

Inteligencia artificial para modelar y comprender fenómenos meteorológicos y climáticos en la Provincia De Bolívar, Ecuador

Artificial intelligence for modeling and understanding meteorological and climate phenomena in the Province of Bolívar, Ecuador

<https://doi.org/10.5281/zenodo.20291810>

AUTORES:

Deysi Guanga¹

Henry Vallejo²

Galuth García³

Danilo Barrerno⁴

DIRECCIÓN PARA CORRESPONDENCIA: dguanga@ueb.edu.ec

Fecha de recepción: 01 / 11 / 2025

Fecha de aceptación: 14 / 11 / 2025

RESUMEN

En los últimos años, la inteligencia artificial (IA) ha tenido un profundo impacto en varios campos, incluidas las ciencias del sistema terrestre, al mejorar el pronóstico del tiempo, la emulación de modelos, la estimación de parámetros y la predicción de eventos climáticos. Este artículo revisa cómo se utiliza la IA para analizar eventos climáticos, como inundaciones y sequías, destacando la importancia de crear modelos de IA precisos, transparentes y confiables en la provincia de Bolívar, Ecuador. Se revisan las técnicas de aprendizaje automático (ML) y aprendizaje profundo (DL) para la detección de eventos como inundaciones y sequías, la predicción de su impacto y la atribución de sus causas. A través de la contextualización de datos climáticos históricos de la región, se demuestra el potencial de la IA para mejorar los sistemas de alerta temprana y la toma de decisiones. Se discuten también los desafíos asociados a la calidad de los datos, la interpretabilidad de los modelos y su

¹ <https://orcid.org/0000-0002-6548-5585>, Universidad Estatal de Bolívar, dguanga@ueb.edu.ec

² <https://orcid.org/0000-0002-3604-5572>, Universidad Estatal de Bolívar, hvallejo@ueb.edu.ec

³ <https://orcid.org/0000-0001-8692-4017>, Universidad Estatal de Bolívar, ggarcia@ueb.edu.ec

⁴ <https://orcid.org/0000-0001-7557-4453>, Universidad Estatal de Bolívar, dbarreno@ueb.edu.ec

integración operativa. Finalmente, se presentan ejemplos de visualización de datos de temperatura y humedad para la provincia de Bolívar como resultado del proyecto de investigación desarrollado por la UEB, subrayando la necesidad de soluciones de IA que sean precisas, confiables y adaptadas a las necesidades locales para fortalecer la resiliencia ante los crecientes riesgos climáticos.

Palabras Clave: *Aprendizaje Automático, Cambio Climático, Inteligencia Artificial, Modelado Climático*

ABSTRACT

In recent years, artificial intelligence (AI) has had a profound impact across numerous fields, including Earth system sciences, by improving weather forecasting, model emulation, parameter estimation, and the prediction of climatic events. This article reviews how AI is employed to analyze climate-related events—such as floods and droughts—highlighting the importance of developing accurate, transparent, and reliable AI models in Bolívar Province, Ecuador. Machine learning (ML) and deep learning (DL) techniques for detecting events like floods and droughts, predicting their impacts, and attributing their causes are examined. By contextualizing historical climate data from the region, the study demonstrates AI's potential to enhance early warning systems and support decision-making. Challenges related to data quality, model interpretability, and operational integration are also discussed. Finally, examples of temperature and humidity data visualizations for Bolívar Province are presented as outcomes of the research project conducted by the UEB, underscoring the need for AI solutions that are accurate, trustworthy, and tailored to local needs to strengthen resilience against escalating climate risks.

Keywords: *Machine Learning, Climate Change, Artificial Intelligence, Climate Modeling*

INTRODUCCIÓN

La frecuencia e intensidad de los eventos climáticos han aumentado globalmente, presentando desafíos significativos para la estabilidad social, la seguridad económica y la integridad ecológica. La provincia de Bolívar, con su diversa topografía que abarca desde zonas subtropicales hasta páramos andinos, es particularmente vulnerable a fenómenos como inundaciones, deslizamientos de tierra y sequías (Weyn et al., 2020). Modelar y comprender estos eventos es fundamental para desarrollar estrategias de mitigación y adaptación efectivas.

Tradicionalmente, la predicción meteorológica se ha basado en modelos numéricos que, si bien son potentes, requieren inmensos recursos computacionales. La Inteligencia Artificial (IA) ha surgido

como una alternativa prometedora, ofreciendo la capacidad de analizar grandes volúmenes de datos climáticos para detectar patrones, predecir eventos y explicar sus causas subyacentes con una eficiencia sin precedentes (Meehl et al., 2014).

Objetivo principal de este trabajo es proponer y validar teóricamente un marco metodológico basado en Inteligencia Artificial (IA) para la detección, predicción y comunicación de eventos climáticos extremos. A través del análisis sintético de estudios de caso (sequías, olas de calor, incendios forestales e inundaciones), se busca establecer una hoja de ruta técnica que mejore la preparación ante desastres y la reducción de riesgos, con especial énfasis en la aplicabilidad de estas herramientas en contextos geográficos complejos como la provincia de Bolívar.

METODOLOGÍA

La investigación se desarrolla mediante un diseño de síntesis metodológica de vanguardia, estructurado en cuatro fases que transforman el conocimiento científico actual en un modelo operativo:

1. Sistematización del Pipeline General de IA

Se define un flujo de trabajo iterativo (Pipeline) que constituye la base del análisis. Esta fase metodológica no solo contempla la recopilación de datos multimodales (satelitales, reanálisis y texto), sino que establece el ciclo de retroalimentación donde los resultados de la IA informan la redefinición de hipótesis y la mejora de la captura de datos.

2. Análisis Comparativo de Técnicas por Tipología de Evento

Para responder a los objetivos específicos, la metodología emplea un Análisis de Capacidad Técnica basado en cuatro dominios críticos, evaluando las herramientas de IA que mejor se adaptan a cada uno:

- Sequías: Integración de datos multimodales y XAI (*Integrated Gradients*) para predecir dinámicas de superficie.
- Olas de Calor: Aplicación de técnicas de agrupación y reducción de dimensionalidad en datos heterogéneos.
- Incendios Forestales: Uso de inferencia causal para entender fenómenos complejos como las nubes *pyrocumulonimbus* (pyroCbs).

- Inundaciones: Implementación de modelos híbridos (física + DL) para el modelado de precipitación-escorrentía.

3. Marco de Evaluación de Confiabilidad y Explicabilidad

Se establece un protocolo de verificación mediante IA Explicable (XAI) y Cuantificación de la Incertidumbre (UQ). Este paso metodológico es crucial para diferenciar entre correlaciones estadísticas y relaciones causales reales, permitiendo que el marco propuesto sea auditable por tomadores de decisiones y expertos en gestión de riesgos.

4. Protocolo de Operacionalización y "Última Milla"

Finalmente, la metodología integra un componente de Comunicación de Riesgos Asistida por IA. Se evalúa la viabilidad de utilizar Modelos de Lenguaje de Gran Escala (LLM) y visualizaciones 3D fotorrealistas para transformar datos técnicos en alertas comprensibles y personalizadas para la población, superando la brecha entre el pronóstico y la acción ciudadana.

RESULTADOS

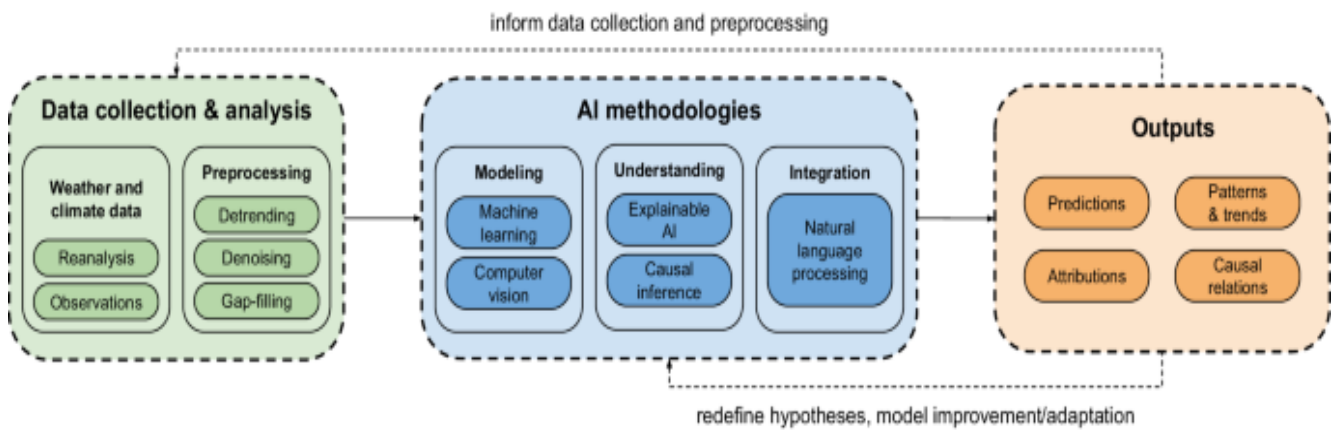
La Inteligencia Artificial (IA) ha surgido como una herramienta transformadora para la detección, la predicción, el análisis de eventos climáticos y la generación de eventos en el peor de los casos, y promete avances en estudios de atribución, explicación y comunicación del riesgo. Las capacidades del aprendizaje automático (ML) y el aprendizaje profundo (DL), en particular, en combinación con técnicas de visión por computadora, están avanzando en la detección y localización de eventos mediante la explotación de datos climáticos, como el reanálisis y las observaciones.

Las técnicas modernas para cuantificar la incertidumbre son necesarias para avanzar en la evaluación del riesgo del cambio climático. El uso de conjuntos en combinación con modelos de IA ha progresado en el campo de la atribución de climáticos, la identificación de patrones, tendencias y análogos climáticos (Brenowitz & Bretherton, 2018).

Los recientes aportes investigativos han explorado las aplicaciones de IA para fenómenos meteorológicos y climáticos, cubriendo temas como el aprendizaje profundo para pronósticos de mediano alcance, predicciones sub estacionales a decenales y causalidad y explicabilidad en eventos atmosféricos climáticos (Chen et al., 2020). Sin embargo, carecen de una visión holística que incluya los impactos ambientales y sociales más amplios de estos eventos.

La línea general de análisis de eventos climáticos impulsada por IA (cf. Fig. 1) encapsula todo el flujo de trabajo, desde la recopilación y el preprocesamiento de datos hasta la generación de resultados como predicciones, patrones, tendencias, atribuciones climáticas y relaciones causales (Höhlein et al., 2020).

Figura. 1. Una canalización general de análisis de eventos climáticos impulsada por la Inteligencia Artificial (IA)



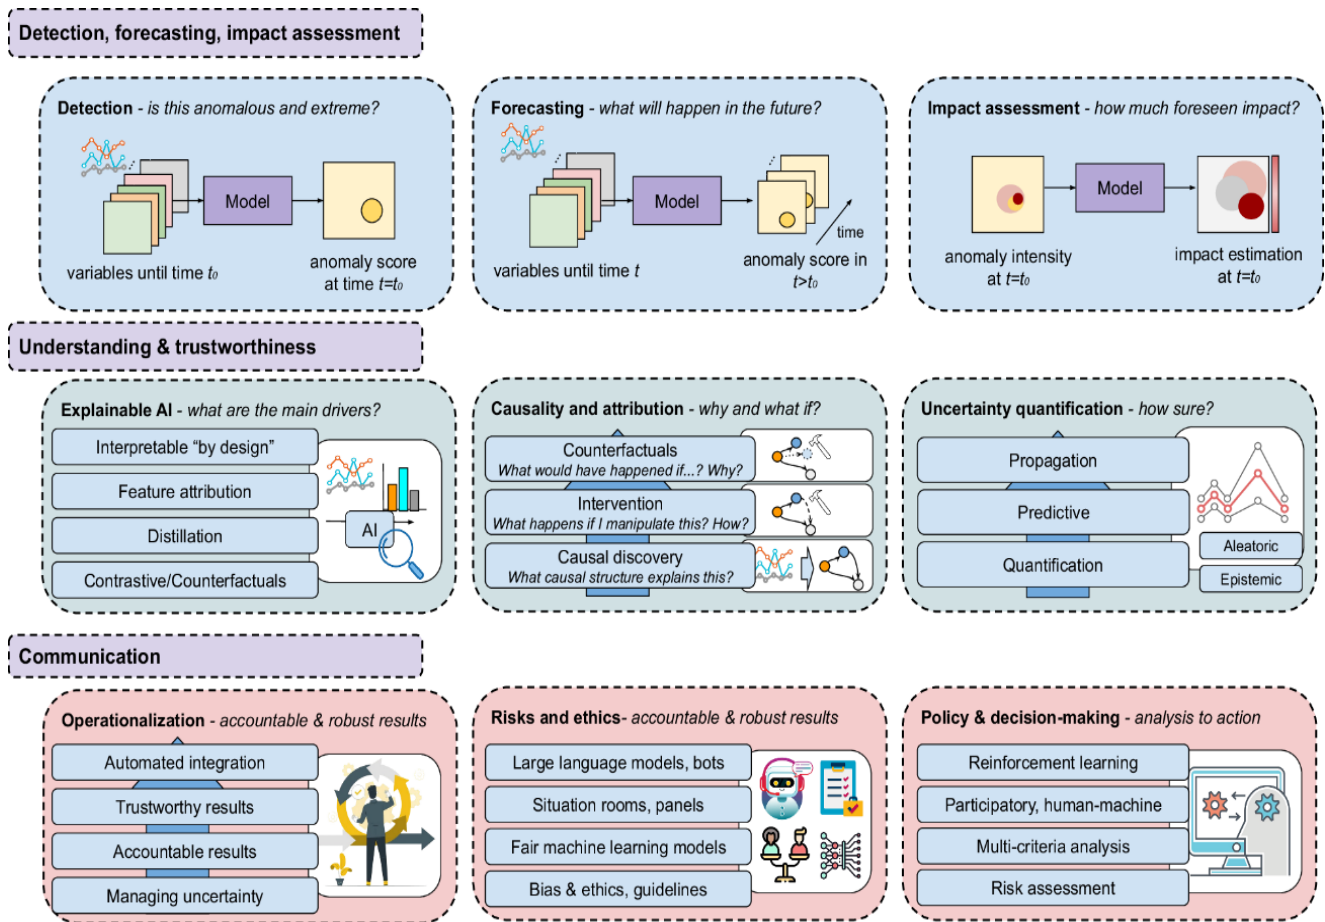
Los diferentes componentes en el modelado y la comprensión de eventos climáticos utilizando metodologías de IA están interconectados, destacando el flujo desde la recopilación y el análisis de datos hasta la información / resultados procesables (Chattopadhyay, Nabizadeh, et al., 2020).

Revisión de los métodos de IA

Modelado de eventos

Las metodologías de IA para el modelado de eventos climáticos se pueden clasificar en tareas de detección, predicción y evaluación de impacto. Gracias a la aparición y el éxito de la DL, todas estas tareas pueden abordarse mediante el diseño de modelos basados en datos que exploten las características de los datos de la Tierra espaciotemporales y de múltiples fuentes, desde las variables climáticas hasta las mediciones in situ y las imágenes de teledetección por satélite (Zheng et al., 2018)

Figura 2. Componentes en una tubería de Inteligencia Artificial (IA)



La IA explota principalmente la observación espaciotemporal de la Tierra, el reanálisis y los datos climáticos para responder a las preguntas "qué" (fila superior): detección de eventos, predicción y evaluación de impacto.

La IA también se puede utilizar para comprender los eventos y, por lo tanto, responder a las preguntas de "qué pasaría si", "por qué" y "qué tan seguro" y hace uso de la IA explicable (XAI) para identificar los impulsores relevantes de los eventos, la causalidad para comprender el sistema, estimar los efectos causales y los impactos, e imaginar escenarios contra fácticos para la estimación de la atribución y la incertidumbre para cuantificar la confianza y la solidez para la toma de decisiones (Boukabara et al., 2019). La comunicación de eventos climáticos y sus impactos puede beneficiarse del aprendizaje estadístico/automático al mejorar la operacionalización, garantizar narrativas justas y equitativas e integrar modelos de lenguaje en las salas de situación para mejorar la toma de decisiones (Schultz et al., 2021).

Detección

Detectar e identificar eventos climáticos geográficamente a lo largo del tiempo es fundamental para evaluar los impactos y mejorar las estrategias de anticipación y mitigación. Además, la detección es el primer paso para descubrir patrones subyacentes y comprender mejor sus procesos y mecanismos de generación (Rasp et al., 2020).

Los métodos estadísticos clásicos, a menudo pasan por alto los eventos identificados por los expertos o los enfoques de detección basados en el impacto y no logran capturar la complejidad del evento, ya que se centran en variables individuales y pasan por alto los umbrales de peligro que varían en el espacio y el tiempo. Para abordar esta limitación, las metodologías de IA pueden ayudar a conciliar el conocimiento experto con los enfoques basados en datos, ya que capturan regularidades y relaciones matizadas en grandes volúmenes de datos observacionales, consideran múltiples variables juntas, capturan interacciones complejas y evalúan correlaciones espaciales temporales y anisotrópicas de largo alcance (Li, 2019).

Canonical ML trata el problema de detección como un problema de clasificación de una clase o un problema de detección de valores atípicos. De este modo, se aplican muchos métodos y están disponibles en paquetes de software (Kim et al., 2020).

Los avances recientes incluyen el aprendizaje profundo para la segmentación y detección de ciclones tropicales y ríos atmosféricos (AR) en el resultado del modelo climático de alta resolución y la localización semi supervisada de climáticos. Alternativamente, los modelos basados en la reconstrucción (por ejemplo, con autocodificadores) se optimizan para reconstruir con precisión las instancias de datos normales y, por lo tanto, los climáticos se asocian con grandes errores de reconstrucción (Maiello et al., 2017).

Finalmente, los enfoques probabilísticos intentan identificar climáticos mediante la estimación de la función de densidad de probabilidad de datos (PDF) o cuantiles específicos de la misma (Rosenfeld & Lensky, 1998). Sin embargo, los enfoques estándar de la teoría del valor climático (EVT) luchan con datos de series de tiempo cortas, no linealidades y procesos no estacionarios. Los modelos probabilísticos alternativos (ML) se han basado en re pronósticos estacionales meteorológicos e hidrológicos sustitutos, procesos gaussianos y medidas de dependencia no lineal y gaussianización multivariada (G. Zheng et al., 2020). Los enfoques probabilísticos en ML también permiten derivar

intervalos de confianza para las predicciones o incluso optimizarse a ciertos niveles de interés (altos, climáticos) utilizando regresión cuantil, enfoques de calibración de cola o EVT multivariante.

Predicción

El diseño de sistemas predictivos que modelen con precisión los eventos climáticos es esencial para anticipar los efectos de futuros eventos climáticos y proporcionar información crítica para que los responsables de la toma de decisiones eviten daños y pérdidas (O’Gorman & Dwyer, 2018). Las predicciones espaciales y temporales tienen como objetivo proporcionar una estimación cuantitativa del valor futuro del estado de la Tierra.

Recientemente, las técnicas de predicción basadas en DL han ganado popularidad por su capacidad para procesar grandes volúmenes de datos, capturar relaciones no lineales complejas y reducir la ingeniería manual de características. Estos beneficios han llevado a la creación de modelos globales que se generalizan en varios lugares, como se ve en las predicciones de inundaciones e incendios forestales. Las técnicas híbridas basadas en IA integradas en los modelos climáticos pueden mejorar las predicciones, como en la predicción de sequías y la reducción de la escala de las precipitaciones convectivas extremas.

Los modelos probabilísticos, a diferencia de los deterministas, se centran en predecir la distribución de probabilidad de los estados futuros de las variables. Se ha enfatizado la importancia de los pronósticos probabilísticos para las olas de calor extremas (Urbich et al., 2020).

Evaluación de impacto

Estimar los efectos de los eventos climáticos en la sociedad, la economía y el medio ambiente es crucial para transmitir las posibles consecuencias futuras al público, a los responsables de la formulación de políticas y a todas las disciplinas. La evaluación de impacto implica comprender cómo reacciona un sistema a los forzamientos de eventos climáticos (Scher, 2018). A diferencia de la detección y predicción de eventos climáticos, la atención se centra aquí en los resultados relacionados con el impacto, como el número de lesiones, los hogares afectados o las pérdidas de cultivos.

En los últimos años, ha habido un creciente interés en predecir el estado de la vegetación utilizando ML, como una forma de estimar el impacto de los climáticos en la evolución de la variable de estado de la vegetación. Los métodos de avances recientes han utilizado redes de estado de eco, basadas en

memoria convolucional a largo plazo a corto plazo (basadas en ConvLSTM) y transformadores⁴ utilizando datos climáticos y de teledetección de alta resolución (Scher, 2018).

Otra forma de abordar la evaluación de impacto con ML es analizar los cambios en el PDF a lo largo del tiempo. Este enfoque permite cuantificar el impacto de diferentes eventos, lo que puede utilizarse para mejorar nuestra comprensión de los factores que impulsan la vulnerabilidad, como el desplazamiento de la población. Alternativamente, el impacto de los eventos climáticos se puede detectar analizando la cobertura de noticias basada en el procesamiento del lenguaje natural (NLP) y, más recientemente, en los LLM (Dueben & Bauer, 2018).

Comprensión y confiabilidad de eventos climáticos

Sin embargo, todos los enfoques anteriores se centran en las preguntas de "qué", "cuándo" y "dónde", no en las de "por qué", "qué pasaría si" y "qué tan seguras". Estas últimas preguntas son esenciales para lograr un ML confiable, ya que de ello dependen las decisiones de alto riesgo que afectan la seguridad pública, la salud, la infraestructura y la asignación de recursos. Disciplinas como XAI y cuantificación de incertidumbre (UQ) ofrecen métodos para hacer que la IA sea más confiable y confiable (ver Fig. 2). Estos enfoques no solo nos ayudan a interpretar las predicciones de los modelos de IA, sino que también mejoran nuestra comprensión de los eventos climáticos en sí (Meehl et al., 2014). Técnicas como la inferencia causal y la atribución de eventos climáticos complementan aún más a XAI y UQ al comprender los mecanismos detrás de estos eventos, cruciales para mejorar los modelos de IA y ganar confianza en el proceso de toma de decisiones.

IA explicable

Muchos modelos son transparentes e interpretables por diseño, como los modelos lineales o los árboles de decisión. Aun así, es posible que no funcionen bien en problemas complejos y rara vez se emplean en eventos climáticos (véase la Tabla 1). XAI tiene como objetivo revelar el proceso de toma de decisiones de los modelos de IA. XAI también facilita la depuración, la mejora de los modelos y la recopilación de información científica al revelar el funcionamiento del modelo, las relaciones aprendidas y los sesgos (Moraux et al., 2019).

Los enfoques XAI más utilizados se basan en métodos de destilación o atribución de características independientes del modelo, cf. Fig. 2. Los métodos de destilación, como las explicaciones aditivas de SHapley y las explicaciones agnósticas de modelos interpretables locales, crean modelos sustitutos y

se han utilizado ampliamente en geociencias y ciencias climáticas. Los métodos de atribución de características, como el gráfico de dependencia parcial (PDP) o el mapa de activación de clases basado en gradiente, resaltan características importantes perturbando las entradas o utilizando la retro propagación. Los enfoques recientes explican los modelos de DL utilizando la atención en la predicción de sequías y los prototipos para explicar la localización de eventos (Ricchi et al., 2021).

XAI también se ha utilizado para evaluar las predicciones climáticas y, por lo tanto, ofrece un enfoque agnóstico basado en datos para la intercomparación de modelos y datos. Sin embargo, la mayoría de los métodos XAI, particularmente los enfoques post-hoc, se aproximan al modelo subyacente, y la falta de una definición clara de una explicación "suficiente" complica su evaluación. Más información sobre las limitaciones de XAI está disponible en "Desafíos del modelo" (Palmer & Stevens, 2019).

Causalidad y atribución

La causalidad o inferencia causal tiene como objetivo descubrir las relaciones subyacentes entre las variables para determinar no solo qué influye en un resultado, sino también por qué y en qué medida. Esto implica dos tareas principales: el descubrimiento causal, que identifica la estructura de las dependencias causales, y la estimación del efecto causal, que cuantifica el impacto de causas específicas en los resultados (Capecchi et al., 2021). Conocer las relaciones causales nos permite responder preguntas como "¿Qué cambiaría con quemas controladas o barreras contra inundaciones?" (intervenciones) o "¿Qué pasaría si no hubiera emisiones antropogénicas?" (contras fácticos). Para eventos climáticos, los métodos de inferencia causal más extendidos no se pueden aplicar directamente, ya que los supuestos tradicionales de normalidad y valores atípicos leves no se cumplen, y las dependencias pueden diferir entre los climáticos y la cola de la distribución (Tabla 1). Esto ha motivado trabajos recientes que se ocupan del descubrimiento causal para el análisis de eventos climáticos, proporcionando diferentes marcos para comprender las dependencias y estructuras causales en valores climáticos (Shrestha & Mahmood, 2019), con aplicaciones en, por ejemplo, la descarga de ríos. Otra línea de trabajo relevante se centra en responder preguntas contra fácticas para eventos climáticos, que se vincula con la atribución de eventos climáticos.

La atribución de eventos climáticos (EEA) cuantifica la influencia de los forzamientos antropogénicos (como las emisiones de gases de efecto invernadero) en la probabilidad de eventos climáticos y, por lo tanto, tiene como objetivo responder a una pregunta intrínsecamente causal (Huang et al., 2009). Los métodos utilizan simulaciones numéricas con Modelos de Circulación General (GCM) para comparar sus probabilidades en condiciones observadas (el mundo fáctico) y un escenario hipotético sin

emisiones humanas (el mundo contra fáctico); o métodos estadísticos aplicados a los datos observacionales. Existen dos puntos de vista principales: la EEA probabilística emplea métodos estadísticos cuantitativos para estimar esta probabilidad (por ejemplo, la EE es 00 veces más probable debido a las emisiones humanas), mientras que los enfoques argumentales simulan la evolución de la EE bajo diferentes forzamientos para recopilar una declaración de atribución basada en el proceso (por ejemplo, el 50% de la magnitud de una EE se explica por la variabilidad natural).

Idealmente, ambos métodos deben combinarse para proporcionar una comprensión completa. Cuando se trata de la atribución de tendencias a largo plazo, se han desarrollado conjuntos de redes neuronales para emular los GCM. Los modelos de redes neuronales predicen ahora con éxito el año basándose en la temperatura anual global o el campo de precipitación en las condiciones actuales, detectando y/o atribuyendo eficazmente tendencias a largo plazo (Cullen et al., 1997), lo que da lugar a algunos patrones de atribución XAI interesantes (que no deben confundirse con la AEMA, véase «IA explicable»). En este contexto, la huella digital del cambio climático se ha identificado en los patrones globales diarios de temperatura y humedad, y precipitación.

El trabajo más reciente utiliza estos enfoques estadísticos y de ML para detectar tendencias en eventos climáticos como fuertes precipitaciones. Sin embargo, la literatura sobre los usos de la IA para la atribución climática formal de eventos climáticos aún es escasa. Sin embargo, los estudios individuales han comenzado a desarrollar contra fácticos sobre el cambio climático para las olas de calor, mientras que la IA, hasta ahora, se utiliza más ampliamente para la detección, predicción e identificación de impulsores de las olas de calor (véase el estudio de caso sobre las olas de calor) (Clark et al., 2016). En términos más generales, los avances recientes en la emulación del tiempo y el clima con IA sugieren que los emuladores climáticos pueden desempeñar un papel importante en futuros estudios de atribución climática (He et al., 2021).

Cuantificación de la incertidumbre

Incluso equipado con métodos explicativos y causales, sigue siendo crucial evaluar la confianza de las decisiones del modelo de IA, ya que las advertencias o decisiones inexactas podrían afectar a la seguridad y los recursos. Comprender las fuentes de incertidumbre es importante para informar y desenredar la incertidumbre inherente (aleatoria) del fenómeno meteorológico de la falta de conocimiento en la incertidumbre (epistémica) del modelo (Dewitte et al., 2021). Se puede reducir este último con más datos y suposiciones adicionales, pero no el primero. Los enfoques de DL con UQ han demostrado ser prometedores para eventos climáticos recientemente.

La última milla: operacionalización, comunicación, ética y toma de decisiones

Los componentes anteriores (métodos y técnicas) en la tubería de IA deben ser operacionalizados, ser sólidos, responsables y justos, para que en última instancia sirvan al propósito de la formulación de políticas basadas en evidencia (ver Fig. 2 [fila inferior]) (Villares et al., n.d.).

Operacionalización

La operacionalización necesita estrictamente la capa anterior (XAI, causalidad, UQ) para mejorar y rendir cuentas a las explicaciones de las predicciones en los sistemas de alerta temprana (SAT) y para mejorar la gestión del riesgo de desastres. La calibración de los modelos de ML, especialmente cuando se combina con la estimación de la incertidumbre, alinea las probabilidades predichas para reflejar la probabilidad real de resultados climáticos, mejorando la confiabilidad y la interpretabilidad esenciales para la toma de decisiones informadas (Lam et al., 2023). Una mala calibración puede llevar a decisiones equivocadas, como sobreestimar o subestimar la probabilidad de eventos críticos.

Comunicación de riesgos y aspectos éticos

Iniciativas globales como el Protocolo Común de Alertas han estandarizado los datos de alerta, lo que permite alertas oportunas. Sin embargo, la efectividad de estos sistemas depende de la inclusión y la adaptabilidad a las diversas necesidades de la comunidad (Gonzalez-Calabuig et al., 2024). Lograr esto a nivel mundial sigue siendo un desafío, ya que los modelos centralizados son más fáciles y baratos, pero carecen de sensibilidad local. La IA puede abordar esto identificando poblaciones en riesgo, optimizando la claridad del mensaje, seleccionando canales de comunicación efectivos y superando las limitaciones de los métodos tradicionales de talla única a escala.

Sin embargo, la historia muestra que incluso los pronósticos procesables pueden fallar si no se comunican adecuadamente (Vicente & Li, n.d.). Por ejemplo, a pesar de las predicciones de que la tormenta mediterránea Daniel tocaría tierra con cuatro días de anticipación, la falta de comunicación efectiva contribuyó al trágico resultado en Libia, con graves víctimas y desplazamiento. El desafío de las falsas alarmas en el contexto de EWS es un desafío importante, ya que pueden conducir a una "fatiga de advertencia", donde el público se vuelve insensible a las alertas y puede ignorar las advertencias cruciales durante emergencias reales.

Abordar este problema requiere mejorar la precisión y la confianza en los modelos predictivos, refinar las estrategias de comunicación e involucrar a la comunidad (Vicente & Li, n.d.). La IA mejora la

comunicación de riesgos al permitir la personalización de mensajes y mejorar la claridad, especialmente en sistemas en tiempo real. Sin embargo, incluso si la IA puede ayudar a gestionar y evaluar el riesgo en los sistemas de alerta temprana, creemos que pasar de la advertencia a la decisión, especialmente cuando se trata de escenarios altamente inciertos, requerirá ciencia de la comunicación, psicología del comportamiento y tomadores de decisiones valientes (Gonzalez-Calabuig et al., 2024).

Ética en modelos y datos de IA

La gobernanza de la ética de la IA exige que los sistemas respeten la dignidad humana, garanticen la seguridad y apoyen los valores democráticos. El despliegue de la IA para ayudar a gestionar los climáticos implica varios principios fundamentales: garantizar la equidad, mantener la privacidad y lograr la transparencia (Clark et al., 2016).

En este contexto, el aumento de los LLM aumenta los riesgos éticos como datos obsoletos o inexactos, sesgos, errores y desinformación, a menudo oscurecidos por su vasto entrenamiento en datos web. Además, los modelos actuales de IA (como la IA generativa y los LLM) a menudo se basan en grandes conjuntos de datos, por lo que existe el riesgo de fuertes sesgos si estos conjuntos de datos no son representativos (Aligo et al., 2009). El muestreo y el análisis espacial son vitales para recopilar datos representativos, justos e imparciales desde el punto de vista geográfico y ambiental. La IA mejora los SAT al permitir la rápida difusión de alertas personalizadas adaptadas a ubicaciones específicas y factores de riesgo individuales como la proximidad a llanuras aluviales o zonas de incendios forestales, lo que garantiza que las advertencias sean comprensibles y relevantes para todos.

Lograr la inclusión de las comunidades afectadas, especialmente en el Sur Global, sigue siendo un desafío importante, ya que los modelos centralizados de "talla única" suelen ser más simples y baratos de implementar, pero menos efectivos para abordar los matices locales (Huang et al., 2009). El diseño de sistemas de IA, basados en modelos de lenguaje grande ajustados a las comunidades locales con usuarios al tanto, ofrece excelentes oportunidades para superar la "talla única" y al mismo tiempo ser eficiente.

Política y toma de decisiones

Incluso si es asistido por IA, los operadores humanos están a cargo de implementar la decisión final. Esto implica apoyar a los usuarios finales para que aprovechen al máximo la información generada. Este valor operativo suele ser específico del problema y depende de la dinámica dominante del sistema

y de los sectores socioeconómicos considerados. Sin embargo, cuantificar este valor podría no ser sencillo, ya que una predicción más precisa no implica necesariamente una mejor decisión por parte de los usuarios finales (Shrestha & Mahmood, 2019). Cuando se dispone de múltiples pronósticos de diferentes sistemas, los usuarios deben abordar una serie de problemas en los que la IA puede ser útil, incluida la selección del producto de pronóstico, el tiempo de entrega, la agregación de variables, la corrección de sesgos y cómo hacer frente a la incertidumbre del pronóstico.

Integración de la tubería en la Fig. 1 con modelos de impacto que aprovechan los algoritmos de aprendizaje por refuerzo para simular una toma de decisiones óptima puede ayudar a cuantificar cómo la información mejorada por IA sobre eventos climáticos se traduce en mejores decisiones (He et al., 2021). El diseño conjunto de modelos de impacto a través de procesos participativos, que incluyen a los usuarios finales en el circuito, fortalece aún más la investigación general basada en modelos al capturar mejor los requisitos, expectativas y preocupaciones de los usuarios finales. Los usuarios finales deben comprender tanto los beneficios de la información mejorada por IA para mejorar la toma de decisiones como los riesgos de que la información errónea conduzca a malas decisiones.

Desafíos de datos, modelos e integración

El análisis de eventos climáticos enfrenta muchos desafíos importantes relacionados con los datos y las características del modelo, pero también con la integración de la IA en las canalizaciones de decisión.

Tabla 1. *Desafíos, riesgos y necesidades en IA para eventos climáticos*

Aspecto	Desafíos	Riesgos	IA del futuro
Datos	Gestionar inconsistencias y sesgos en los datos	Falta de datos suficientes con anotaciones de expertos	Aprendizaje por transferencia
	Manejar datos multimodales de diversas fuentes	Bajo número de muestras para el caso anómalo	Aprendizaje desequilibrado en clase y de bajo nivel
			Aprendizaje de cola larga
	Adaptarse a las variaciones en las resoluciones de datos	Dificultad para definir lo que constituye un evento climático	ML en línea y continuo
	Manejar ocurrencias dispersas de eventos climáticos	Perder valores climáticos críticos	Modelos generativos y de cimentación

			durante el preprocesamiento	
		Adaptarse a conjuntos de datos en evolución		Mecanismos de atención y transformadores
		Desarrollar características interpretables y causalmente efectivas adaptadas a los climáticos	Se puede perder información discriminativa	Aprendizaje de representación causal
		Confianza y justificación de simulaciones	Simulaciones computacionalmente costosas	Modelos de ML híbridos y basados en la física
Modelo	Modelación	Gestionar anomalías contextuales complejas	Fuentes desconocidas de anomalías	Aprendizaje semi, auto-supervisado y no supervisado
		Integrar datos a través de puntos distantes del espacio-tiempo	Sensibilidad de los modelos de IA a las condiciones iniciales	Redes neuronales gráficas
		Captura de dependencias a largo plazo	Es posible que los datos no revelen la dinámica de los climáticos	Modelos de ML híbridos y basados en la física
		Capture patrones sutiles (nuevos) mientras minimiza los falsos positivos y negativos	Cambios en la dinámica invisible	ML/DL con pronósticos y simulaciones como características de entrada
		Establecer umbrales adaptativos	Es posible que la estacionariedad no se mantenga	Aprendizaje por refuerzo
			Modelos con colas insuficientemente pesadas	
	Comprensión y confiabilidad	Atribución de climáticos meteorológicos y climáticos	La suposición errónea sobre dónde proviene la anomalía conduce a gráficos causales incorrectos	Benchmarking y nuevas metodologías de evaluación
		Explicaciones para muestras fuera de distribución	Métodos xAI complejos, que requieren modelos de IA adicionales	Mecanismos de atención
				Modelos basados en prototipos

		Dependencia causal de los datos climáticos	Los diferentes enfoques de xAI proporcionan diferentes explicaciones	Inferencia causal
		Calibración de la incertidumbre en las colas del PDF	Dificultad para encontrar explicaciones y relaciones causales debido a relaciones de datos complejas	Inferencia variacional
			UQ generalmente difícil en DL debido a la alta dimensionalidad	Procesos gaussianos
Integración		Escala a grandes conjuntos de datos y escenarios reales	Calidad, disponibilidad, complejidad e interpretabilidad de los datos	Adaptación de dominio
		Generalización y transferibilidad	Falta de experiencia y colaboración en el dominio	Replicabilidad y validez, human-in-the-loop
		Parcialidad, transparencia y equidad	Resultados difíciles de interpretar o confiar para los no expertos	Bibliotecas e implementaciones mejoradas
		Interacción humano-IA y apoyo a la toma de decisiones	Falta de cuantificación de incertidumbre para modelos y gráficos	Soluciones distribuidas y aprendizaje federado
				Calibración de modelos y cuantificación de incertidumbre
		Comunicar y gestionar las incertidumbres	Perpetúan involuntariamente los sesgos en la toma de decisiones	Grandes modelos de lenguaje
			Resistencia al uso de sistemas de apoyo a la toma de decisiones impulsados por IA	AI for perception and reasoning
			IA para la percepción y el razonamiento	

Un desafío importante es la falta de datos suficientes con anotaciones de expertos, que son esenciales para entrenar y evaluar modelos de IA (Lam et al., 2023). Dada su rareza, los eventos climáticos pueden pasarse por alto durante los pasos de preprocesamiento de datos para eliminar el ruido, las brechas, los sesgos y las inconsistencias. Además, la IA tiene dificultades para integrar y extraer

información relevante en varias fuentes de datos y escalas, lo que puede complicar la extracción y selección de características. El desarrollo futuro de la IA debe centrarse en derivar características (o representaciones) robustas que capturen eficazmente las características distintivas de los eventos climáticos (véase la Tabla 1).

Desafíos del modelo

La falta de una definición estadística clara de los eventos climáticos y los mecanismos responsables de su ocurrencia dificultan el desarrollo y la adopción de modelos. Para la detección, los climáticos generalmente no constituyen anomalías contextuales, grupales o condicionales complejas sino complejas, cuya fuente (proceso cambiante, padres, distribución) a menudo se desconoce. Esto da lugar a desafíos, como la captura de patrones sutiles (nuevos), el establecimiento de umbrales adaptativos o la integración de datos en puntos distantes en el espacio y el tiempo (Kurth et al., 2023).

Para la predicción y la evaluación del impacto, los modelos de IA son sensibles a las condiciones iniciales y pueden no capturar dependencias a largo plazo. Además, es posible que los datos no revelen la dinámica de los climáticos, ya que puede haber cambios en la dinámica invisible y la estacionariedad puede no mantenerse en general. La no estacionariedad y los cambios en la distribución dificultan la predicción porque los cambios en las líneas de base y la evolución de las distribuciones de datos impiden que los modelos generalicen más allá de los datos históricos.

Además, las relaciones entre las variables pueden cambiar con el tiempo, lo que significa que las predicciones a menudo carecen de solidez en condiciones invisibles. El uso de modelos híbridos que combinan datos, conocimiento del dominio y ML podría permitir comprender los mecanismos que desencadenan eventos climáticos.

La complejidad de los climáticos también hace que la atribución, el descubrimiento causal y la explicabilidad sean particularmente desafiantes. XAI solo puede revelar correlaciones que el modelo aprendió y no tiene información sobre la estructura causal. Esto podría llevar a XAI a exacerbar los sesgos del modelo o las correlaciones espurias. De hecho, diferentes métodos XAI pueden producir explicaciones muy diferentes, cuya idoneidad para diferentes modelos debe evaluarse cuantitativamente (Gonzalez-Calabuig et al., 2024). Las explicaciones de XAI también son difíciles de interpretar, a menudo destacando relaciones complejas que requieren conocimiento experto. La causalidad tampoco está libre de errores, ya que una suposición errónea sobre de dónde proviene el climático podría conducir a gráficos, conclusiones y decisiones causales incorrectos. Finalmente, los

desafíos en UQ incluyen diferenciar y cuantificar las incertidumbres aleatorias y epistémicas, lo que se complica por la sobre parametrización de los modelos y su falta de fundamentos probabilísticos sólidos (cf. Tabla 1).

Desafíos de integración

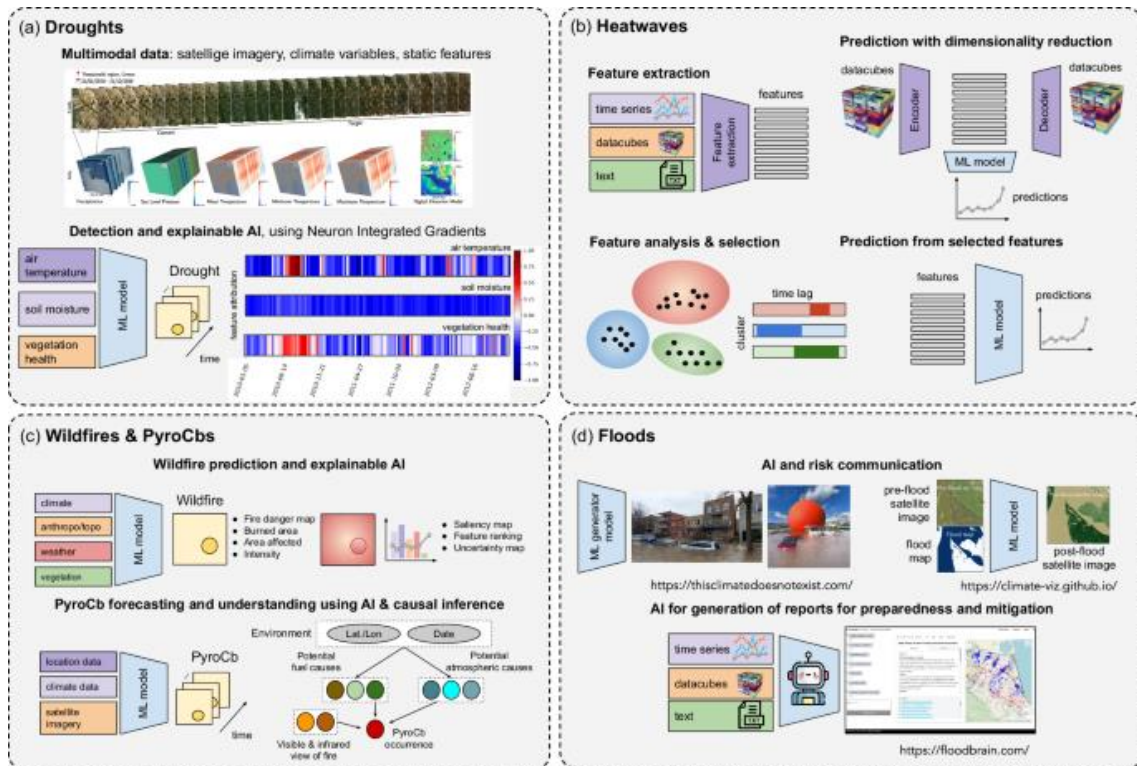
Los modelos de ML se entrenan típica y necesariamente en conjuntos de datos de alta calidad y bien seleccionados, como el reanálisis de Copernicus ERA 5 o las imágenes satelitales sin nubes, que a menudo no reflejan los pronósticos meteorológicos propensos a errores y las condiciones nubosas que se encuentran en situaciones del mundo real (Tabla 1). Los enfoques recientes de ML proponen implementar técnicas de aprendizaje de transferencia y adaptación de dominios que encuentran representaciones de características robustas, conscientes de la física e invariantes para aliviar el problema de lidiar con los cambios de distribución (Maiello et al., 2017).

La aplicación de estrategias de adaptación de dominio o el aprovechamiento de características invariantes podría alinear el rendimiento del modelo desde las fases de entrenamiento hasta las condiciones operativas. Además, aprovechar los datos geoespaciales patentados y confiables de las partes interesadas operativas, como mapas detallados de combustibles forestales y modelos de elevación, permite ajustar estos modelos para mejorar la precisión de la detección y el pronóstico y permitir una resolución espacial y temporal más precisa en los productos de salida (Dueben & Bauer, 2018).

Estudios de caso

Mostramos la investigación en IA para eventos climáticos a través de cuatro estudios de caso, cada uno centrado en un peligro distinto: sequías, olas de calor, incendios forestales e inundaciones. En cada caso, destacamos el panorama actual de la investigación y qué preguntas novedosas y apremiantes puede ayudar a abordar la IA (Fig. 3).

Figura 3. Resumen de estudios de casos que utilizan Inteligencia Artificial (IA) para gestionar eventos climáticos.



Se muestran cuatro estudios de caso (sequía, olas de calor, incendios forestales e inundaciones) en los que la IA permite la detección, la previsión, la evaluación del impacto, la explicación, la comprensión y la comunicación del riesgo, proporcionando una solución integral para la gestión de desastres.

a. Sequías. Arriba: La IA aprovecha los datos multimodales para predecir la dinámica de la superficie de la Tierra, mejorando los pronósticos de rendimiento de los cultivos, la salud de los bosques y los impactos de la sequía. Abajo: Las técnicas XAI, como los "gradientes integrados de neuronas", aclaran los factores clave que impulsan las condiciones de sequía severa, destacando las interacciones variables a lo largo del tiempo.

b. Olas de calor. Arriba: Las variables de interés se extraen de fuentes de datos heterogéneas (imágenes, series temporales, texto) y potencialmente se agregan en el espacio y/o el tiempo. Abajo a la izquierda: Las características relevantes se pueden extraer de los datos utilizando técnicas de agrupación, por ejemplo. Derecha: La predicción de la ola de calor se puede realizar combinando herramientas de reducción de dimensionalidad o directamente desde las entidades seleccionadas.

c. Incendios forestales. Arriba: La IA mejora la comprensión y la predicción de la dinámica de los incendios forestales, particularmente para los mega incendios intensificados por el calentamiento global, mediante el análisis de conjuntos de datos extensos y la diferenciación de tipos de incendios con XAI. Abajo: La IA combinada con la inferencia causal tiene como objetivo detectar y comprender mejor las nubes pirocumulonimbus, sistemas de tormentas intensas generados por grandes incendios forestales que complican la predicción del comportamiento del fuego.

d. Inundaciones. La IA transforma la comunicación del riesgo de inundación mediante el uso de visualizaciones y animaciones 3D realistas para representar el impacto del aumento del nivel del agua en las comunidades y la infraestructura, lo que hace que la información sea más identificable (thisclimatedoesnotexist.com). Las plataformas impulsadas por IA analizan grandes cantidades de datos de pronósticos meteorológicos, niveles de ríos y patrones históricos de inundaciones para predecir eventos futuros con precisión, integrando esta información con mapas digitales y modelos urbanos para identificar áreas de alto riesgo (climate-viz.github.io.com). Este enfoque mejora la gestión del riesgo de inundaciones al permitir una comunicación específica y personalizada, lo que permite a los residentes recibir alertas específicas y visualizar los posibles impactos en sus hogares. La IA también apoya la generación de informes detallados de inundaciones de diversas fuentes, mejorando los esfuerzos de preparación y mitigación (floodbrain.com).

Debido al calentamiento global, esperamos un aumento en la frecuencia de condiciones atmosféricas inestables en los próximos años. Estas condiciones pueden conducir a la formación de nubes Pirocumulonimbus (pyroCbs), nubes de tormenta que generan sus propios frentes climáticos, lo que puede hacer que el comportamiento de los incendios forestales sea impredecible. A pesar del riesgo que representan los piroCbs, las condiciones que conducen a su aparición y evolución aún no se comprenden bien, y sus mecanismos causales son inciertos. En combinación con la inferencia causal, la IA puede avanzar en la detección, previsión y comprensión de los impulsores de los eventos pyroCb (Rosenfeld & Lensky, 1998).

Inundaciones: de la modelización a la comunicación del riesgo

El estudio de las inundaciones es crucial, ya que son los desastres naturales más frecuentes y costosos, que afectan a millones de personas anualmente y causan más de 40 mil millones de dólares en daños en todo el mundo. El desarrollo de métodos novedosos para la detección de inundaciones mejora los SAT, reduciendo las muertes hasta en un 40%, mientras que la comunicación eficaz de los riesgos

garantiza una mejor preparación y respuesta, lo que puede salvar miles de vidas (Kirkwood et al., 2021).

La IA ofrece vías prometedoras para mejorar los sistemas de gestión de inundaciones. Los modelos avanzados de pronóstico meteorológico global impulsados por IA pueden procesar rápidamente grandes conjuntos de datos, proporcionando estimaciones probabilísticas más precisas incluso durante eventos climáticos. Los modelos híbridos recientes, como el aprendizaje profundo guiado por la física para el modelado de precipitación-escorrentía que considera los eventos climáticos y el DL híbrido del ciclo hidrológico global, están avanzando en el campo con una mayor consistencia y capacidades de pronóstico. Además, las técnicas de IA como la dinámica de fluidos computacional acelerada por ML podrían abordar los desafíos computacionales en el modelado hidromorfodinámico, lo que permite predicciones más precisas del flujo de los arroyos y los niveles de inundación, particularmente en cuencas no aforadas.

Además, la IA puede ayudar a calibrar medidores de video sin contacto, potencialmente más robustos que los métodos tradicionales, ya que no se ven directamente afectados por el agua. La IA también puede guiar el análisis forense para evaluar la exposición y la vulnerabilidad, empleando enfoques multimodales para refinar los modelos geoespaciales a escala local. Sin embargo, la eficacia de estos modelos impulsados por la IA depende de un conocimiento detallado del terreno local, incluidos los posibles cuellos de botella, como puentes y canales, y de datos precisos sobre la vulnerabilidad de la sociedad a las inundaciones (Hanna et al., 2016).

Sin embargo, la IA también puede transformar la forma en que se emiten las advertencias para mejorar las estrategias de comunicación y respuesta. Por ejemplo, los mapas generados por IA y las visualizaciones fotorrealistas basadas en modelos digitales de elevación pueden representar las áreas de inundación y los daños esperados. Además, la IA puede generar advertencias basadas en el lenguaje fácilmente comprensibles, tanto escritas como auditivas, adaptadas a diversas poblaciones, incluidas las personas con discapacidad visual (Chattopadhyay, Nabizadeh, et al., 2020). Una función de chatbot basada en LLM podría mejorar la interactividad, proporcionando respuestas personalizadas en tiempo real a las consultas de emergencia (ver ejemplos en la Fig. 3). La IA puede mejorar la gestión de riesgos en los SAT, pero convertir las alertas en acciones en escenarios inciertos requiere una comunicación eficaz.

DISCUSIÓN

La transición de métodos estadísticos clásicos basados en umbrales fijos hacia modelos de Deep Learning (DL) representa un cambio de paradigma para regiones como la provincia de Bolívar. Mientras que los índices tradicionales a menudo fallan al capturar la naturaleza no estacionaria del clima (Cohen et al., 2019), la IA permite una detección de eventos basada en múltiples variables espaciotemporales. Para Bolívar, esto es crítico dada su topografía diversa, donde una inundación en las zonas bajas puede ser predicha con mayor precisión mediante el análisis de la humedad del suelo y la escorrentía en las partes altas (Hanna et al., 2016).

Un hallazgo fundamental en esta investigación es que la precisión no es suficiente para la toma de decisiones en SAT. Como se observó en los casos de inundaciones en Europa durante 2021 y 2024, las predicciones precisas fallaron por falta de comunicación efectiva (Vicente & Li, n.d.). Aquí, la IA Explicable (XAI) y el uso de Gradientes Integrados (como se vio en el estudio de sequías) son esenciales. No basta con predecir una sequía en el cantón Guaranda; el modelo debe explicar qué factores (ej. anomalías de temperatura o déficit de precipitación acumulada) están impulsando el riesgo para que los agricultores confíen en la alerta y ajusten sus siembras.

La discusión sobre los modelos híbridos (física + IA) es especialmente relevante para cuencas no aforadas en la región andina. La integración de la dinámica de fluidos computacional acelerada por ML permite superar la falta de sensores físicos en los ríos de la provincia, utilizando datos de teledetección para estimar niveles de inundación (Kirkwood et al., 2021). Sin embargo, persiste el desafío de la "fatiga de advertencia" y los sesgos en los datos. La implementación de LLMs para personalizar alertas, como se propone en el marco operativo, debe ser manejada con ética para evitar la desinformación en comunidades rurales con baja conectividad (Clark et al., 2016).

A diferencia de los enfoques de ML tradicionales que solo detectan patrones, la inclusión de la inferencia causal en este marco permite abordar fenómenos extremos impredecibles, como los incendios forestales intensificados por el cambio climático (pyroCbs). Para Bolívar, esto significa que la IA no solo dirá "hay riesgo de incendio", sino que podrá modelar escenarios contra fácticos: "¿Qué pasaría si la humedad relativa baja un 5% adicional bajo estas condiciones de viento?" (Boukabara et al., 2019). Esta capacidad de "imaginar" escenarios es lo que finalmente permitirá a la provincia pasar de una respuesta reactiva a una preparación proactiva y científica.

CONCLUSIONES

Este artículo destaca el importante potencial de la IA para analizar y modelar eventos climáticos, al tiempo que detalla las principales dificultades y perspectivas asociadas con este campo emergente.

La integración de la IA en el análisis de eventos climáticos enfrenta varios desafíos, incluidos problemas de gestión de datos como el manejo de conjuntos de datos dinámicos, sesgos y alta dimensionalidad que complican la extracción de características.

Los modelos de IA también luchan con definiciones estadísticas poco claras de lo que es "climático".

La integración de la IA con los modelos físicos plantea desafíos sustanciales, pero ofrece oportunidades prometedoras para mejorar la precisión y confiabilidad del modelo.

Las preocupaciones sobre la confiabilidad surgen de la complejidad e interpretabilidad de los modelos de ML, la dificultad de generalizar en diferentes contextos y la cuantificación de la incertidumbre.

Los desafíos operativos incluyen la complejidad de los resultados de la IA, que dificultan la interpretación por parte de personas no expertas, la resistencia a la adopción de IA debido a preocupaciones sobre la confiabilidad y la equidad, y la necesidad de marcos que faciliten la integración transparente y ética de los conocimientos de IA en los procesos de toma de decisiones

REFERENCIAS BIBLIOGRÁFICAS

- Aligo, E. A., Gallus, W. A., & Segal, M. (2009). On the impact of WRF model vertical grid resolution on midwest summer rainfall forecasts. *Weather and Forecasting*, 24(2), 575–594. <https://doi.org/10.1175/2008WAF2007101.1>
- Boukabara, S. A., Krasnopolsky, V., Stewart, J. Q., Maddy, E. S., Shahroudi, N., & Hoffman, R. N. (2019). Leveraging modern artificial intelligence for remote sensing and NWP benefits and challenges. *Bulletin of the American Meteorological Society*, 100(12), ES473–ES491. <https://doi.org/10.1175/BAMS-D-18-0324.1>
- Brenowitz, N. D., & Bretherton, C. S. (2018). Prognostic Validation of a Neural Network Unified Physics Parameterization. *Geophysical Research Letters*, 45(12), 6289–6298. <https://doi.org/10.1029/2018GL078510>
- Capecchi, V., Antonini, A., Benedetti, R., Fibbi, L., Melani, S., Rovai, L., Ricchi, A., & Cerrai, D. (2021). Assimilating x-and s-band radar data for a heavy precipitation event in italy. *Water*, 13(13). <https://doi.org/10.3390/W13131727>
- Chattopadhyay, A., Nabizadeh, E., & Hassanzadeh, P. (2020). Analog Forecasting of Extreme-Causing Weather Patterns Using Deep Learning. *Journal of Advances in Modeling Earth Systems*, 12(2). <https://doi.org/10.1029/2019MS001958>
- Chen, K., Wang, P., Yang, X., Zhang, N., & Wang, D. (2020). A model output deep learning method for grid temperature forecasts in Tianjin Area. *Applied Sciences*, 10(17). <https://doi.org/10.3390/APP10175808>

- Clark, P., Roberts, N., Lean, H., Ballard, S. P., & Charlton-Perez, C. (2016). Convection-permitting models: A step-change in rainfall forecasting. *Meteorological Applications*, 23(2), 165–181. <https://doi.org/10.1002/MET.1538>
- Cohen, J., Coumou, D., Hwang, J., Mackey, L., Orenstein, P., Tetz, S., & Tziperman, E. (2019). S2S reboot: An argument for greater inclusion of machine learning in subseasonal to seasonal forecasts. *Wiley Interdisciplinary Reviews: Climate Change*, 10(2). <https://doi.org/10.1002/WCC.567>
- Cullen, M. J. P., Davies, T., Mawson, M. H., James, J. A., Coulter, S. C., & Malcolm, A. (1997). An overview of numerical methods for the next generation u.k. nwp and climate model. *Atmosphere - Ocean*, 35, 425–444. <https://doi.org/10.1080/07055900.1997.9687359>
- Dewitte, S., Cornelis, J. P., Müller, R., & Munteanu, A. (2021). Artificial Intelligence Revolutionises Weather Forecast, Climate Monitoring and Decadal Prediction. *Remote Sensing*, 13(16), 3209. <https://doi.org/10.3390/RS13163209>
- Dueben, P. D., & Bauer, P. (2018). Challenges and design choices for global weather and climate models based on machine learning. *Geoscientific Model Development*, 11(10), 3999–4009. <https://doi.org/10.5194/GMD-11-3999-2018>
- Gonzalez-Calabuig, M., Cortes-Andres, J., Williams, T. K. E., Zhang, M., Pellicer-Valero, O. J., Fernandez-Torres, M. A., & Camps-Valls, G. (2024). The AIDE Toolbox: Artificial intelligence for disentangling extreme events. *IEEE Geoscience and Remote Sensing Magazine*, 12(2), 113–118. <https://doi.org/10.1109/MGRS.2024.3382544>
- Hanna, E., Cropper, T. E., Hall, R. J., & Cappelen, J. (2016). Greenland Blocking Index 1851–2015: a regional climate change signal. *International Journal of Climatology*, 36(15), 4847–4861. <https://doi.org/10.1002/JOC.4673>
- He, S., Li, X., DelSole, T., Ravikumar, P., & Banerjee, A. (2021). Sub-Seasonal Climate Forecasting via Machine Learning: Challenges, Analysis, and Advances. *35th AAAI Conference on Artificial Intelligence*, 1, 169–177. <https://doi.org/10.1609/aaai.v35i1.16090>
- Höhlein, K., Kern, M., Hewson, T., & Westermann, R. (2020). A comparative study of convolutional neural network models for wind field downscaling. *Meteorological Applications*, 27(6). <https://doi.org/10.1002/MET.1961>
- Huang, X. Y., Xiao, Q., Barker, D. M., Zhang, X., Michalakes, J., Huang, W., ... & Kuo, Y. H. (2009). Four-dimensional variational data assimilation for WRF: Formulation and preliminary results. *Monthly Weather Review*, 137(1), 299–314. <https://doi.org/10.1175/2008MWR2577.1>
- Kim, K. S., Lee, J. B., Roh, M. Il, Han, K. M., & Lee, G. H. (2020). Prediction of ocean weather based on denoising autoencoder and convolutional LSTM. *Journal of Marine Science and Engineering*, 8(10), 1–24. <https://doi.org/10.3390/JMSE8100805>
- Kirkwood, C., Economou, T., Odbert, H., & Pugeault, N. (2021). A framework for probabilistic weather forecast post-processing across models and lead times using machine learning. *Philosophical Transactions of the Royal Society A*, 379(2194). <https://doi.org/10.1098/RSTA.2020.0099>
- Kurth, T., Subramanian, S., Harrington, P., Pathak, J., Mardani, M., Hall, D., ... & Anandkumar, A. (2023). FourCastNet: Accelerating Global High-Resolution Weather Forecasting Using Adaptive Fourier Neural Operators. *PASC '23*. <https://doi.org/10.1145/3592979.3593412>
- Lam, R., Sanchez-Gonzalez, A., Willson, M., Wirnsberger, P., Fortunato, M., Alet, F., ... & Battaglia,

- P. (2023). Learning skillful medium-range global weather forecasting. *Science*, 382(6677), 1416–1422. <https://doi.org/10.1126/SCIENCE.ADI2336>
- Li, L. (2019). Geographically weighted machine learning and downscaling for high-resolution spatiotemporal estimations of wind speed. *Remote Sensing*, 11(11). <https://doi.org/10.3390/RS11111378>
- Maiello, I., Gentile, S., Ferretti, R., Baldini, L., Roberto, N., Picciotti, E., ... & Marzano, F. (2017). Impact of multiple radar reflectivity data assimilation on the numerical simulation of a flash flood event. *Hydrology and Earth System Sciences*, 21(11), 5459–5476. <https://doi.org/10.5194/HESS-21-5459-2017>
- Meehl, G. A., Goddard, L., Boer, G., Burgman, R., Branstator, G., Cassou, C., ... & Yeager, S. (2014). Decadal climate prediction an update from the trenches. *Bulletin of the American Meteorological Society*, 95(2), 243–267. <https://doi.org/10.1175/BAMS-D-12-00241.1>
- Morau, A., Dewitte, S., Cornelis, B., & Munteanu, A. (2019). Deep learning for precipitation estimation from satellite and rain gauges measurements. *Remote Sensing*, 11(21). <https://doi.org/10.3390/RS11212463>
- O’Gorman, P. A., & Dwyer, J. G. (2018). Using Machine Learning to Parameterize Moist Convection. *Journal of Advances in Modeling Earth Systems*, 10(10), 2548–2563. <https://doi.org/10.1029/2018MS001351>
- Palmer, T., & Stevens, B. (2019). The scientific challenge of understanding and estimating climate change. *PNAS*, 116(49), 34390–34395. <https://doi.org/10.1073/PNAS.1906691116>
- Rasp, S., Dueben, P. D., Scher, S., Weyn, J. A., Mouatadid, S., & Thuerey, N. (2020). WeatherBench: A Benchmark Data Set for Data-Driven Weather Forecasting. *Journal of Advances in Modeling Earth Systems*, 12(11). <https://doi.org/10.1029/2020MS002203>
- Ricchi, A., Bonaldo, D., Cioni, G., Carniel, S., & Miglietta, M. M. (2021). Simulation of a flash-flood event over the Adriatic Sea with a high-resolution coupled system. *Scientific Reports*, 11(1). <https://doi.org/10.1038/S41598-021-88476-1>
- Rosenfeld, D., & Lensky, I. M. (1998). Satellite-Based Insights into Precipitation Formation Processes. *Bulletin of the American Meteorological Society*, 79(11), 2457–2476. [https://doi.org/10.1175/1520-0477\(1998\)079<2457:SBIIPF>2.0.CO;2](https://doi.org/10.1175/1520-0477(1998)079<2457:SBIIPF>2.0.CO;2)
- Scher, S. (2018). Toward Data-Driven Weather and Climate Forecasting: Approximating a Simple General Circulation Model With Deep Learning. *Geophysical Research Letters*, 45(22), 12,616–12,622. <https://doi.org/10.1029/2018GL080704>
- Schultz, M. G., Betancourt, C., Gong, B., Kleinert, F., Langguth, M., Leufen, L. H., ... & Stadtler, S. (2021). Can deep learning beat numerical weather prediction? *Philosophical Transactions of the Royal Society A*, 379(2194). <https://doi.org/10.1098/RSTA.2020.0097>
- Shrestha, A., & Mahmood, A. (2019). Review of deep learning algorithms and architectures. *IEEE Access*, 7, 53040–53065. <https://doi.org/10.1109/ACCESS.2019.2912200>
- Urbich, I., Bendix, J., & Müller, R. (2020). Development of a seamless forecast for solar radiation using anaklim++. *Remote Sensing*, 12(21), 1–19. <https://doi.org/10.3390/RS12213672>
- Vicente, S. M., & Li, S. (n.d.). *Weather and Climate Extreme Events in a Changing Climate*. coordinating Lead Authors. <https://doi.org/10.1017/9781009157896.013>
- Villares, M., Moratorio, S., Abrigo, M., & Tomasoni, M. (n.d.). *Informe IA y Cambio Climático Oportunidades y Desafíos*. www.sustentabilidadsf.com.ar

- Weyn, J. A., Durran, D. R., & Caruana, R. (2020). Improving Data-Driven Global Weather Prediction Using Deep Convolutional Neural Networks on a Cubed Sphere. *Journal of Advances in Modeling Earth Systems*, 12(9). <https://doi.org/10.1029/2020MS002109>
- Zheng, F., Tao, R., Maier, H. R., See, L., Savic, D., Zhang, T., ... & Popescu, I. (2018). Crowdsourcing Methods for Data Collection in Geophysics. *Reviews of Geophysics*, 56(4), 698–740. <https://doi.org/10.1029/2018RG000616>
- Zheng, G., Li, X., Zhang, R. H., & Liu, B. (2020). Purely satellite data-driven deep learning forecast of complicated tropical instability waves. *Science Advances*, 6(29). <https://doi.org/10.1126/SCIADV.ABA1482>