáticos globales tienden a presentar limitaciones sustanciales en simular y predecir adecuadamente el clima en el Pacífico oriental y esta situación ha mejorado muy lentamente. Esto motiva la búsqueda de enfoques alternativos que complementen los sistemas de predicción existentes. En este contexto, el Instituto Geofísico del Perú (IGP) y la Universidad de Hawái en Manoa (UHM) desarrollaron 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 se plantea como una herramienta complementaria a los productos de pronóstico tradicionales, ya que permite identificar regiones potencialmente relevantes para la predicción de cada evento. Sin embargo, no resulta evidente si los modelos de IA representan adecuadamente las relaciones de causa y efecto que emergen de los mecanismos físicos, aspecto crucial para garantizar un desempeño confiable, sobre todo en situaciones novedosas.

Un mecanismo clave en ENOS es la retroalimentación de Bjerknes, vinculada a anomalías del viento del oeste en el Pacífico ecuatorial, que pueden amplificar el desarrollo de El Niño. Esta retroalimentación se activa cuando los vientos alisios en el Pacífico occidental se debilitan, reduciendo el afloramiento ecuatorial y, en consecuencia, un mayor calentamiento de la superficie del mar en el Pacífico oriental, fortaleciendo el evento El Niño (Bjerknes, 1966; Bjerknes, 1969; Neelin, 1998; Cane, 1985; Capotondi et al., 2018). En particular, los eventos extremos de El Niño, como los de 1983 y 1998, se caracterizaron por un calentamiento inusualmente intenso en el Pacífico oriental (Takahashi et al., 2011). Su desarrollo ha sido asociado con la amplificación no lineal de la retroalimentación de Bjerknes y la activación de la convección profunda atmosférica al alcanzar un umbral crítico de la temperatura superficial del mar en el Pacífico oriental (Takahashi & Dewitte, 2015; Takahashi et al., 2018). En contraste, fuertes vientos del este pueden inhibir la evolución de

un evento El Niño (Chiodi & 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 en el Pacífico ecuatorial central (\bar{u}), en el mes de agosto del año anterior, 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 ocurrencia de un evento extremo El Niño posiblemente se reduzca de manera significativa. Por consiguiente, cabría esperar que las predicciones del modelo IA IGP-UHM reflejen sensibilidad a este precursor. En este estudio, se evalúa empíricamente las posibles relaciones de causalidad del modelo IA IGP-UHM entre precursores seleccionados en agosto (Takahashi & Dewitte, 2015) y el índice E en el siguiente enero utilizando la técnica PCMCI (Runge et al., 2015).

2. Metodología

Se utilizaron datos mensuales observacionales de GODAS y Reanalysis II, a partir de los cuales se obtuvieron el índice C y E, la inclinación de la termoclina en el Pacífico ecuatorial (tilt, por sus siglas en inglés; calculada mediante la regresión lineal de la altura superficial del mar entre $120^{\circ}\text{E} - 80^{\circ}\text{W}$ y $5^{\circ}\text{S} - 5^{\circ}\text{N}$), el contenido de calor (HC, por sus siglas en inglés; calculado a partir de la profundidad de la termoclina en el Pacífico ecuatorial entre $120^{\circ}\text{E} - 80^{\circ}\text{W}$ y $5^{\circ}\text{S} - 5^{\circ}\text{N}$), y el esfuerzo zonal del viento (\bar{u}) en el Pacífico central ($155^{\circ}\text{E} - 160^{\circ}\text{W}$ y $5^{\circ}\text{S} - 5^{\circ}\text{N}$) y oriental (\bar{u} ; $160^{\circ}\text{W} - 130^{\circ}\text{W}$ y $5^{\circ}\text{S} - 5^{\circ}\text{N}$). También se emplearon datos generados por el modelo IA de enero correspondientes al índice E para el periodo 1981–2024.

En primer lugar, se aplicó el algoritmo de descubrimiento causal PCMCI (Runge et al., 2015) a las series de tiempo de los índices derivados de datos observacionales. Dado que el descubrimiento causal de series temporales es sensible a dependencias temporales, fue esencial conservar dichas dependencias en el procedimiento de remuestreo. El remuestreo estándar tiende a destruirlas, al menos parcialmente; por ello, se implementó la estrategia de remuestreo de Debeire et al. (2023). Con este procedimiento, aplicamos el método PCMCI a 8 000 muestras de remuestreo con el fin de obtener un grafo causal único para los datos observados, las salidas de los pronósticos existentes del modelo IA ("corrida

control”) y los experimentos, junto con su respectiva estimación de incertidumbre. Posteriormente, se calculó la métrica F1 (Nowack et al., 2020) para cuantificar la similitud entre el grafo causal del modelo IA de la corrida control y el grafo observacional, así como entre el grafo causal de los experimentos y el de la corrida control del modelo.

Para el análisis de sensibilidad, se adaptó la definición de los predictores propuesta por Takahashi & Dewitte (2015), con el fin de controlarlos mediante la modificación de los campos espaciales de las variables de entrada del modelo IA IGP-UHM de junio-agosto de 1982, 1997 y 2015 (Tabla 1) y

reemplazando tanto los precursores como las predicciones en las series originales antes de aplicar el PCMCI. Los primeros cuatro experimentos se diseñaron para evaluar la sensibilidad de los pronósticos a los predictores U' (anomalía de viento zonal), SSH' (anomalía de altura superficial del mar) y SST' (anomalía de temperatura superficial del mar). Dado que los resultados iniciales indicaron que la SST tiene alta relevancia para el modelo, se optó por realizar un quinto experimento en el que se eliminó la señal de la SST' sobre el patrón E en junio-agosto, es decir, se reemplazó su valor por cero en la región núcleo del patrón E. En todos los experimentos, se consideraron los 30 miembros del ensemble del modelo IA.

Tabla 1. Experimentos realizados.

N.º DE EXPERIMENTO	PREDICTOR EVALUADO	DESCRIPCIÓN
1	U'	U' para junio-agosto de 1982, 1997 y 2015 fue invertido en el Pacífico central (160° E-160° O, 5° S-5° N).
2	SSH'	SSH' para junio-agosto de 1982, 1997 y 2015 fue invertido en el Pacífico ecuatorial (120° E-80° O, 5° S-5° N).
3	U' & SSH'	Igual que n.º 1 y n.º 2, pero simultáneamente.
4	$SSTm'$	SST' sobre todo el dominio fue invertido para junio-agosto de 1982, 1997 y 2015.
5	Um'	Igual que n.o 1, pero manteniendo la SST' sobre la región núcleo del patrón E en cero.

3. Resultados

Se evaluaron los grafos causales utilizando el método PCMCI de 8 000 muestras de agregación bootstrap. En la Figura 1 se observa que cada nodo representa los predictores y el predictando. Entre ellos, destacan el viento zonal en el océano Pacífico central y oriental, el contenido de calor en el océano Pacífico ecuatorial, la inclinación en el océano Pacífico ecuatorial, y los índices E y C en agosto como predictores que influyen causalmente a nuestro predictando, el índice E en el siguiente enero. Las flechas indican relaciones causales, los colores rojos indican relaciones directas mientras que los colores azules, en caso de aparecer, indicarían relaciones inversas. La intensidad del color refleja la magnitud de la correlación asociada a la relación y el grosor de las flechas, el grado de confiabilidad de la relación causal entre las 8 000 muestras que coincidieron en la dirección y la intensidad de la correlación, mientras que flechas más delgadas indican lo contrario.

El grafo causal de la mediana de los 30 miembros del modelo (Figura 1b) muestra que el índice E y la

inclinación en agosto son los predictores más importantes, mientras que para el grafo causal observacional (Figura 1a) el viento zonal en el Pacífico central y la inclinación en agosto son los predictores más importantes. Asimismo, se calculó la puntuación F1 para medir la similitud de la red causal del modelo con respecto a las observaciones.




Figura 1. Grafo causal para los datos observacionales (a) y para la mediana de los 30 miembros de la corrida control (periodo 1981-2024) del modelo de IA (b). La métrica F1 se calculó con respecto al grafo causal observacional. Los colores rojos indican relaciones directas mientras que los colores azules indican relaciones inversas. La intensidad del color está relacionada con la correlación de la relación causal. El espesor de las flechas indica la confianza de la relación causal, es decir flechas más gruesas indican que la mayoría de las 8 000 muestras coincidieron en la dirección y la intensidad de la correlación, mientras que flechas más delgadas indican lo contrario.

Dado que el modelo IA IGP-UHM cuenta con 30 miembros, primero se calcularon los grafos causales individualmente para cada miembro (no mostrado) en el periodo 1981-2024. Para cada grafo causal se calculó la métrica F1 score tomando como referencia el grafo causal de las observaciones. La Figura 2 muestra la distribución de estos valores: mientras que un F1 próximo a 1 indica mayor semejanza entre el grafo causal del miembro del modelo y el grafo causal de referencia, valores cercanos a 0 indican divergencia. En particular, los miembros número 15, 16, 23 y 24 fueron los más semejantes al grafo obtenido con datos observacionales, con valores de F1 superiores a 0.6.




Figura 2. Métrica F1 score para los 30 miembros de la corrida control del modelo IA IGP-UHM con respecto al grafo causal observacional. La línea horizontal es un valor referencial de 0.6.

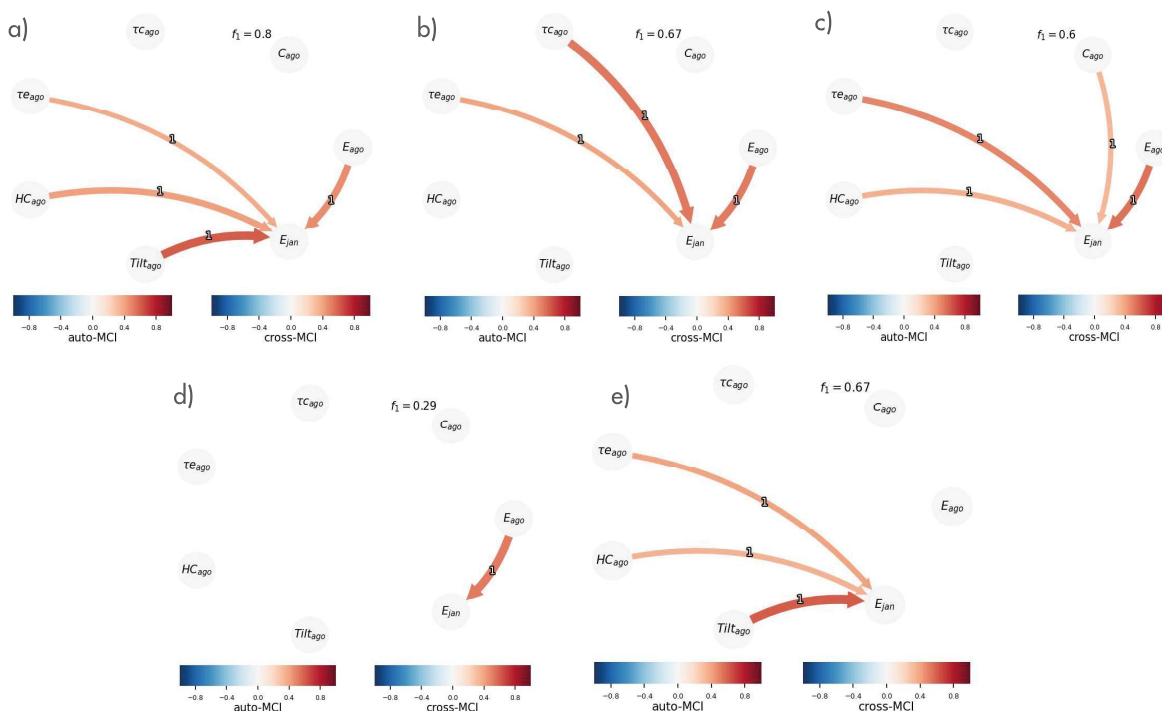


Figura 3. Grafos causales para los experimentos N°1 (a), N°2 (b), N°3 (c), N°4 (d) y N°5 (e), según la Tabla 1, con respecto al grafo causal de la corrida control del modelo de IA. Para cada experimento y el control se considera la mediana de los 30 miembros. El espesor de las flechas indica la confianza de la relación causal, es decir flechas más gruesas indican que la mayoría de las 8 000 muestras coincidieron en la dirección y la intensidad de la correlación, mientras que flechas más delgadas indican lo contrario.

El resultado del experimento N° 1 (ver Tabla 1) se muestra en la figura 1a. Este experimento consistió en invertir el viento zonal en el Pacífico central durante junio-agosto de 1982, 1997 y 2015, manteniendo los datos de todos los demás años iguales al control. El grafo causal obtenido muestra cambios sustanciales respecto al control, a pesar de que el modelo que generó los datos permaneció idéntico. En particular, la flecha que conectaba TC_{ago} con E_{jan} desapareció, lo que sugiere que, según estos nuevos datos, E_{jan} parece no depender de TC_{ago} . Hubiera sido esperable que el grafo causal de este experimento coincidiera con el

control, dado que el grafo causal debería corresponder a las relaciones causales codificadas en el modelo, el cual no se modificó tras invertir los valores de $\bar{\kappa}c$ en los datos de entrada para 1982, 1997 y 2015, y no ser sensibles a cuáles de los datos generados por este son considerados. Este resultado es consistente con lo encontrado por Obregon & Takahashi (2024), quienes mostraron que el modelo de IA presenta una sensibilidad muy baja a los vientos zonales en el océano Pacífico central. Ello sugiere que (1) el modelo no aprendió de manera correcta esta relación causal y (2) que el método de PCMCI podría no haber

identificado adecuadamente el grafo causal correspondiente al modelo con los datos disponibles.

El grafo causal identificado para el experimento n.º 2 (Figura 1b), en el que se invirtió el nivel del mar ecuatorial SSH_{ago} , sugiere que el pronóstico de E de enero parece no depender ni del contenido de calor (HC_{ago}) ni del tilt en junio-agosto ($tilt_{ago}$). Aunque la inversión se aplicó solo en 3 años (1982, 1997 y 2015) de los 44 años analizados y no tuvo un efecto mayor en el pronóstico general, fue suficiente para atenuar la relación causal diagnosticada entre el contenido de calor y tilt con respecto al índice E de enero.

De manera consistente con los dos anteriores, el experimento n.º 3, en el que se invirtieron los valores de la SSH_{ago} y $\tau_{C_{ago}}$ en simultáneo en 1982, 1997 y 2015, mostró un efecto limitado en el pronóstico. El grafo causal (Figura 1c) indica que el pronóstico de E de enero no depende de $\tau_{C_{ago}}$ o de tilt en agosto.

En contraste, el experimento n.º 4, que consistió en invertir las anomalías de SST sobre la región núcleo del patrón E en junio-agosto de 1982, 1997 y 2015, anuló los valores de E pronosticados para los meses de enero siguientes. El grafo causal identificado (Figura 1d) indica que el pronóstico de E de enero solo depende de E como predictor. Esto es consistente con lo encontrado por Obregon & Takahashi (2024), quienes señalaron que el predictor más influyente para el modelo de IA fue la SST en la región central del patrón E, debido a la fuerte dependencia en el pronóstico de E en la SST inicial según el modelo.

Finalmente, la Figura 1e muestra el grafo causal del experimento n.º 5, en el que se multiplicó por cero los valores de SST' dentro del núcleo del patrón E en agosto y, de forma simultánea, se invirtió el viento zonal en el Pacífico central en agosto ($\tau_{C_{ago}}$). En principio, se hubiera esperado que la relación causal entre $\tau_{C_{ago}}$ y el índice E en enero se mantuviera. Sin embargo, el grafo causal indica que el pronóstico de E de enero no depende de $\tau_{C_{ago}}$ ni de los índices E y C en agosto. Esto da a entender que el modelo de IA muestra una sensibilidad reducida a los cambios en el viento zonal en el Pacífico central, incluso en ausencia de una influencia dominante de SST como predictor. Dicho comportamiento concuerda con lo encontrado por Obregon & Takahashi (2024), quienes encontraron que, en estas condiciones, el modelo seguía prediciendo desde condiciones neutras hasta condiciones moderadas de El Niño en estas condiciones. En este sentido, los resultados sugieren que los cambios en las condiciones iniciales del viento

zonal no son muy importantes para el modelo IGP-UHM para predecir El Niño, en contraposición al conocimiento científico vigente sobre el fenómeno.

4. Conclusiones

Este estudio evaluó la capacidad del método PCMCI para descubrir empíricamente las relaciones causales aprendidas por el modelo IA IGP-UHM, con el objetivo de entender mejor la sensibilidad de sus pronósticos frente a aspectos de las condiciones iniciales que son considerados precursores clave en la investigación científica sobre los mecanismos físicos de ENOS. Para ello, se expuso el modelo a situaciones artificiales en las condiciones iniciales, cuyo efecto en el pronóstico podía anticiparse cualitativamente con base en el conocimiento de la física de ENOS. Sin embargo, los resultados sugieren que este conocimiento no habría sido inferido adecuadamente a partir de los datos utilizados en el entrenamiento del modelo.

El método PCMCI identificó, a partir, tanto de datos observacionales como de los pronósticos con el modelo IA, relaciones causales que, en términos generales, son consistentes con nuestro entendimiento de ENOS. No obstante, se observaron diferencias relevantes: mientras que en los datos observacionales los precursores más importantes del índice E en enero fueron el esfuerzo de viento zonal en el Pacífico central ($\tau_{C_{ago}}$) y la inclinación de la termoclina (tilt) de agosto, para el modelo IA lo fueron tilt y el índice E de agosto.

Tras realizar varios experimentos (Tabla 1), en los que se modificaron las condiciones iniciales del modelo para los años 1982, 1997 y 2015, los grafos causales identificados por el método PCMCI a partir de las condiciones iniciales y predicciones del modelo de IA mostraron alta variabilidad. Esto ocurrió a pesar de que el modelo de IA que generó las predicciones siempre fue el mismo, y en general los resultados fueron inconsistentes en general con los grafos causales obtenidos de los datos observacionales y de la corrida control del modelo. En particular, el análisis de los experimentos sugiere que el modelo es poco sensible al viento zonal en el Pacífico central y que otorga mayor importancia a la SST que la esperada sobre el núcleo del patrón E. Esto sugiere que el modelo no capturó adecuadamente las relaciones físicas entre sus variables de entrada, así como que los resultados del método empírico PCMCI podrían estar sesgados en general, dado que los datos generados en forma natural (no experimental) pueden ser insuficientes para identificar las relaciones causales de

forma robusta.

Al considerar los seis experimentos, incluyendo el control, se encontró que los predictores que aparecen en el mayor número de grafos causales es E_{ago} y τE_{ago} (en 5 de 6 grafos), seguido por HC_{ago} (4 de 6) y Tilt_{ago} (3 de 6). En contraste, C_{ago} y τC_{ago} solo fueron identificados como predictores en 2 de 6 grafos causales. Estos resultados podrían reflejar con mayor precisión cuáles son las relaciones causales realmente representadas por el modelo, que parece priorizar el calentamiento superficial y viento en el Pacífico oriental. Ello abre la posibilidad de aplicar un enfoque similar a modelos numéricos climáticos, con el fin de obtener evaluaciones más robustas de la causalidad.

En conjunto, los hallazgos ilustrarían una limitación fundamental de los modelos de *machine learning*, los cuales típicamente no son capaces de identificar relaciones de causalidad, sólo de correlación o asociación, así como de los métodos de descubrimiento causal, que están limitados por los datos disponibles y que no presentarían suficiente diversidad como para poder distinguir las asociaciones de las relaciones causales. A diferencia de estos enfoques, los investigadores 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, así como de la experimentación, la cual crea situaciones artificiales que permiten evaluar directamente las asociaciones causales. Este estudio plantea interrogantes sobre la capacidad de los modelos de IA para realizar predicciones confiables cuando se enfrentan a situaciones novedosas, en las que las relaciones o asociaciones correlacionales pueden dejar de ser válidas. En tales casos, resulta fundamental que los modelos se basen en relaciones causales, cuyo valor predictivo tiende a mantenerse. Por tanto, es necesario mantener una perspectiva crítica frente al desempeño de los modelos de IA en la predicción climática e incorporar el conocimiento experto en su desarrollo y evaluación.

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:ATFTEP>2.3.CO;2](https://doi.org/10.1175/1520-0493(1969)097<0163:ATFTEP>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*, 30(4), 1505–1519.

<https://doi.org/10.1175/JCLI-D-16-0385.1>

Debeire, K., Gerhardus, A., Runge, J., & Eyring, V. (2024, March). Bootstrap aggregation and confidence measures to improve time series causal discovery. In F. Locatello, F. & Didelez, V. (Eds.), *Proceedings of the Third Conference on Causal Learning and Reasoning In Causal Learning and Reasoning* (Vol. 236, pp. 979-1007). *Proceedings of Machine Learning Research*. PMLR.

<https://proceedings.mlr.press/v236/debeire24a.html>

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>

Nowack, P., Runge, J., Eyring, V., & Haigh, J. D. (2020). Causal networks for climate model evaluation and constrained projections. *Nature communications*, 11(1), 1415.

<https://doi.org/10.1038/s41467-020-15195-y>

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.

<http://hdl.handle.net/20.500.12816/5712>

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), Article 21150.

<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. (2019). 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), 2668–2675.

[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), Article 11684.

<https://doi.org/10.1038/s41598-024-62361-z>