

García Díaz, D.; Aguilar Gómez, F.; A. Schauman, S.; Verger, A. Modelización y atribución de la dinámica vegetación-clima a escala global mediante inteligencia artificial explicable

# Modelización y atribución de la dinámica vegetación-clima a escala global mediante inteligencia artificial explicable

García Díaz, Daniel <sup>1,2</sup> Aguilar Gómez, Fernando <sup>2</sup> A. Schauman, Santiago <sup>3,1</sup> Verger, Alexandre <sup>1,3</sup>

<sup>1</sup> Centro de Investigaciones sobre Desertificación (CIDE)

<sup>2</sup> Instituto de Física de Cantabria (IFCA)

<sup>3</sup> Centro de Investigación Ecológica y Aplicaciones Forestales (CREAF)

ORCID: García Díaz 0000-0002-3399-1598 Aguilar Gómez 0000-0001-9462-4831 Verger 0000-0001-9374-1745

Correspondencia: [garciad@ifca.unican.es](mailto:garciad@ifca.unican.es) [aguilarf@ifca.unican.es](mailto:aguilarf@ifca.unican.es) [santischauaman@gmail.com](mailto:santischauaman@gmail.com) [verger@csic.es](mailto:verger@csic.es)

## RESUMEN

Comprender la respuesta de la vegetación a la variabilidad y al cambio climático es esencial para evaluar la dinámica de los ecosistemas a escala global. El índice de área foliar (LAI), derivado de series temporales satelitales de larga duración, constituye un indicador clave de la vegetación; sin embargo, atribuir sus variaciones a forzamientos climáticos específicos sigue siendo complejo debido a la no linealidad de las interacciones, la heterogeneidad espacial y la multicolinealidad entre variables ambientales. En este estudio se desarrolla un marco metodológico escalable a nivel global para analizar las relaciones vegetación-clima a partir de la evolución del producto GEOV2-AVHRR LAI durante el periodo 1982–2022 y su relación con variables climáticas derivadas del reanálisis ERA5. Como caso ilustrativo, se presentan resultados para el dominio de América, donde se analiza la sensibilidad del LAI frente a indicadores de disponibilidad hídrica, incluyendo la humedad del suelo. Las relaciones vegetación-clima se modelizan mediante algoritmos no lineales basados en árboles, como Random Forest y Gradient Boosting, e incorporando técnicas de inteligencia artificial explicable (XAI), como SHAP y análisis de dependencia parcial, para cuantificar la contribución de los predictores climáticos y estimar sensibilidades comparables entre modelos y regiones. Los resultados muestran una alta consistencia espacial entre algoritmos, lo que refuerza la robustez de las sensibilidades estimadas y su interpretación física. El enfoque propuesto proporciona un marco reproducible y extensible para el análisis de las interacciones vegetación-clima a gran escala.


**Palabras clave:** Índice de área foliar (LAI); Sensibilidad climática; Aprendizaje automático; Inteligencia artificial explicable; Cambio climático


Fecha de recepción: 18 febrero 2026 · Fecha de aceptación: 18 febrero 2026

# Modelización y atribución de la dinámica vegetación-clima a escala global mediante inteligencia artificial explicable


García-Díaz, Daniel <sup>(1,2)</sup>, Aguilar Gómez, Fernando <sup>(2)</sup>, Schauman, Santiago A. <sup>(3,1)</sup>, Verger, Aleixandre <sup>(1,3)</sup>

<sup>(1)</sup> Centro de Investigaciones sobre Desertificación (CIDE).

 0000-0002-3399-1598, garciad@ifca.es

 0000-0001-9374-1745, verger@csic.es.

<sup>(2)</sup> Instituto de Física de Cantabria.

 0000-0001-9462-4831, aguilarf@ifca.es.

<sup>(3)</sup> Centro de Investigación Ecológica y Aplicaciones Forestales (CREAF).  
santischauman@gmail.com

**Resumen:** Comprender la respuesta de la vegetación a la variabilidad y al cambio climático es esencial para evaluar la dinámica de los ecosistemas a escala global. El índice de área foliar (LAI), derivado de series temporales satelitales de larga duración, constituye un indicador clave de la vegetación; sin embargo, atribuir sus variaciones a forzamientos climáticos específicos sigue siendo complejo debido a la no linealidad de las interacciones, la heterogeneidad espacial y la multicolinealidad entre variables ambientales. En este estudio se desarrolla un marco metodológico escalable a nivel global para analizar las relaciones vegetación-clima a partir de la evolución del producto GEOV2-AVHRR LAI durante el periodo 1982–2022 y su relación con variables climáticas derivadas del reanálisis ERA5. Como caso ilustrativo, se presentan resultados para el dominio de América, donde se analiza la sensibilidad del LAI frente a indicadores de disponibilidad hídrica, incluyendo la humedad del suelo. Las relaciones vegetación-clima se modelizan mediante algoritmos no lineales basados en árboles, como Random Forest y Gradient Boosting, e incorporando técnicas de inteligencia artificial explicable (XAI), como SHAP y análisis de dependencia parcial, para cuantificar la contribución de los predictores climáticos y estimar sensibilidades comparables entre modelos y regiones. Los resultados muestran una alta consistencia espacial entre algoritmos, lo que refuerza la robustez de las sensibilidades estimadas y su interpretación física. El enfoque propuesto proporciona un marco reproducible y extensible para el análisis de las interacciones vegetación-clima a gran escala.

**Palabras clave:** Índice de área foliar (LAI); Sensibilidad climática; Aprendizaje automático; Inteligencia artificial explicable; Cambio climático

## ***Modelling and Attribution of Global Vegetation–Climate Dynamics Using Explainable Artificial Intelligence***

**Abstract:** Understanding vegetation responses to climate variability and climate change is essential for assessing ecosystem dynamics at the global scale. The Leaf Area Index (LAI), derived from long-term satellite time series, constitutes a key indicator of vegetation; however, attributing its variations to specific climatic forcings remains challenging due to the nonlinearity of interactions, spatial heterogeneity, and multicollinearity among environmental variables. In this study, a globally scalable methodological framework is developed to analyse vegetation–climate relationships based on the evolution of the GEOV2-AVHRR LAI product over the period 1982–2022 and its relationship with climatic variables derived from the ERA5 reanalysis. As an illustrative case, results are presented for the domain of the Americas, where LAI sensitivity to indicators of water availability, including soil moisture, is analysed. Vegetation–climate relationships are modelled using nonlinear tree-based algorithms, such as Random Forest and Gradient Boosting, incorporating explainable artificial intelligence (XAI) techniques, including SHAP and partial dependence analysis, to quantify the contribution of climatic predictors and estimate sensitivities comparable across models and regions. The results show high spatial consistency among algorithms, reinforcing the robustness of the estimated sensitivities and their physical interpretation. The proposed approach provides a reproducible and extensible framework for analysing vegetation–climate interactions at large spatial scales.

**Keywords:** Leaf Area Index (LAI); Climate sensitivity; Machine learning; Explainable artificial intelligence (XAI); Climate change

## 1. INTRODUCCIÓN

La vegetación terrestre desempeña un papel clave en la regulación del sistema climático al controlar los flujos de carbono, agua y energía entre la superficie y la atmósfera. El índice de área foliar (Leaf Area Index, LAI) constituye uno de los indicadores biofísicos más robustos de la vegetación, estrechamente vinculado a la fotosíntesis y la productividad primaria. El desarrollo de productos satelitales de larga duración y alta consistencia temporal, como GEOV2-AVHRR (Verger *et al.*, 2023), permite analizar la dinámica de la vegetación a escala global durante las últimas cuatro décadas.

Durante este periodo se ha documentado un fenómeno generalizado de reverdecimiento a escala global (Zhu *et al.*, 2016; Chen *et al.*, 2019), acompañado de cambios en los factores climáticos dominantes que regulan la productividad vegetal (Wang *et al.*, 2020; Liu *et al.*, 2023), incluyendo un aumento de la sensibilidad a la disponibilidad hídrica y respuestas diferenciadas según los regímenes climáticos regionales (Li *et al.*, 2022; Zhang *et al.*, 2021). Sin embargo, atribuir de forma robusta las tendencias observadas del LAI a forzamientos climáticos específicos sigue siendo un desafío debido a la no linealidad de las interacciones, la multicolinealidad entre variables ambientales y la heterogeneidad espacial (Zscheischler *et al.*, 2018).

En este contexto, el aprendizaje automático proporciona un marco flexible para modelar relaciones vegetación-clima a escala global sin imponer hipótesis funcionales predefinidas. No obstante, el uso de modelos complejos exige incorporar herramientas de interpretabilidad que permitan traducir el rendimiento predictivo en conocimiento físico. La inteligencia artificial explicable (XAI), mediante técnicas como SHAP (Lundberg & Lee, 2017), ofrece un marco cuantitativo para estimar la contribución de las variables climáticas y analizar la estabilidad espacial y temporal de dichas contribuciones.

Este trabajo propone un enfoque basado en algoritmos no lineales de tipo árbol (Random Forest y Gradient Boosting), para modelizar las relaciones vegetación-clima y estimar sensibilidades climáticas del LAI a partir de técnicas XAI. Aunque el marco metodológico se concibe a escala global, en esta contribución se presenta un caso ilustrativo centrado en el dominio de América.

## 2. MATERIAL Y MÉTODOS

### 2.1. Datos

El estudio se basa en las series temporales del producto LAI GEOV2-AVHRR (Verger *et al.*, 2023), disponible en el portal GEODES (<https://geodes.cnes.fr>), con frecuencia de 10 días, resolución espacial de 5 km y cobertura global para el periodo 1981-2022.

Como variables explicativas se utilizan datos climáticos mensuales del reanálisis ERA5, incluyendo temperatura, precipitación, radiación, presión de vapor y variables de

disponibilidad hídrica (humedad del suelo superficial y en zona radicular). La incorporación explícita de indicadores hídricos responde a la evidencia creciente del papel dominante de las limitaciones por agua en amplias regiones del planeta (Li *et al.*, 2022; Liu *et al.*, 2023). Todas las variables se remuestrean a una resolución espacial común de 0.5°.

### 2.2. Preprocesado y cálculo de anomalías


Se aplica un preprocesado homogéneo a nivel de píxel que incluye control de calidad y verificación de la consistencia de las series temporales. Posteriormente, se calculan climatologías mensuales a partir de medias multianuales y, a partir de ellas, las anomalías correspondientes (Zhu *et al.*, 2016; Chen *et al.*, 2019).

El análisis se restringe a la temporada de crecimiento de la vegetación, definida mediante un umbral térmico (temperatura del aire > 5°C), con el fin de analizar las relaciones dinámicas entre anomalías climáticas y del LAI.

### 2.3. Modelización mediante aprendizaje automático

Las relaciones entre anomalías de LAI y variables climáticas se modelizan mediante algoritmos no lineales basados en árboles, permitiendo capturar interacciones complejas y dependencias no lineales entre predictores. Los modelos se entrenan de forma independiente a nivel de píxel, integrando información de distintos biomas y regímenes climáticos en un marco común.

El objetivo del modelado no es únicamente predictivo, sino proporcionar una base sobre la que aplicar técnicas de interpretabilidad que permitan descomponer las predicciones en contribuciones atribuibles a cada variable climática. A partir de estas contribuciones se derivan sensibilidades climáticas comparables entre regiones y algoritmos. La Figura 1 resume el flujo metodológico completo.



**Figura 1.** Esquema metodológico del estudio, que integra la adquisición de datos, preprocesado y cálculo de anomalías, entrenamiento de modelos de aprendizaje automático y la aplicación de técnicas de inteligencia artificial explicable.

### 2.4. Interpretabilidad y estimación de sensibilidad climática

Para avanzar más allá del análisis puramente predictivo, se aplican técnicas de inteligencia artificial explicable

(XAI) que permiten descomponer las predicciones del modelo en contribuciones atribuibles a cada variable climática. En particular, se emplea SHAP (Lundberg & Lee, 2017; Liu *et al.*, 2023) para estimar contribuciones locales a nivel de píxel y tiempo, proporcionando una medida consistente de la influencia de cada predictor sobre la predicción del modelo. De forma complementaria, se utilizan métodos basados en permutación (*permutation importance*) para evaluar la importancia relativa de las variables y verificar la estabilidad de las atribuciones obtenidas.

A partir de estas contribuciones se estiman sensibilidades empíricas del LAI frente a cada variable climática, permitiendo cuantificar tanto la magnitud como la dirección de la influencia de cada forzamiento y analizar su variabilidad espacial y temporal.

### 3. SENSIBILIDAD CLIMÁTICA

La sensibilidad climática local se define como una aproximación empírica a la respuesta del LAI frente a variaciones en un predictor climático, y puede interpretarse como una derivada efectiva dependiente del estado del sistema. Para un predictor climático  $X$ , la sensibilidad  $S_X$  en el píxel  $i$  se expresa como la relación entre las anomalías de LAI y del predictor correspondiente:

$$S_{X,i} = \frac{\partial LAI'_{i,t}}{\partial X'_{i,t}} \quad (1)$$

donde  $LAI'_{i,t}$  representa la anomalía del LAI y  $X'_{i,t}$  la anomalía del predictor climático.

Dado que los modelos empleados son no lineales y no analíticamente diferenciables, esta sensibilidad se aproxima a partir de las contribuciones locales estimadas mediante técnicas XAI. En particular, los valores SHAP permiten cuantificar la contribución de cada predictor a la predicción del modelo (Lundberg & Lee, 2017).

Bajo este enfoque, la contribución del predictor climático  $X$  a la anomalía del LAI puede expresarse como:

$$\phi_{X,i,t} = S_{X,i}X'_{i,t} + \epsilon_{i,t} \quad (2)$$

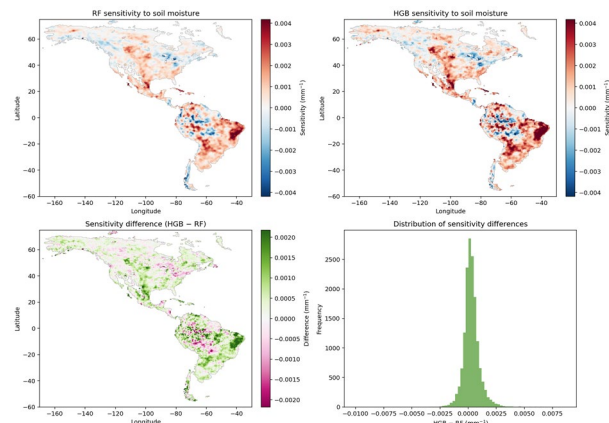
donde  $\phi_{X,i,t}$  representa el valor SHAP asociado al predictor  $X$ ;  $S_{X,i}$  es la sensibilidad climática local estimada;  $X'_{i,t}$  corresponde a la anomalía del predictor y  $\epsilon_{i,t}$  es el término residual que recoge la variabilidad no explicada por el modelo.

### 4. RESULTADOS

Como caso ilustrativo, se presenta el dominio de América, donde se han entrenado modelos Random Forest (RF) y HistGradientBoosting (HGB) para estimar la sensibilidad del LAI frente a la humedad del suelo.

Los mapas de sensibilidad obtenidos con ambos algoritmos muestran patrones espaciales coherentes (Figura 2), con respuestas positivas dominantes en amplias zonas semiáridas y mayor heterogeneidad, incluyendo respuestas negativas, en regiones tropicales

y húmedas. Las magnitudes estimadas son comparables entre modelos.



**Figura 2.** Comparación espacial de la sensibilidad del LAI a la humedad del suelo estimada mediante RF y HGB en América.

Se muestran los mapas de ambos modelos, el mapa de diferencias (HGB-RF) y la distribución de dichas diferencias. Las unidades de sensibilidad se expresan en  $\text{mm}^{-1}$ .

La comparación cuantitativa confirma esta consistencia: la correlación espacial entre mapas alcanza  $r = 0.90$ , con un RMSE de  $7.9 \times 10^{-4} \text{ mm}^{-1}$ . El 86.7% de los píxeles presentan el mismo signo de sensibilidad en ambos modelos, mientras que las discrepancias se concentran en regiones con sensibilidades cercanas a cero. La distribución de diferencias está centrada en cero, indicando un alto grado de acuerdo entre algoritmos.

Estos resultados evidencian la robustez de las sensibilidades estimadas frente al algoritmo empleado y respaldan la interpretación física de los patrones detectados, así como su extensión a escala global y a otros predictores climáticos.

### 5. AGRADECIMIENTOS

Este trabajo ha sido financiado por el Ministerio de Ciencia, Innovación y Universidades, proyecto PROFECIA (PID2023-152114OB-I00). Los productos GEOV2-AVHRR fueron producidos y distribuidos por el CNES utilizando los algoritmos desarrollados por el CSIC, CREAM y INRAE en el marco del programa THEIA (contratos CNES n.º. 5700007172/DOA096 y n.º 140570/00).

### 6. REFERENCIAS

Chen, C., Park, T., Wang, X., *et al.* (2019). China and India lead in greening of the world through land-use management. *Nature Sustainability*, 2(2), 122–129. <https://doi.org/10.1038/s41893-019-0220-7>

Li, W., Ciais, P., Peng, S., *et al.* (2022). Widespread increasing vegetation sensitivity to soil moisture. *Nature Communications*, 13, 3959. <https://doi.org/10.1038/s41467-022-31665-9>

Liu, Y., Piao, S., Chen, A., *et al.* (2023). Shifts in climatic limitations on global vegetation productivity unveiled by Shapley additive explanation: Reduced temperature but increased water limitations. *Global*

- Change Biology, 29(3), 623–638.  
<https://doi.org/10.1111/gcb.16432>
- Lundberg, S. M., & Lee, S.-I. (2017). A unified approach to interpreting model predictions. In I. Guyon *et al.* (Eds.), *Advances in neural information processing systems* (Vol. 30). Curran Associates.
- Verger, A., Baret, F., & Weiss, M. (2023). GEOV2-AVHRR: Continuous and consistent time series of global leaf area index and fraction absorbed PAR from 1981 to 2022. *Remote Sensing of Environment*, 290, 113509. <https://doi.org/10.1016/j.rse.2023.113509>
- Wang, X., Piao, S., Ciais, P., *et al.* (2020). Recent global decline of CO<sub>2</sub> fertilization effects on vegetation photosynthesis. *Science*, 370(6522), 1295–1300. <https://doi.org/10.1126/science.abb7772>
- Zhang, Y., Xiao, X., Zhou, S., *et al.* (2021). Contrasting ecosystem vegetation response in global drylands under drying and wetting conditions. *Global Change Biology*, 27(8), 1759–1773. <https://doi.org/10.1111/gcb.15523>
- Zhu, Z., Piao, S., Myneni, R. B., *et al.* (2016). Greening of the Earth and its drivers. *Nature Climate Change*, 6(8), 791–795. <https://doi.org/10.1038/nclimate3004>
- Zscheischler, J., Westra, S., van den Hurk, B. J. J. M., *et al.* (2018). Future climate risk from compound events. *Nature Climate Change*, 8(6), 469–477. <https://doi.org/10.1038/s41558-018-0156-3>