



PERÚ

Ministerio
del Ambiente



IGP Instituto
Geofísico
del Perú

BOLETÍN CIENTÍFICO

EL NIÑO

Vol. 12 n.º 07 julio 2025

PROGRAMA PRESUPUESTAL n.º 068

"Reducción de la vulnerabilidad y
atención de emergencias por desastres"

En este boletín

- Menos bosques, más sequedad en la amazonía: impactos de la deforestación desde el modelado acoplado superficie-atmósfera | **Pág. 4**
- Descubrimiento e inferencia causal para la predicción de El Niño | **Pág. 15**
- Resumen del informe técnico de El Niño | **Pág. 22**
- Resumen de comunicado ENFEN | **Pág. 23**



Créditos

Miguel Angel Espichán Mariñas
Ministro del Ambiente

Hernando Tavera Huarache
Jefe institucional

James Apaéstegui Campos
Director de Ciencias de la Atmósfera, Hidrósfera y Cambio Climático

Lina Godoy Encarnación
Coordinadora de la Unidad Funcional de Comunicaciones

Fey Yamina Silva Vidal de Millones
Ken Takahashi Guevara
Joel Anicama Díaz
Editores

Fernanda Quispe Nakashima
Diseño y diagramación

Carátula: Fotografía de bosque amazónico deforestado.
Fuente: Diego Pérez / SPDA Actualidad Ambiental

El boletín científico "El Niño" es generado en el marco del Programa Presupuestal n.º 068 "Reducción de la vulnerabilidad y atención de emergencias por desastres"

Producto 1: Estudios para la estimación del riesgo de desastres
Actividad 5: Generación de información y monitoreo del Fenómeno El Niño
Instituto Geofísico del Perú

Calle Badajoz 169 Mayorazgo, Ate, 15012

Teléfono: +51-1-3172300

Lima, noviembre de 2025

Puedes acceder a la colección completa de los boletines científicos El Niño escaneando el siguiente código QR.



Introducción

Los eventos El Niño y La Niña corresponden, a grandes rasgos, a situaciones en las que la temperatura de la superficie del mar está por encima o por debajo del promedio en el océano Pacífico ecuatorial. Estas fluctuaciones están fuertemente influenciadas por El Niño-Oscilación del Sur (ENOS), el cual es uno de los modos de variabilidad climática más importantes en el océano Pacífico que ejerce una gran influencia sobre el clima a nivel global y regional. La fase cálida de ENOS se puede denominar El Niño “global”.

En el Perú, los impactos de El Niño y La Niña son particularmente complejos debido a que recibimos influencias tanto costeras, asociadas a las fluctuaciones en el mar peruano en el Pacífico oriental, así como influencias remotas a través de teleconexiones atmosféricas desde el Pacífico central. En particular, El Niño en el Pacífico oriental o Costero puede producir lluvias y altas temperaturas en la costa y alterar el ecosistema marino-costero, mientras que El Niño en el Pacífico central o global puede reducir las precipitaciones e incrementar la temperatura en los Andes y en la Amazonía. Por el contrario, La Niña tendría efectos aproximadamente opuestos. Así, El Niño en el Pacífico oriental es el que causa mayores impactos para el Perú, ya que tiene el potencial de provocar grandes daños a infraestructuras, actividades económicas y, más importante, la seguridad y bienestar de las personas, además de sus medios de vida.

El Perú, como parte de la estrategia de gestión pública para enfrentar los peligros naturales, especialmente respecto a El Niño, establece el Programa Presupuestal por Resultados (PPR) 068 “Reducción de vulnerabilidad y atención de emergencias por desastres”. A partir de 2014, el Instituto Geofísico del Perú (IGP), al igual que otras instituciones que conforman la Comisión Multisectorial encargada del Estudio Nacional del Fenómeno El Niño (ENFEN), participa en este PPR con el producto denominado “Estudios para la estimación del riesgo de desastres”. Este consiste en la entrega en forma oportuna de información científica sobre el monitoreo y pronóstico de este evento natural oceánico-atmosférico, mediante informes técnicos mensuales, que permita la toma de decisiones de las autoridades a nivel nacional y regional.

A este producto, el IGP contribuye con la actividad “Generación de información y monitoreo del Fenómeno El

Niño”, la cual incluye la síntesis y evaluación de los modelos de pronóstico de El Niño generados internacionalmente, como es el caso de los modelos climáticos globales, así como de aquellos obtenidos a partir de modelos propios como el de predicción de ondas oceánicas ecuatoriales, el modelo de inteligencia artificial y el recientemente desarrollado modelo de Sistema Tierra regional de pronóstico para el territorio peruano y el océano Pacífico (IGP RESM-COW v1). Asimismo, incluye el desarrollo de investigaciones y estudios científicos que permiten entender la variabilidad climática y los procesos asociados al cambio climático, a fin de fortalecer, en forma continua, las capacidades para el pronóstico de El Niño.

En esta línea, el IGP ha estructurado y desarrollado el Boletín científico El Niño, un producto que contiene, en gran medida, los aportes científicos en el estudio y vigilancia del ENOS, con énfasis en El Niño. El Boletín, que se publica mensualmente desde 2014, cuenta con aportes nacionales e internacionales en diversos temas asociados a El Niño, sus impactos, procesos vinculados, temas asociados y otros igual de relevantes, que se presentan en las secciones de “Divulgación Científica” y “Avances Científicos”. De igual forma, se comparte en el Boletín una versión resumida del informe técnico que el IGP elabora mensualmente para cumplir con los compromisos asumidos en el marco del PPR 068 (68) (8) (<https://repositorio.igp.gob.pe/handle/20.500.12816/5356>). Dicho informe contiene información actualizada operativamente que el IGP proporciona como insumo para que el ENFEN genere en forma colegiada la evaluación final que será entregada a los usuarios. Finalmente, el Boletín presenta los comunicados ENFEN publicados durante el periodo correspondiente.

MENOS BOSQUES, MÁS SEQUEDAD EN LA AMAZONÍA: IMPACTOS DE LA DEFORESTACIÓN DESDE EL MODELADO ACOPLADO SUPERFICIE-ATMÓSFERA

Omar Gutiérrez-Cori^{1,2,3}, Laurent Li³ y Jhan-Carlo Espinoza^{4,5}

¹ Wildlife Conservation Society (WCS), Lima, Perú.

² Departamento de Ordenamiento Territorial y Construcción, Universidad Nacional Agraria La Molina (UNALM), Lima, Perú.

³ Laboratoire de Météorologie Dynamique, LMD – IPSL, Sorbonne Université, CNRS, París, Francia.

⁴ Université Grenoble Alpes, IRD, CNRS, INRAE, Grenoble, Francia.

⁵ Instituto de Investigación Sobre la Enseñanza de las Matemáticas, Pontificia Universidad Católica del Perú, Lima, Perú.



Omar Gutiérrez Cori es Ph.D. en Ciencias de la Tierra y del Medio Ambiente por la Sorbonne Université (París, Francia), M.Sc. en Recursos Hídricos por la Universidad Nacional Agraria La Molina (Lima, Perú) y B.Sc. en Ciencias Agrarias por la Universidad Nacional del Altiplano (Puno, Perú). Su línea de investigación se centra en comprender la dinámica de las retroalimentaciones físicas entre los cambios en el LULC, los procesos hidrológicos y la variabilidad climática, mediante observaciones en campo, sensores remotos y modelos. Actualmente es investigador postdoctoral en la Wildlife Conservation Society (WCS).

Palabras clave: Deforestación, Modelado superficie-atmósfera, Transición biofísica, ORCHIDEE y LMDZ

Citar como Gutiérrez-Cori, O., Li, L. & Espinoza, J.C. (2025). Menos bosques, más sequedad en la Amazonía: impactos de la deforestación desde el modelado acoplado superficie-atmósfera. Boletín científico El Niño, Instituto Geofísico del Perú, vol. 12 n.º 07, págs. 4-14.

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

Esta investigación brinda evidencia clave para la toma de decisiones al mostrar que la deforestación proyectada hacia 2050 intensificaría el estrés hídrico en el suroeste amazónico (Perú y Bolivia principalmente). Esto podría comprometer la resiliencia de los ecosistemas locales, el ingreso de aire húmedo que alimenta las lluvias en los Andes —particularmente en el Altiplano—, produciendo impactos en la seguridad hídrica y agrícola. La evidencia generada respalda la necesidad de implementar políticas urgentes de conservación y gestión forestal, integrando la protección de la Amazonía con estrategias nacionales y regionales de adaptación al cambio climático, gestión de los recursos hídricos y reducción del riesgo de desastres.

Resumen

Los bosques amazónicos juegan un papel crucial en la hidroclimatología regional, pues impulsan el ciclo del agua y actúan como amortiguadores frente a sequías extremas. No obstante, el cambio climático y la pérdida de bosques están alterando estas funciones debido al fuerte acoplamiento tierra-atmósfera, especialmente en la Amazonía sur. Esta investigación evalúa los impactos de la deforestación proyectada

hacia el 2050 sobre el ciclo hidrológico y el estrés hídrico regional, mediante simulaciones acopladas del modelo de superficie terrestre ORCHIDEE (ORganising Carbon and Hydrology In Dynamic EcosystEms) y el modelo de circulación general LMDZ (Laboratoire de Météorologie Dynamique-Zoom). Los resultados muestran que la pérdida de cobertura forestal reduce la precipitación (P) y la evapotranspiración (E), mientras incrementa la

escorrentía (R), con efectos más marcados durante la estación seca. Regionalmente se observa un aumento del coeficiente de escorrentía (R/P) y una disminución del reciclaje local de agua (E/P), lo que indica un menor aprovechamiento del agua por parte del ecosistema. Además, se intensifica el estrés hídrico, reflejado en valores más negativos del Acumulado Máximo de Déficit de Agua (MCWD, por sus siglas en inglés) y en un aumento significativo del Déficit de Presión de Vapor (VPD, por sus siglas en inglés), particularmente en la Amazonía suroeste. Estos desequilibrios se asocian a cambios en la circulación atmosférica y a una reducción del reciclaje de humedad inducida por la deforestación, lo que amplifica el déficit hídrico. Los resultados también sugieren un debilitamiento de los flujos de humedad más allá de la cuenca amazónica, con posibles efectos en regiones como el Altiplano. En conjunto, los hallazgos subrayan la vulnerabilidad de la Amazonía ante escenarios de pérdida forestal y aportan evidencia sobre los riesgos crecientes asociados al estrés hídrico, contribuyendo a una mejor comprensión de los vínculos entre la deforestación, la disponibilidad de agua y la estabilidad ecohidrológica regional.

1. Introducción

La Amazonía constituye uno de los principales núcleos de biodiversidad, proporciona servicios ecosistémicos (Barlow et al., 2018) y desempeña un papel fundamental como el mayor sumidero natural de carbono terrestre (Gatti et al., 2021). Más aún, los bosques amazónicos actúan como reguladores del sistema climático e impulsores del ciclo hidrológico (Worden et al., 2021), pues influyen en el clima y la hidrología mediante procesos biofísicos, como el reciclaje de agua (Zemp et al., 2017; Jenkins et al., 2025). Funcionan como bombas hidráulicas que extraen grandes volúmenes de agua del subsuelo profundo y los liberan a la atmósfera gracias al fuerte acoplamiento tierra-atmósfera (Aragão, 2012) y a complejos mecanismos de retroalimentación (Flores & Staal, 2022), los cuales pueden mitigar el impacto de eventos climáticos extremos, como las sequías (Staal et al., 2018). Estas dinámicas están moduladas por la interacción entre sistemas atmosféricos de gran escala (Marengo et al., 2010), las altas tasas de precipitación (Builes-Jaramillo and Poveda, 2018) y las condiciones geomorfológicas locales, factores que, en conjunto, explican la composición, dinámica y heterogeneidad forestal (Marca-Zevallos et al., 2022).

En un estado ecológico estable, esta configuración resulta esencial para determinar la respuesta del ecosistema amazónico al estrés hídrico y al cambio climático (Esquivel-Muelbert et al., 2019). No obstante, bajo condiciones de perturbación, la circulación atmosférica y los flujos de agua y energía del sistema tierra-atmósfera pueden modificarse por factores internos y externos (Sierra et al., 2023). En este contexto, sistemas interconectados como el Andes–Amazon–Atlantic (AAA) evidencian cómo una alteración local puede desencadenar respuestas en cascada a lo largo de toda la cuenca. Así, los impactos se manifiestan mediante retroalimentaciones positivas, que amplifican el cambio, o negativas, que lo amortiguan (Beveridge et al., 2024).

La cuenca amazónica es un ecosistema dinámico en constante cambio que, en los últimos años, ha experimentado perturbaciones en el equilibrio del sistema clima-vegetación. Dichas alteraciones se atribuyen al cambio climático global y a la intensa presión antropogénica, principales impulsores de las transformaciones sobre un ecosistema cada vez más frágil (Lapola et al., 2023). Además, las retroalimentaciones entre actividades humanas y fenómenos climáticos —por ejemplo, el déficit de lluvias— tienen el potencial de transformar la Amazonía en un ecosistema más seco (Staal et al., 2020). Esto es preocupante, pues acentúa el debate planteado sobre el posible colapso de todo el ecosistema amazónico vinculado a estas sinergias (Wunderling et al., 2022). De hecho, el ciclo hidrológico regional se ha intensificado: se registran episodios secos más frecuentes e intensos durante las últimas décadas (Espinoza et al., 2024), lo que favorece la ocurrencia de incendios forestales y una mayor mortalidad de bosques (Barlow et al., 2020).

En años recientes se ha informado, además, que los procesos humanos ya superan en magnitud a los estrictamente climáticos (Albert et al., 2023). Las tasas de deforestación se han incrementado sustancialmente por la expansión de la frontera agrícola, sobre todo en la Amazonía sur (Silva-Junior et al., 2021). Dado que la deforestación puede reducir las lluvias e intensificar los episodios secos (Staal et al., 2020), resulta crucial determinar sus impactos y comprender la dirección futura de los cambios en la estabilidad hidroclimática.

Debido a todo lo anterior, la Amazonía es reconocida como un posible punto de inflexión en el sistema climático de la Tierra; es decir, podría desencadenarse una transición biofísica abrupta del bosque tropical

hacia un ambiente más seco, lo que representaría una amenaza para la estabilidad de todo el ecosistema (Wunderling et al., 2022). Una reducción de la evapotranspiración forestal —mecanismo clave en el reciclaje y transporte de humedad (Zemp et al., 2017)— afectaría especialmente a las regiones ubicadas al suroeste de la cuenca, incluidos los Andes, que dependen del suministro de agua reciclada para su estabilidad, dado que influye en las precipitaciones y la disponibilidad hídrica (Ruiz-Vásquez et al., 2020). Sin embargo, la deforestación, combinada con períodos secos intensos y prolongados, podría alterar el equilibrio vegetación-atmósfera y generar riesgos significativos para toda la región debido a sus efectos autoamplificados (Zemp et al., 2017). Comprender cómo la pérdida de bosques altera los procesos hidroclimáticos es, por tanto, fundamental; ello subraya la importancia de profundizar en el conocimiento de las interacciones clima-vegetación y sus cambios. En los últimos años, los modelos han contribuido significativamente a mejorar este entendimiento (Guimberteau et al., 2017; Wongchuig et al., 2023). No obstante, persisten incertidumbres, por lo que resulta necesario seguir explorando

diversas perspectivas, especialmente considerando que las proyecciones hacia 2050 indican que los impulsores climáticos y antropogénicos continuarán representando una amenaza latente (Lapola et al., 2023).

En este contexto, la presente investigación analiza cómo escenarios de deforestación futura podría afectar los procesos hidrológicos e intensificar la sequedad en la Amazonía, mediante simulaciones acopladas entre el modelo de superficie terrestre ORCHIDEE y el modelo de circulación atmosférica global LMDZ (Figura 1a). Aunque el análisis abarca toda la cuenca, se enfoca en el suroeste amazónico (Figura 1b), una región clave por su biodiversidad, sus contrastes hidroclimáticos y la creciente presión antrópica. Se trata, por ende, de un escenario crucial para comprender las posibles alteraciones en la estabilidad hidroclimática de toda la Amazonía.

Los resultados presentados en esta investigación forman parte de la tesis doctoral titulada “Relationship and Feedback Between LULC Changes and Hydroclimatic Variability in Amazonia” (Gutierrez Cori, 2024).

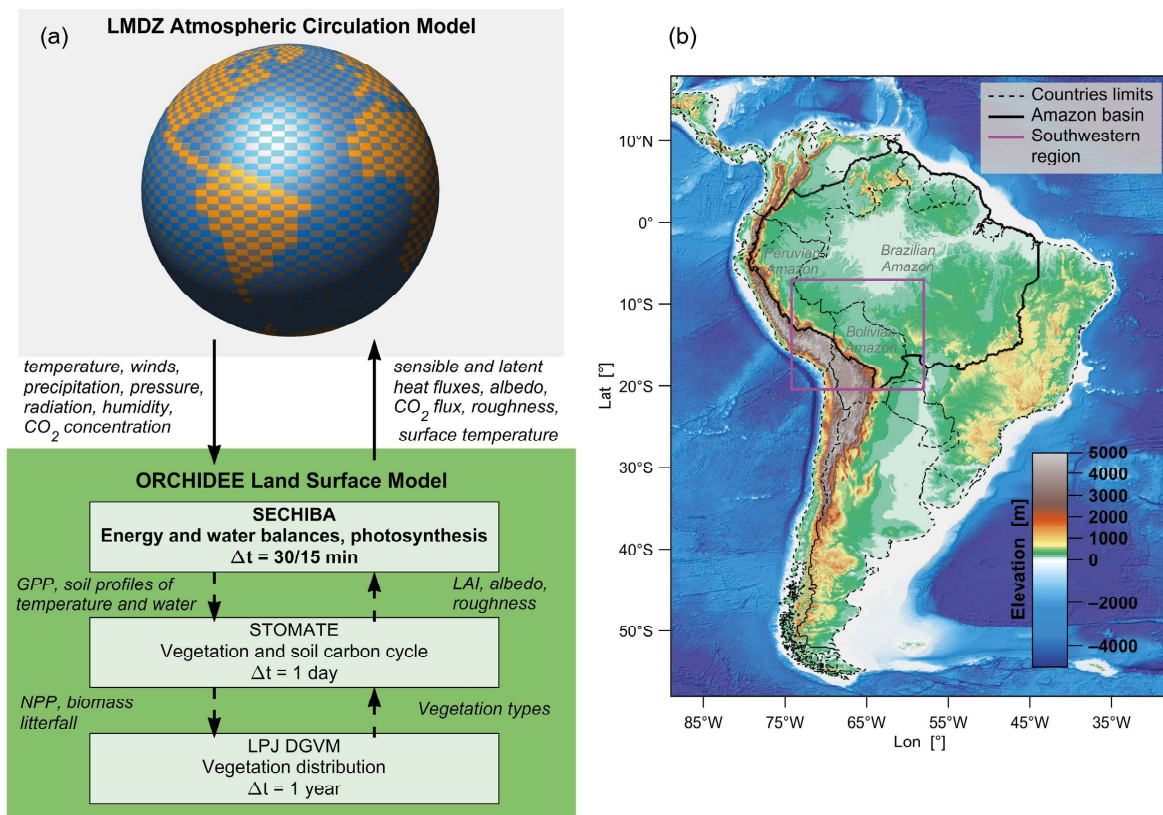


Figura 1. Conceptualización del modelo ORCHIDEE acoplado a LMDZ (a) y ubicación de la región de estudio (b). La línea magenta indica el suroeste de la Amazonía.

2. Datos y métodos

Modelo de superficie ORCHIDEE

ORCHIDEE (ORganizing Carbon and Hydrology in Dynamic Ecosystems) es el componente de superficie del Modelo del Sistema Terrestre del Institut Pierre-Simon Laplace (IPSL-ESM) y evalúa las interacciones y los intercambios de energía, agua y carbono en el sistema vegetación-suelo-atmósfera (Krinner et al., 2005). Consta de dos módulos principales: SECHIBA (Schématisation des EChanges Hydriques à l'Interface entre la Biosphère et l'Atmosphère) y STOMATE (Saclay Toulouse Orsay Model for the Analysis of Terrestrial Ecosystems), los cuales resuelven procesos asociados a los ciclos de energía, agua y carbono (Campoy et al., 2013). SECHIBA simula los intercambios de energía y agua entre el sistema tierra-atmósfera, así como la hidrología del suelo (Krinner et al., 2005). Este módulo interactúa con la atmósfera y resuelve procesos térmicos e hidrológicos clave de la superficie, como la temperatura, la evapotranspiración y el escurrimiento (Guimberteau et al., 2017). SECHIBA opera sobre celdas de cuadrículas rectangulares, donde la cobertura vegetal se representa mediante mosaicos homogéneos distribuidos en Tipos Funcionales de Plantas (PFT, por sus siglas en inglés). Cada PFT se caracteriza por un conjunto de parámetros que describen los procesos biofísicos que rigen las interacciones superficie-atmósfera (Campoy et al., 2013).

Modelo atmosférico LMDZ

LMDZ es un modelo de circulación general atmosférica (General Circulation Model, GCM) desarrollado por el Laboratoire de Météorologie Dynamique (Hourdin et al., 2013). Su núcleo dinámico se basa en una discretización por diferencias finitas de las ecuaciones primitivas de la meteorología. Horizontalmente utiliza una cuadrícula longitud-latitud con posibilidad de refinamiento en ambas direcciones (la "Z" en LMDZ hace referencia a zoom); verticalmente emplea una coordenada híbrida clásica sigma-presión (Hourdin et al., 2020). LMDZ es el componente atmosférico del modelo de Sistema Tierra IPSL-ESM y ha estado presente de esta manera en diversas fases de los ejercicios CMIP (Coupled Model Intercomparison Project) (Hourdin et al., 2013). En cuanto a las parametrizaciones físicas, el IPSL participó en el CMIP5 con dos versiones: Standard Physics y New Physics. Sin embargo, esta última

presentó deficiencias frente a la primera, especialmente en métricas relacionadas con nubes, convección profunda y la alta variabilidad de las precipitaciones en los trópicos (Hourdin et al., 2020). Ante esto, se desarrolló una versión revisada de New Physics, con mejoras en las parametrizaciones de turbulencia, convección y nubes. Dicha versión fue incorporada al modelo LMDZ6A-LR, utilizado en IPSL-CM6A-LR para CMIP6, que opera con una grilla horizontal regular de 144x143 puntos (2.5°x1.25°) y 79 niveles verticales que se extienden desde los 10 m hasta los 80 km sobre la superficie terrestre (Hourdin et al., 2020).

Diseño del experimento

Se realizaron dos experimentos acoplados con LMDZ y ORCHIDEE: (i) uno considerando las condiciones de vegetación histórica y (ii) otro bajo un escenario de deforestación futura.

- El experimento de control (CTRL): simula los procesos bajo las condiciones actuales de uso y cobertura del suelo (LULC), utilizando un mapa de cobertura forestal correspondiente al año 2014 (Figura 2a).
- El experimento de deforestación (DFOR): reemplaza el mapa de uso y cobertura del suelo en la Amazonía con un escenario proyectado para 2050 (Figura 2b), que estima pérdidas de bosques superiores al 45 %, y refleja un escenario pesimista con cambios sustanciales en el LULC debido a la sustitución de bosques por cultivos (Soares-Filho et al., 2006).

Los mapas de LULC son integrados en el modelo y representados mediante Tipos Funcionales de Plantas (PFT, por sus siglas en inglés) en las simulaciones LMDZ-ORC CTRL (Figura 2c) y LMDZ-ORC DFOR (Figura 2d).

El acoplamiento en ambos experimentos se realiza según el protocolo del Proyecto de Intercomparación de Modelos Atmosféricos (AMIP, por sus siglas en inglés), que prescribe la Temperatura de la Superficie del Mar y la Concentración de Hielo Marino, con simulaciones para el periodo 1971-2014 y un análisis enfocado en 1981-2014.




Figura 2. Mapas de deforestación Amazónica para los años 2014 (a) y 2050 (b), y fracción de cobertura boscosa en los experimentos de control (c) y bajo deforestación (d), derivadas de los mapas mostrados.

Indicadores de cambios hidrológicos y biofísicos

Se utilizaron diversos índices para analizar los impactos de la deforestación proyectada en el ciclo hidrológico, el estrés hídrico y la intensidad de la sequedad.

Para evaluar cómo la pérdida de bosques podría modificar la partición de los flujos de agua, se analizaron los cambios en dos relaciones clave. Se consideró el coeficiente de escurrimiento, definido como el cociente entre escurrimiento y precipitación (R/P), que representa la fracción de agua no utilizada por el ecosistema, y el cociente entre evapotranspiración y precipitación (E/P), indicador de la capacidad de reciclaje local del agua.

Para caracterizar la intensidad del estrés hídrico superficial, se calculó el Acumulado Máximo de Déficit de Agua (MCWD, por sus siglas en inglés), una métrica que cuantifica el déficit de agua en función de la duración e intensidad de la estación seca (Esquivel-Muelbert et al., 2019). Este índice ha sido ampliamente utilizado para evaluar la estabilidad del

ecosistema, la severidad del estrés hídrico y la posible muerte regresiva de los bosques amazónicos (Zemp et al., 2017; Wunderling et al., 2022). El MCWD se define como el valor más negativo del déficit de agua acumulado durante el año; cuanto mayor es el estrés hídrico, más negativo es su valor.

También se empleó el Déficit de Presión de Vapor (VPD, por sus siglas en inglés) como indicador del estrés hídrico atmosférico. El VPD se calcula a partir de la ecuación de Clausius-Clapeyron, que describe la relación entre la presión de vapor de saturación del aire y la presión de vapor real (Green et al., 2022). Cuanto mayor es la diferencia entre ambos valores, mayor es la demanda atmosférica de agua, lo que se traduce en un VPD más elevado. Este índice también es un indicador de la aridez atmosférica y está estrechamente vinculado con los procesos biofísicos de la vegetación.

3. Resultados

Evaluamos los posibles impactos de la deforestación proyectada para 2050 sobre el ciclo hidrológico

terrestre de la Amazonía suroeste (área en magenta en la Figura 1b). La Figura 3 presenta una comparación de los valores anuales y estacionales de los componentes del ciclo hidrológico, estimados a partir de los experimentos CTRL y DFOR, e incluye una estimación de los cambios inducidos por la pérdida de bosques, calculados como la diferencia entre ambos experimentos. Bajo escenarios de deforestación, la precipitación anual (P) disminuye, la escorrentía total (R; disponibilidad de agua terrestre) aumenta y la evapotranspiración (E; flujo de agua entre la superficie y la atmósfera) se reduce (Figura 3a).

Cuantitativamente, estos cambios se traducen en una disminución del 2.9% en P, un incremento del 11.2% en R y una reducción del 7.8% en E (Figura 3d). Sin embargo, a escala estacional las diferencias se acentúan. Durante la estación húmeda (octubre-marzo) P y E no presentan variaciones significativas (Figuras 3b y 3e), pero R aumenta en un 15.9% y el almacenamiento de agua terrestre (ΔS_w) disminuye en un 13.6%, con el mayor aumento en R registrado entre enero-marzo. En contraste, durante la

estación seca (abril-septiembre), los cambios son aún más pronunciados. P y E disminuyen en un 5.8% y un 13.7%, respectivamente (Figuras 3c y 3f), mientras que R y ΔS_w se incrementan en 6.2% y 13.2%, concentrándose las mayores reducciones de E en los meses de junio-agosto. A nivel de toda la cuenca amazónica, los mayores desequilibrios en las particiones de flujos de agua inducidos por la pérdida de bosques se localizan en el sur, sobre el denominado "arco de deforestación" (Figura 4). En la Amazonía suroeste, la dirección de los cambios sugiere que, en promedio, el coeficiente de escorrentía (R/P) aumenta significativamente en un 5.5% (Figura 4a), y el reciclaje de agua (E/P) disminuye en un 5.1% (Figura 4b). Lo cual, desde una perspectiva ec hidrológica, implica un aumento en la cantidad de agua que se pierde por escurrimiento sin ser aprovechada por el ecosistema, junto con una disminución en la humedad devuelta a la atmósfera por la vegetación. En conjunto, estos desequilibrios tienen el potencial de intensificar el déficit hídrico en la región.

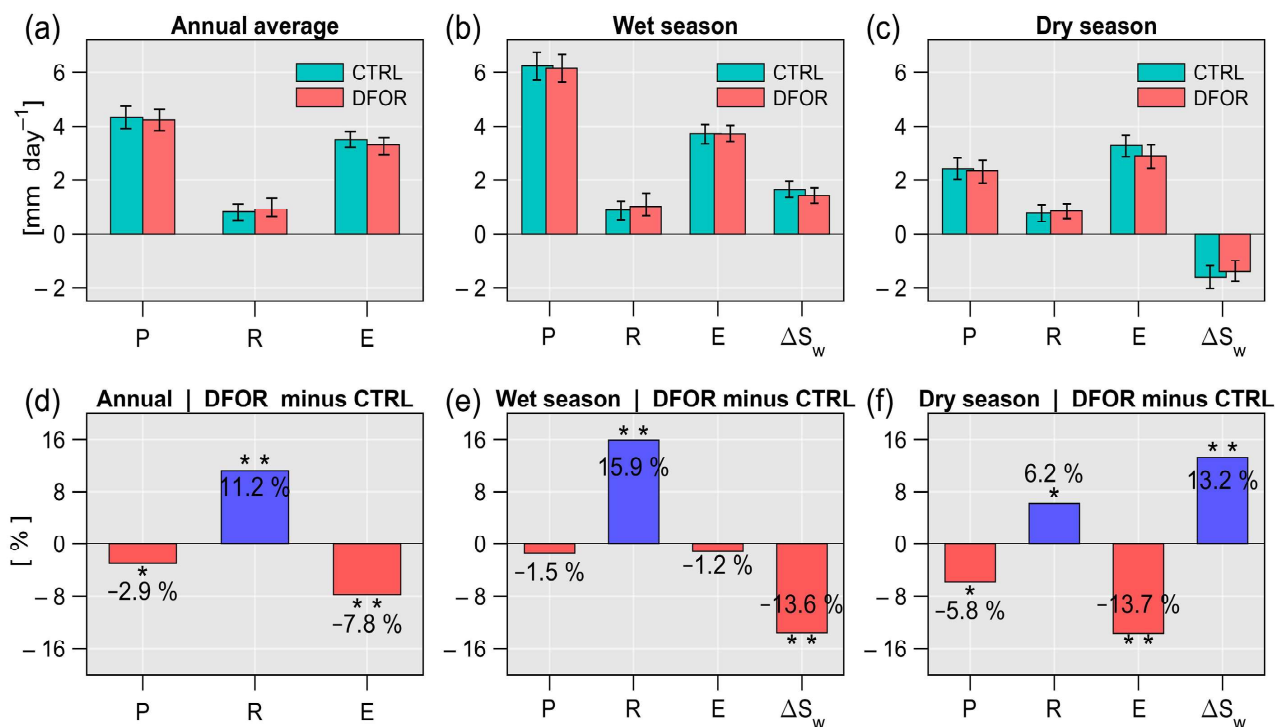


Figura 3. Valores anuales (a) y estacionales (b y c) de los componentes del ciclo hidrológico, estimados a partir de los experimentos CTRL y DFOR en la Amazonía suroeste. Los paneles d a f muestran los cambios porcentuales inducidos por la deforestación. "*" y "**" indican diferencias significativas al 90 % ($p < 0.1$) y 99 % ($p < 0.01$), respectivamente.




Figura 4. Cambios en el coeficiente de escorrentía (R/P ; a) y en el reciclaje local del agua (E/P ; b) inducidos por la deforestación. El tamaño de los puntos se asocia con la significancia de los cambios.

Para inferir los impactos de la deforestación sobre el estrés hídrico, se analizaron los cambios en el MCWD y el VPD (a un nivel de presión de 1000 hPa), observándose modificaciones de las condiciones estacionarias a largo plazo en ambos índices debido a la pérdida de cobertura boscosa (Figura 5). La deforestación proyectada induce valores de MCWD significativamente más negativos en la Amazonía occidental y suroeste, lo que indica una intensificación de las condiciones secas y un mayor estrés hídrico en los bosques de estas regiones (Figura 5a). De hecho, en comparación con el conjunto de la Amazonía, es en la región suroeste donde el VPD muestra un aumento más pronunciado como resultado de la deforestación (Figura 5b), lo que genera un ecosistema considerablemente más seco, limitando los procesos biofísicos de la vegetación.

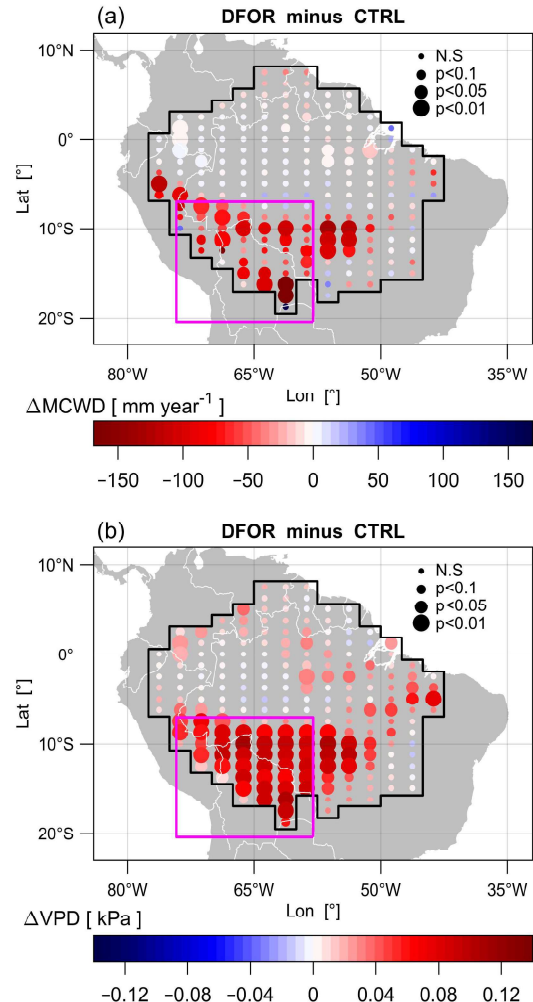


Figura 5. Cambios en el Acumulado Máximo de Déficit de Agua (MCWD; a) y en el Déficit de Presión de Vapor (VPD; b) inducidos por la deforestación. El tamaño de los puntos se asocia con la significancia de los cambios.

El análisis vertical longitud-altura sobre la Amazonía sur (8° – 20° S, 78° – 45° W; Figura 6a en magenta) revela que el aumento de la aridez y del estrés hídrico en la región suroeste se asocia a cambios en la dinámica atmosférica, principalmente durante la estación seca. La deforestación intensifica los vientos zonales (u) hacia el este en los niveles altos de la troposfera, debilita el movimiento vertical (w) y reduce la humedad específica (q) (Figura 6b). Los valores más negativos de humedad específica se concentran en la baja troposfera, sobre la Amazonía boliviana y brasileña, como resultado de una menor evapotranspiración. Durante la estación húmeda también se observan cambios en la dinámica atmosférica inducidos por la pérdida de bosques (Figura 6c). En este período, se debilitan los vientos zonales hacia el oeste en los niveles altos sobre la

Amazonía brasileña, junto con una reducción del movimiento vertical y de la humedad específica, especialmente en el suroeste de la cuenca. Los valores

más negativos se concentran entre los 800 y 500 hPa sobre la Amazonía boliviana, y se extienden incluso hacia los Andes tropicales en el Altiplano.

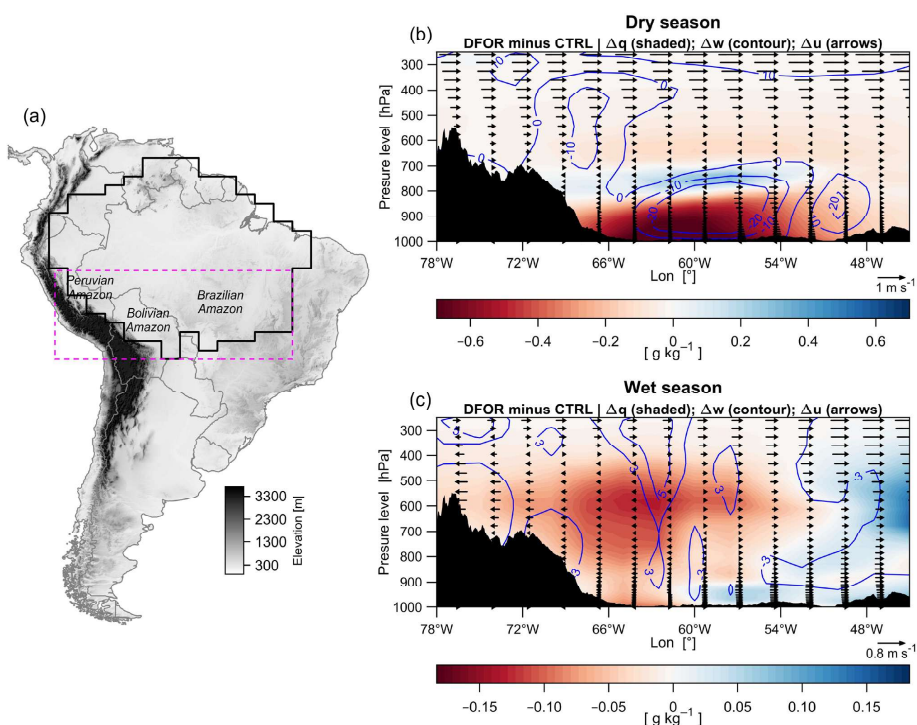


Figura 6. Sección transversal longitud-altura de los cambios en la humedad específica q (g kg^{-1} color), el movimiento vertical w (Pa h^{-1} ; contornos) y la velocidad del viento zonal u (m s^{-1} ; flechas), inducidos por la deforestación. El panel (a) muestra la ubicación de la sección transversal, promediada entre 8° y 20°S (en magenta); el panel (b) muestra los cambios durante el período seco, y el panel (c), durante el período húmedo. El color negro representa el perfil topográfico.

4. Conclusiones

Los resultados de este trabajo, a escala anual, coinciden con los supuestos de Aragão (2012): la deforestación reduce la precipitación, disminuye la evapotranspiración y aumenta la escorrentía. A escala estacional, los desequilibrios son más complejos (Wongchuig et al., 2023). Durante la temporada de lluvias, aunque la precipitación cambia poco, la deforestación reduce la capacidad del suelo para retener agua, lo que incrementa la escorrentía. En la estación seca, los efectos se intensifican: disminuyen la precipitación y la evapotranspiración, mientras aumenta la escorrentía y el almacenamiento de agua en el suelo, lo que sugiere una menor extracción hídrica por parte de la vegetación.

Los resultados también revelan que los desequilibrios inducidos por la deforestación pueden exacerbar el estrés hídrico tanto en la atmósfera como en la superficie terrestre, especialmente en la Amazonía suroeste, una de las regiones más vulnerables a estos

cambios (Weng et al., 2018). De hecho, el aumento del VPD, combinado con la disminución del MCWD, convierte a esta región en un núcleo de pérdida de resiliencia forestal (Zemp et al., 2017). Este proceso está vinculado a cambios en la circulación atmosférica y a la reducción del reciclaje de agua por los bosques (Ruiz-Vásquez et al., 2020; Sierra et al., 2023). La deforestación disminuye la evapotranspiración y el aporte de humedad a la atmósfera, lo que puede intensificar el estrés hídrico incluso en otras regiones debido al debilitamiento de las "cascadas de lluvia forestal" y los impactos autoamplificados (Zemp et al., 2017; Staal et al., 2020; Wunderling et al., 2022). Aunque no se analiza a fondo, los resultados sugieren una reducción de los flujos de humedad hacia el Altiplano, lo que implicaría condiciones más secas, dada la estrecha conexión entre los procesos atmosféricos de la Amazonía y los Andes (Segura et al., 2019).

Estos hallazgos contribuyen a las discusiones sobre la retroalimentación vegetación-atmósfera, los impactos de la pérdida de bosques y la intensificación de las

sequías, particularmente en la región suroeste (Weng et al., 2018; Zemp et al., 2017; Staal et al., 2020). Sin embargo, es importante señalar que, debido a la baja resolución horizontal del modelo LMDZ-ORCHIDEE, algunos procesos locales podrían estar subestimados o sobreestimados. Adicionalmente, para reducir las incertidumbres, es necesario incluir y examinar el acoplamiento entre la humedad del suelo y la atmósfera —incluso bajo escenarios de calentamiento global—, un aspecto que no fue considerado en este análisis. Finalmente, persiste la urgencia de comprender mejor estas interacciones y sus implicancias futuras, dentro como fuera de la cuenca, ante la evidencia de cambios abruptos que ya superan la capacidad adaptativa del sistema amazónico.

Referencias

- Albert, J. S., Carnaval, A. C., Flantua, S. G., Lohmann, L. G., Ribas, C. C., Riff, D., Carrillo, J. D., Fan, Y., Figueiredo, J. J. P., Guayasamin, J. M., Hoorn, C., de Melo, G. H., Nascimento, N., Quesada, C. A., Ulloa Ulloa, C., Val, P., Arieira, J., Encalada, A. C., & Nobre, C. A. (2023). Human impacts outpace natural processes in the Amazon. *Science*, 379(6630), eabo5003. <https://doi.org/10.1126/science.abo5003>
- Aragão, L. E. O. C. (2012). The rainforest's water pump. *Nature*, 489(7415), 217–218. <https://doi.org/10.1038/nature11485>
- Barlow, J., França, F., Gardner, T. A., Hicks, C. C., Lennox, G. D., Berenguer, E., Castello, L., Economo, E. P., Ferreira, J., Guénard, B., Gontijo Leal, C., Isaac, V., Lees, A. C., Parr, C. L., Wilson, S. K., Young, P. J., & Graham, N. A. (2018). The future of hyperdiverse tropical ecosystems. *Nature*, 559(7715), 517–526. <https://doi.org/10.1038/s41586-018-0301-1>
- Barlow, J., Berenguer, E., Carmenta, R., & França, F. (2020). Clarifying Amazonia's burning crisis. *Global Change Biology*, 26(2), 319–321. <https://doi.org/10.1111/gcb.14872>
- Beveridge, C. F., Espinoza, J. C., Athayde, S., Correa, S. B., Couto, T. B., Heilpern, S. A., ... & Anderson, E. P. (2024). The Andes–Amazon–Atlantic pathway: A foundational hydroclimate system for social–ecological system sustainability. *Proceedings of the National Academy of Sciences*, 121(22), e2306229121. <https://doi.org/10.1073/pnas.2306229121>
- Builes-Jaramillo, A., & Poveda, G. (2018). Conjoint analysis of surface and atmospheric water balances in the Andes–Amazon system. *Water Resources Research*, 54(5), 3472–3489. <https://doi.org/10.1029/2017WR021338>
- Campoy, A., Ducharne, A., Cheruy, F., Hourdin, F., Polcher, J., & Dupont, J. C. (2013). Response of land surface fluxes and precipitation to different soil bottom hydrological conditions in a general circulation model. *Journal of Geophysical Research: Atmospheres*, 118(19), 10,725–10,739. <https://doi.org/10.1002/jgrd.50627>
- Espinoza, J. C., Jimenez, J. C., Marengo, J. A., Schongart, J., Ronchail, J., Lavado-Casimiro, W., & Ribeiro, J. V. M. (2024). The new record of drought and warmth in the Amazon in 2023 related to regional and global climatic features. *Scientific Reports*, 14(1), 8107. <https://doi.org/10.1038/s41598-024-58782-5>
- Esquivel-Muelbert, A., Baker, T. R., Dexter, K. G., Lewis, S. L., Brienen, R. J., Feldpausch, T. R., Lloyd, J., Monteagudo-Mendoza, A., Arroyo, L., Álvarez-Dávila, E., Higuchi, N., Marimon, B. S., Marimon-Junior, B. H., Silveira, M., Vilanova, E., Gloor, E., Malhi, Y., Chave, J., Barlow, J., & Phillips, O. L. (2019). Compositional response of Amazon forests to climate change. *Global change biology*, 25(1), 39–56. <https://doi.org/10.1111/gcb.14413>
- Flores, B. M., & Staal, A. (2022). Feedback in tropical forests of the Anthropocene. *Global Change Biology*, 28(17), 5041–5061. <https://doi.org/10.1111/gcb.16293>
- Gatti, L. V., Basso, L. S., Miller, J. B., Gloor, M., Gatti Domingues, L., Cassol, H. L., Tejada, G., Aragão, L. E. O. C., Nobre, C., Peters, W., Marani, L., Arai, E., Sanches, A. H., Corrêa, S. M., Anderson, L., Von Randow, C., Correia, C. S. C., Crispim, S. P., & Neves, R. A. (2021). Amazonia as a carbon source linked to deforestation and climate change. *Nature*, 595(7867), 388–393. <https://doi.org/10.1038/s41586-021-03629-6>
- Gutierrez Cori, O. (2024). Relationship and feedback between LULC changes and hydroclimatic variability in Amazonia [Tesis doctoral, Sorbonne Université]. TEL

(thèses-en-ligne).

<https://theses.hal.science/tel-04681119>

Green, J. K., Ballantyne, A., Abramoff, R., Gentine, P., Makowski, D., & Ciais, P. (2022). Surface temperatures reveal the patterns of vegetation water stress and their environmental drivers across the tropical Americas. *Global change biology*, 28(9), 2940-2955.

<https://doi.org/10.1111/gcb.16139>

Guimberteau, M., Ciais, P., Ducharme, A., Boisier, J. P., Dutra Aguiar, A. P., Biemans, H., De Deurwaerder, H., Galbraith, D., Kruijt, B., Langerwisch, F., Poveda, G., Rammig, A., Rodriguez, D. A., Tejada, G., Thonicke, K., Von Randow, C., Von Randow, R. C. S., Zhang, K., & Verbeeck, H. (2017). Impacts of future deforestation and climate change on the hydrology of the Amazon Basin: a multi-model analysis with a new set of land-cover change scenarios. *Hydrology and Earth System Sciences*, 21(3), 1455-1475.

<https://doi.org/10.5194/hess-21-1455-2017>

Hourdin, F., Grandpeix, J. Y., Rio, C., Bony, S., Jam, A., Cheruy, F., Rochetin, N., Fairhead, L., Idelkadi, A., Musat, I., Dufresne, J.-L., Lahellec, A., Lefebvre, M.-P., & Roehrig, R. (2013). LMDZ5B: The atmospheric component of the IPSL climate model with revisited parameterizations for clouds and convection. *Climate Dynamics*, 40(9-10), 2193-2222.

<https://doi.org/10.1007/s00382-012-1343-y>

Hourdin, F., Rio, C., Grandpeix, J. Y., Madeleine, J. B., Cheruy, F., Rochetin, N., Jam, A., Musat, I., Idelkadi, A., Fairhead, L., Foujols, M., Mellul, L., Traore, A., Dufresne, J., Boucher, O., Lefebvre, M., Millour, E., Vignon, E., Jouhaud, J., ... & Ghattas, J. (2020). LMDZ6A: The atmospheric component of the IPSL climate model with improved and better tuned physics. *Journal of Advances in Modeling Earth Systems*, 12(7), e2019MS001892.

<https://doi.org/10.1029/2019MS001892>

Jenkins, C. N., Athayde, S., Beveridge, C. F., Correa, S. B., Espinoza, J. C., Heilpern, S. A., ... & Anderson, E. P. (2025). Global importance of Amazonian freshwaters. *Frontiers in Ecology and the Environment*, e2868.

<https://doi.org/10.1002/fee.2868>

Krinner, G., Viovy, N., de Noblet-Ducoudré, N., Ogée, J., Polcher, J., Friedlingstein, P., ... & Prentice, I. C. (2005). A dynamic global vegetation model for studies of the coupled atmosphere-biosphere system.

Global Biogeochemical Cycles, 19(1), GB1015.

<https://doi.org/10.1029/2003GB002199>

Lapola, D. M., Pinho, P., Barlow, J., Aragão, L. E. O. C., Berenguer, E., Carmenta, R., Liddy, H. M., Seixas, H., Silva, C. V. J., Silva-Junior, C. H. L., Alencar, A. A. C., Anderson, L. O., Armenteras, D., Brovkin, V., Calders, K., Chambers, J., Chini, L., Costa, M. H., Faria, B. L., Fearnside, P. M., ... Walker, W. S. (2023). The drivers and impacts of Amazon forest degradation. *Science*, 379(6630), eabp8622.

<https://doi.org/10.1126/science.abp8622>

Marengo, J. A., Liebmann, B., Grimm, A. M., Misra, V., Silva Dias, P. D., Cavalcanti, I. F. A., ... & Alves, L. M. (2010). Recent developments on the South American monsoon system. *International Journal of Climatology*, 32(1), 1-21.

<https://doi.org/10.1002/joc.2254>

Marca-Zevallos, M. J., Moulatlet, G. M., Sousa, T. R., Schietti, J., Coelho, L. D. S., Ramos, J. F., J. F., Lima Filho, D. de A., Amaral, I. L., de Almeida Matos, F. D., Rincón, L. M., Cardenas Revilla, J. D., Gribel, R., Barbosa, E. M., Miranda, I. P. de A., Bonates, L. C. de M., Guevara, J. E., Salomão, R. P., Ferreira, L. V., Vriesendorp, C., & Costa, F. R. (2022). Local hydrological conditions influence tree diversity and composition across the Amazon basin. *Ecography*, 2022(11), e06125.

<https://doi.org/10.1111/ecog.06125>

Ruiz-Vásquez, M., Arias, P. A., Martínez, J. A., & Espinoza, J. C. (2020). Effects of Amazon basin deforestation on regional atmospheric circulation and water vapor transport towards tropical South America. *Climate Dynamics*, 54(9-10), 4169-4189.

<https://doi.org/10.1007/s00382-020-05223-4>

Segura, H., Junquas, C., Espinoza, J. C., Vuille, M., Jauregui, Y. R., Rabatel, A., Condom, T., & Lebel, T. (2019). New insights into the rainfall variability in the tropical Andes on seasonal and interannual time scales. *Climate dynamics*, 53(1-2), 405-426.

<https://doi.org/10.1007/s00382-018-4590-8>

Sierra, J. P., Espinoza, J. C., Junquas, C., Wongchuig, S., Polcher, J., Moron, V., Fita, L., Arias, P. A., Schrapfner, A., & Pennel, R. (2023). Impacts of land-surface heterogeneities and Amazonian deforestation on the wet season onset in southern Amazon. *Climate Dynamics*, 61(9), 4867-4898.

<https://doi.org/10.1007/s00382-023-06835-2>

Silva-Junior, C. H., Pessôa, A. C., Carvalho, N. S., Reis, J. B., Anderson, L. O., & Aragão, L. E. (2021). The Brazilian Amazon deforestation rate in 2020 is the greatest of the decade. *Nature ecology & evolution*, 5(2), 144-145.
<https://doi.org/10.1038/s41559-020-01368-x>

Soares-Filho, B. S., Nepstad, D. C., Curran, L. M., Cerqueira, G. C., Garcia, R. A., Ramos, C. A., ... & Schlesinger, P. (2006). Modelling conservation in the Amazon basin. *Nature*, 440(7083), 520-523.
<https://doi.org/https://doi.org/10.1038/nature04389>

Staal, A., Tuinenburg, O. A., Bosmans, J. H., Holmgren, M., van Nes, E. H., Scheffer, M., Zemp, D. C., & Dekker, S. C. (2018). Forest-rainfall cascades buffer against drought across the Amazon. *Nature Climate Change*, 8(6), 539-543.
<https://doi.org/10.1038/s41558-018-0177-y>

Staal, A., Flores, B. M., Aguiar, A. P. D., Bosmans, J. H., Fetzer, I., & Tuinenburg, O. A. (2020). Feedback between drought and deforestation in the Amazon. *Environmental Research Letters*, 15(4), 044024.
<https://doi.org/10.1088/1748-9326/ab738e>

Weng, W., Luedeke, M. K. B., Zemp, D. C., Lakes, T., & Kropp, J. P. (2018). Aerial and surface rivers: downwind impacts on water availability from land use changes in Amazonia. *Hydrology and Earth System Sciences*, 22(1), 911-927.
<https://doi.org/10.5194/hess-22-911-2018>

Wongchuig, S., Espinoza, J. C., Condom, T., Junquas, C., Sierra, J. P., Fita, L., Sörensson, A., & Polcher, J. (2023). Changes in the surface and atmospheric water budget due to projected Amazon deforestation: Lessons from a fully coupled model simulation. *Journal of Hydrology*, 625(A), 130082.
<https://doi.org/10.1016/j.jhydrol.2023.130082>

Worden, J., Saatchi, S., Keller, M., Bloom, A. A., Liu, J., Parazoo, N., Fisher, J. B., Bowman, K., Reager, J. T., Fahy, K., Schimel, D., Fu, R., Worden, S., Yin, Y., Gentile, P., Konings, A. G., Quetin, G. R., Williams, M., Worden, H., ... & Barkhordarian, A. (2021). [Rev. of Satellite observations of the tropical terrestrial carbon balance and interactions with the water cycle during the 21st century]. *Reviews of Geophysics* (1985), 59(1).
<https://doi.org/10.1029/2020RG000711>

Wunderling, N., Staal, A., Sakschewski, B., Hirota,

M., Tuinenburg, O. A., Donges, J. F., Barbosa, H. M. J., & Winkelmann, R. (2022). Recurrent droughts increase risk of cascading tipping events by outpacing adaptive capacities in the Amazon rainforest. *Proceedings of the National Academy of Sciences*, 119(32), e2120777119.
<https://doi.org/10.1073/pnas.2120777119>

Zemp, D. C., Schleussner, C. F., Barbosa, H. M., Hirota, M., Montade, V., Sampaio, G., Staal, A., Wang-Erlandsson, L., & Rammig, A. (2017). Self-amplified Amazon forest loss due to vegetation-atmosphere feedbacks. *Nature communications*, 8(1), 14681.
<https://doi.org/10.1038/ncomms14681>

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.

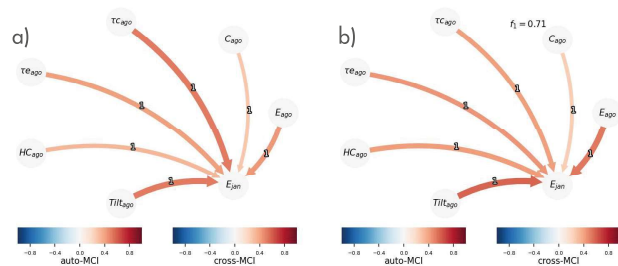


Figura 1. Grafo causal para los datos observacionales (a) y para la mediana de los 30 miembros de la corrida control (periodo 1981-2024) del modelo de IA (b). La métrica F1 se calculó con respecto al grafo causal observacional. Los colores rojos indican relaciones directas mientras que los colores azules 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.

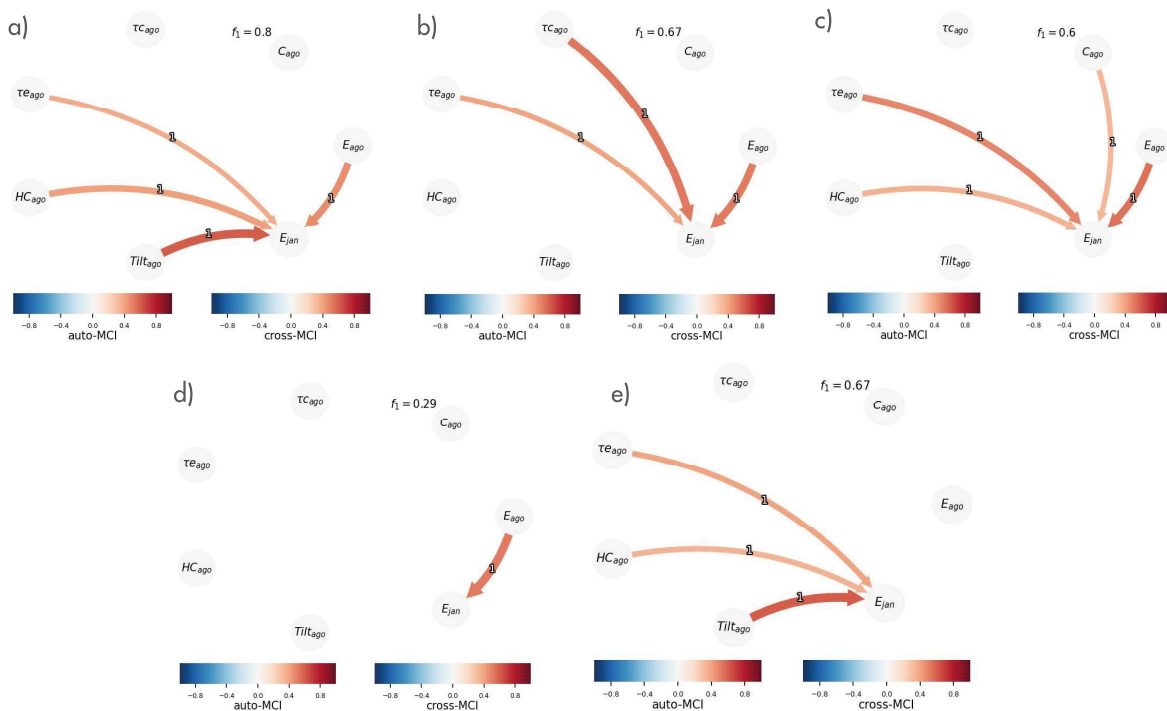


Figura 3. Grafos causales para los experimentos N°1 (a), N°2 (b), N°3 (c), N°4 (d) y N°5 (e), según la Tabla 1, con respecto al grafo causal de la corrida control del modelo de IA. Para cada experimento y el control se considera la mediana de los 30 miembros. El espesor de las flechas indica la confianza 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>

RESUMEN INFORME TÉCNICO

n.º PPR/EL NIÑO-IGP/2025-06

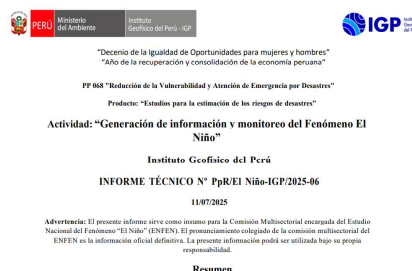
Publicado el 11 de julio de 2025

Para mayo, según el valor del Índice Costero El Niño (ICEN), se mantiene la categoría Neutra (0.18), al igual que los ICEN temporales (ICEN-tmp) de junio (0.04) y julio (0.03). Por otro lado, el promedio de los pronósticos de los modelos climáticos de NMME indican, a la fecha, que las anomalías de la temperatura superficial del mar frente a la costa norte y centro del Perú oscilarían dentro de la categoría Neutra hasta finales del verano de 2026, con una tendencia positiva que conlleva a que el ICEN de mayo se ubique en la categoría Cálida Débil.

En el Pacífico central, el Índice Oceánico Niño (ONI, por sus siglas en inglés) de mayo (-0.11), así como sus temporales de junio (-0.09) y julio (-0.19), corresponden a la categoría Neutra. Según el promedio de los pronósticos generados por los modelos climáticos de NMME, se prevé condiciones dentro de la categoría Neutra hasta agosto, entre setiembre y diciembre se esperarían anomalías negativas que alcanzarían la categoría Fría Débil.

Finalmente, para el verano 2026 se esperan condiciones normales.

El informe técnico completo se encuentra disponible en: <https://bit.ly/4r7iAae>



Advertencia: El presente informe sirve como insumo para la Comisión Multisectorial encargada del Estudio Nacional del Fenómeno "El Niño" (ENFEN). El pronunciamiento colegiado de la comisión multisectorial del ENFEN es la información oficial definitiva. La presente información podrá ser utilizada bajo su propia responsabilidad.

COMUNICADO OFICIAL

EFEN n.º 08 - 2025



COMISIÓN MULTISECTORIAL ENCARGADA
DEL ESTUDIO NACIONAL DEL FENÓMENO "EL NIÑO" – ENFEN
Decreto Supremo n.º 007-2017-PRODUCE

Estado del sistema de alerta: **No activo**¹

Publicado el 15 de julio de 2025

La Comisión Multisectorial del ENFEN, en base al análisis de las condiciones oceánicas y atmosféricas observadas hasta la fecha, así como de los pronósticos de los modelos climáticos nacionales e internacionales, mantiene el Estado del Sistema de Alerta ante El Niño Costero/La Niña Costera en "No Activo" para la región Niño 1+2 (Figura 1), que incluye la costa norte y centro del país. Se estima que es más probable que la condición neutra² continúe hasta marzo de 2026. Asimismo, para la temporada de verano (diciembre 2025 a marzo 2026), se proyecta una probabilidad de 63 % de condiciones neutras (Tabla 1, Figura 2).

En el Pacífico Central (región Niño 3.4, Figura 1), también se mantienen la condición neutra, con una probabilidad del 58 % de que dicha situación continúe hasta el verano 2026³. (Tabla 2, Figura 2).

Para el trimestre julio – setiembre de 2025, se espera que las temperaturas mínimas en la costa central y sur registren valores entre normales y ligeramente por debajo de lo habitual, mientras que las temperaturas máximas se mantendrían dentro de lo normal. Asimismo, se espera que las regiones andina y amazónica registren precipitaciones dentro de sus rangos normales o superiores a lo normal. En cuanto al pronóstico hidrológico³, se prevé que en los ríos de la vertiente occidental norte y centro predominen caudales normales.

En cuanto a los recursos pesqueros, para las próximas semanas se espera que en la región norte-centro del litoral la anchoveta empiece a mostrar un incremento progresivo de los procesos de maduración gonadal. En el caso de los recursos transzonales, se prevé que continúe la disponibilidad de caballa y bonito a lo

¹ No activo: Ocurre cuando se presentan condiciones neutras o, cuando de acuerdo al análisis de las condiciones oceánicas y atmosféricas observadas y de la predicción de los modelos climáticos, el pronóstico probabilístico mensual del Índice Costero El Niño (ICEN) indica que la probabilidad de la categoría neutra superará el 50% durante al menos los siguientes tres meses consecutivos (Nota Técnica ENFEN 02-2024; <https://enfen.imarpe.gob.pe/download/nota-tecnica-enfen-02-2024-sistema-de-alerta-ante-el-nino-y-la-nina-costera/>)

² Las condiciones mensuales se establecen en base al valor del ICEN. En el caso de la condición neutra, esta corresponde cuando el valor del ICEN es mayor o igual que -0,7 y menor o igual que +0,5 (Nota Técnica ENFEN 01-2024; <https://enfen.imarpe.gob.pe/download/notatecnica-enfen-01-2024-definicion-operacional-de-los-eventos-el-nino-costero-y-la-nina-costera-en-el-peru/>). Para el caso del Pacífico central, la condición neutra se considera cuando el valor del ONI es mayor que -0,5 y menor que +0,5 (https://origin.cpc.ncep.noaa.gov/products/analysis_monitoring/ensostuff/ONI_v5.php).

³ <https://www.senamhi.gob.pe/load/file/02694SENA-59.pdf>

⁴ <https://www.senamhi.gob.pe/?p=aviso-meteorologico>

largo del litoral peruano.

Se recomienda a los tomadores de decisiones de los tres niveles de gobierno, así como los sectores productivos y de servicios, mantener activos sus mecanismos de prevención y reducción del riesgo antes que se inicie el periodo de lluvias. Asimismo, se sugiere dar seguimiento constante a los avisos meteorológicos⁴ y pronósticos estacionales⁵, para las acciones correspondientes. Por otro lado, se exhorta a la población a mantenerse informada a través de las fuentes oficiales del ENFEN.

La Comisión Multisectorial del ENFEN continuará monitoreando la evolución de las condiciones oceánicas, atmosféricas y biológicas-pesqueras, y actualizando las perspectivas. La emisión del próximo

Comunicado Oficial ordinario será el viernes 15 de agosto de 2025.

- Para más información, consultar el Informe Técnico en el siguiente enlace: <https://bit.ly/3XCq9bi>

INSTITUCIONES MIEMBROS DEL ENFEN



⁵ <https://www.senamhi.gob.pe/?p=pronostico-climatico&pro=trimestral>



-  @igp.peru
-  @igp_peru
-  @igp.peru
-  @igp_videos
-  @institutogeofisicodelperu
-  @igp.peru