

DETECCIÓN AUTOMÁTICA DE CÁRCAVAS EN OLIVARES DE LA CUENCA DEL GUADALQUIVIR A TRAVÉS DE TÉCNICAS DE MACHINE LEARNING

Juan Ruben Julca Torres

Directores:

Adolfo Peña Acevedo – Departamento de Ingeniería Rural, Construcciones Civiles y Proyectos de Ingeniería.

Rafael González Perea – Departamento de Agronomía.

Palabras clave: erosión, cárcavas, machine learning, sensoriamiento remoto.

RESUMEN. La erosión de cárcavas constituye uno de los problemas de degradación del suelo más graves en las cuencas mediterráneas. En esta investigación se propone y evalúa un trabajo reproducible para detectar la red de cárcavas en olivares de la cuenca del río Guadalquivir, combinando técnicas de machine learning y teledetección. Las variables predictoras se obtuvieron a través de distintas plataformas, como Google Earth Engine, y posteriormente fueron reproyectadas, recortadas y resampladas a 2 m para su análisis en Jupyter Lab mediante Python. Tras depurar correlación y multicolinealidad ($VIF > 10$), se compararon distintos algoritmos de clasificación (Regresión logística, K-Nearest Neighbors, Support Vector Machine, Árbol de decisión, Random Forest y Extreme Gradient Boosting) mediante validación cruzada estratificada. Random Forest alcanzó el mejor desempeño ($AUC=0,989$; $F1=0,959$; $Accuracy=0,967$; $Precision=0,953$; $Recall=0,965$) y, tras su optimización con Grid Search, mejoró el AUC a 0,996. El análisis de importancia de variable reveló que el índice de iniciación de cabecera de cárcava, GHI (33,8%), la acumulación de flujo, A (27,8%) y el índice de inclinación normalizado, Ksn (20,6%) explican cerca del 82% de la capacidad predictiva. Finalmente, con el modelo optimizado se generó un mapa de probabilidad de cárcavas en tres clases (baja $<50\%$, media 50-85%, alta $>85\%$), constituyendo una herramienta útil para priorizar actuaciones de conservación del suelo.

ABSTRACT. Gully erosion is one of the most severe soil degradation processes in Mediterranean basins. This study proposes and evaluates a reproducible workflow to detect the gully network in olive groves of the Guadalquivir basin by combining machine learning techniques and remote sensing. Predictor variables were obtained from different platforms, such as Google Earth Engine, and subsequently reprojected, clipped, and resampled to 2 m for analysis in Jupyter Lab using Python. To avoid redundancy, correlation and multicollinearity were addressed ($VIF > 10$), and several classification algorithms (Logistic Regression, K-Nearest Neighbors, Support Vector Machine, Decision Tree, Random Forest, and Extreme Gradient Boosting) were compared using stratified cross-validation. Among them, Random Forest achieved the best performance ($AUC = 0,989$; $F1 = 0,959$; $Accuracy = 0,967$; $Precision = 0,953$; $Recall = 0,965$). After optimization with Grid Search, the model improved the AUC to 0,996. The variable importance analysis showed that the Gully Head Initiation Index, GHI (33,8%), flow accumulation, A (27,8%), and the Normalized Steepness Index, Ksn (20,6%) together explained nearly 82% of the predictive capacity. Finally, the optimized model was used to generate a gully probability map with three susceptibility classes (low $< 50\%$, medium 50–85%, high $> 85\%$), providing a practical tool to support soil conservation planning and decision-making.

1.- Introducción

La erosión del suelo representa una amenaza creciente para la sostenibilidad ambiental, la productividad agrícola y la seguridad alimentaria a nivel global (Borrelli et al., 2022; Panagos et al., 2024). Dentro de las formas más agresivas de degradación del suelo, la erosión en cárcavas tiene un papel destacado por su capacidad de transformar el paisaje de forma rápida e irreversible. Sus efectos incluyen en a pérdida de suelo fértil, daños a infraestructuras, incremento de la sedimentación en embalses y una disminución significativa en la funcionalidad de los ecosistemas (Poesen et al., 2003; Valentin et al., 2005; Kuhn et al., 2023). A pesar del avance en la investigación sobre este fenómeno (Castillo C., Gómez, J.A., 2016), su predicción, especialmente a escalas regionales o continentales, sigue siendo un reto considerable (Vanmaercke et al., 2021).

Actualmente, el 62 % de los suelos en la Unión Europea se consideran no saludables (Panagos et al., 2024), siendo la erosión del suelo uno de los principales procesos de degradación. En la mitad de las tierras cultivables de la UE se superan las pérdidas tolerables de suelo (Borrelli et al., 2022). Abordar estos problemas es, por tanto, una prioridad en la agenda política europea, y se ha presentado un ambicioso paquete de medidas para promover la salud del suelo a través de políticas como la Política Agrícola Común 2023-2027. El monitoreo obligatorio de la salud del suelo busca revertir la situación actual y lograr que todos los suelos estén en buen estado para 2050. Del mismo modo, la Ley de Restauración de la Naturaleza de la UE, acordada entre los Estados miembros, pretende regenerar los ecosistemas degradados, contribuir a los objetivos de clima y biodiversidad de la UE y mejorar la seguridad alimentaria, estableciendo como meta restaurar al menos el 20 % de las áreas terrestres y marinas para 2030, y todos los ecosistemas que lo necesiten para 2050 (European Parliament, 2024).

Los modelos comúnmente empleados para estimar la erosión del suelo, como la Ecuación Universal Revisada de Pérdida de Suelo (RUSLE), se centran en la erosión laminar y en surcos (Panagos et al., 2015; Tan et al., 2021). Como consecuencia, se subestiman tanto las tasas de pérdida de suelo como la ubicación de los focos críticos de erosión, especialmente en regiones vulnerables como las zonas semiáridas del Mediterráneo, donde los olivares tienen una alta susceptibilidad al desarrollo de cárcavas (Poesen et al., 2002; Hayas et al., 2017).

Este problema es particularmente visible en territorios como Andalucía, donde aproximadamente el 40 % del suelo presenta pérdidas severas, asociadas no solo a factores naturales como la fisiografía montañosa o el régimen climático, sino también al uso intensivo de la tierra y a prácticas agrícolas inadecuadas. La intensificación del cultivo sin medidas de conservación del suelo ha acelerado el proceso de formación de cárcavas en amplias zonas agrícolas.

Uno de los principales desafíos para predecir dónde se inician las cárcavas es la variabilidad que existe entre distintas regiones. Si bien diversos estudios han logrado identificar con éxito los puntos de inicio de cárcavas utilizando el modelo de umbral topográfico (TT) (Vandaele et al., 1996; Vandekerckhove et al., 1998, 2000; Imaizumi et al., 2010; Torri y Poesen, 2014), la mayoría de estas investigaciones se han llevado a cabo a escala local (Vanmaercke et al., 2021). De hecho, Hayas et al. (2017b, 2019), en su estudio sobre cabeceras de cárcavas en una cuenca de olivar mediterráneo, mostraron que el TT varía de un año a otro, en relación directa con la dinámica de la precipitación y la cobertura vegetal. Esto implica que, en áreas extensas donde varían la precipitación, la cobertura vegetal o las propiedades del suelo, el TT no puede considerarse constante. En este sentido, los enfoques estadísticos basados en machine learning podrían ofrecer una alternativa (Li et al., 2024), aunque siguen limitados por el alcance del conjunto de entrenamiento y presentan dificultades de extrapolación.

Las aplicaciones del modelo a escalas más amplias, como la regional, nacional o continental, siguen siendo escasas. Finalmente, modelos basados en procesos, como LANDPLANNER (Rossi, 2014) o el modelo de índice de iniciación de cabecera de cárcava, GHI (De Geeter S. et al., en revisión), muestran un gran potencial para superar esta limitación. El GHI está basado en la relación entre el índice de esfuerzo de corte (SSI) y el esfuerzo de corte crítico (CSS), teniendo en cuenta factores clave en el proceso de iniciación de cárcavas, como la precipitación, el número de curva (CN), el tipo de suelo, el porcentaje de arcilla, la pendiente local (S) y el área de drenaje en la cabeza de la cárcava (A). Este enfoque basado en procesos ofrece varias ventajas. En teoría, permite un modelo más universal, aplicable a distintas áreas de estudio, ya que la variabilidad espacial en las propiedades del suelo, la vegetación y la lluvia se puede tener en cuenta de manera explícita en la calibración de la escorrentía, evitando así depender de calibraciones específicas con datos de cabeceras de cárcavas, como ocurre con el TT.

En un estudio previo del Grupo de Investigación AGR-127 de la Universidad de Córdoba (González y Peña, comunicación interna), el GHI se ha aplicado a cuatro áreas de estudio de 25 km² de olivar, correspondientes a los principales paisajes ocupados por el cultivo, en la cuenca del Guadalquivir entre 2008 y 2019, identificándose tres clases de actividad de cárcavas, con un total de 261 cárcavas activas, 76 cárcavas de nueva formación y 138 cárcavas estables. En este estudio, además, se ha demostrado que el GHI distingue claramente entre píxeles de cárcavas y píxeles que no son cárcavas, con un valor de área bajo la curva (AUC) de 0,93. No obstante, el modelo no fue tan eficaz para diferenciar entre los tipos de actividad de cárcavas. Sin embargo, este estudio presenta varias limitaciones, por ejemplo, la precipitación fue obtenida de estaciones climatológicas cercanas y por lo tanto aplicarlo y automatizar este proceso a todo el olivar de la cuenca supone depender de esta disponibilidad de datos. Con respecto al cálculo de la tensión cortante crítica, solo se ha tenido en cuenta el porcentaje de arcilla (Nachtergaele et al., 2001), por lo que sería interesante tener en cuenta otras variables como algunos índices de vegetación.

En la última década, el uso de técnicas de machine learning para la detección y el mapeo de la susceptibilidad a la erosión por cárcavas ha avanzado notablemente. Los enfoques de inteligencia artificial han mostrado ventajas claras para modelar relaciones no lineales y multivariantes entre factores condicionantes (Arabameri et al., 2021). Por ejemplo, Saha et al. (2020) aplicaron cuatro algoritmos (Random Forest, Gradient Boosted Regression Tree, Naïve Bayes Tree y Tree Ensemble) en el este de la India, alcanzando AUC superiores a 0,90 y demostrando la capacidad de estos métodos para capturar interacciones complejas. De forma consistente, Arabameri et al. (2021) compararon algoritmos de ensemble y concluyeron que superan a los modelos individuales en capacidad predictiva y robustez. En paralelo, se han propuesto enfoques híbridos que integran inventarios continentales, como en el caso de Borrelli et al. (2025) usan el inventario paneuropeo de cárcavas GE-LUCAS v1.1 (3.116 localizaciones en la Unión Europea) para derivar patrones de erosión por cárcava y estimar la probabilidad de ocurrencia más allá de las localizaciones monitorizadas. En conjunto, estas investigaciones respaldan el uso de técnicas de machine learning para una detección más precisa de las zonas afectadas por cárcavas.

Por lo tanto, el objetivo principal del presente trabajo es detectar automáticamente la red de cárcavas en olivares de la cuenca del río Guadalquivir mediante técnicas de machine learning, con el fin de controlar su expansión y contribuir a la restauración

del suelo. Para ello, los objetivos específicos son:

- Analizar la correlación de las variables predictoras para evitar la multicolinealidad.
- Aplicar y comparar distintos algoritmos de clasificación, con el fin de encontrar el más óptimo en la detección de la red de cárcavas.
- Identificar las variables predictoras más relevantes para la detección de la red de cárcavas.
- Optimizar hiperparámetros del algoritmo seleccionado.
- Obtener de la red de cárcavas en olivares de la cuenca del Guadalquivir.

2.- Materiales y métodos

En la **Figura 1**, Flujograma de trabajo, se presenta el procedimiento de la investigación, el cual consiste en la obtención de variables predictoras a partir de distintas fuentes de información geoespaciales, incluyendo variables climáticas, topográficas, satelitales y edáficas. Estos datos fueron obtenidos mediante la plataforma Google Earth Engine y posteriormente sometidos a un proceso de pretratamiento que incluyó la reproyección, recorte y resamplero, con el fin de garantizar su homogeneidad y compatibilidad espacial.

Posteriormente, se aplicó un análisis de correlación y multicolinealidad para depurar las variables predictoras y seleccionar aquellas con mayor poder explicativo, evitando redundancia y sobreajustes en los modelos. Una vez definida la base de predictores, se evaluó el desempeño de distintos algoritmos de clasificación supervisada – Regresión logística, K-Nearest Neighbors (KNN), Support Vector Machine (SVM), Árbol de decisiones (AD), Random Forest (RF) y Extreme Gradient Boosting (XGBoost) – mediante validación cruzada estratificada. El algoritmo con mejores métricas de rendimiento será optimizado a través de técnicas de ajustes de hiperparámetros (Grid Search, Random Search, Bayesian Optimization).

Finalmente, con el modelo seleccionado y optimizado, se procedió a la generación de un mapa de probabilidad de la red de cárcavas, clasificando el territorio en función a distintos niveles de susceptibilidad. Todo el procesamiento de variables y análisis se llevó a cabo en la IDE Jupyter Lab utilizando el lenguaje de programación de Python.

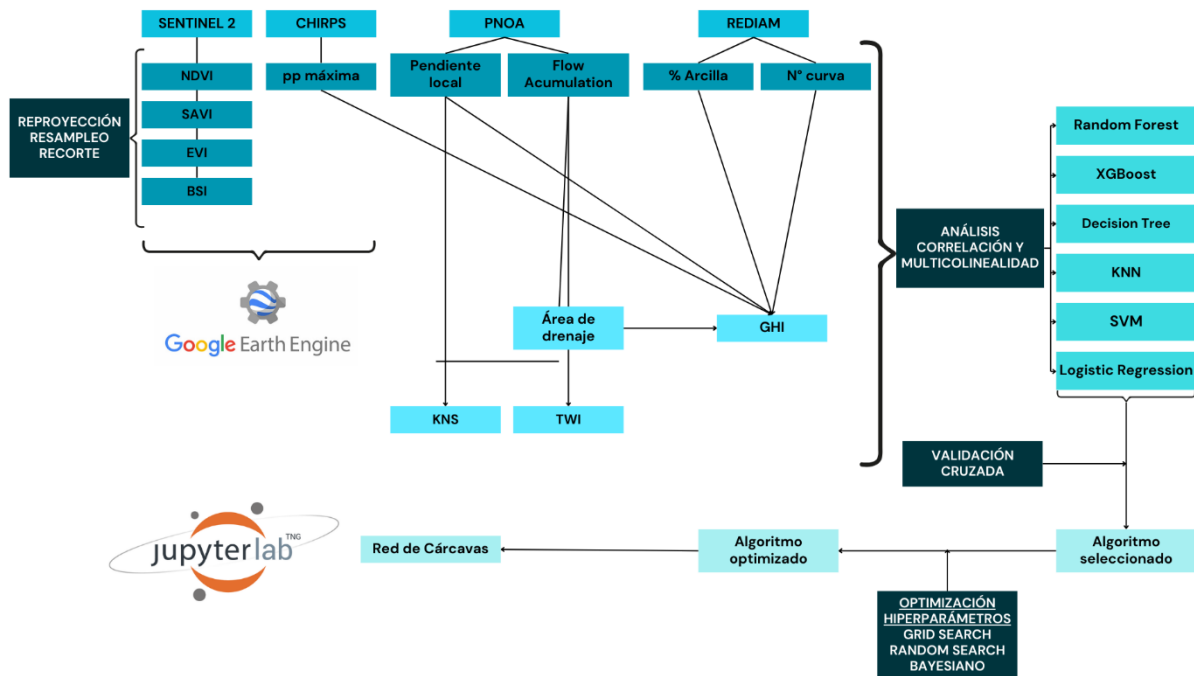


Figura 1. Flujograma de trabajo

2.1 Área de estudio

El área de estudio corresponde al área de cultivo de olivar dentro de la cuenca del río Guadalquivir, la cual conforma uno de los tres grandes territorios geológicos andaluces, abarcando una extensa superficie de 57.527 km², incluyendo porciones de las provincias de Jaén, Córdoba, Sevilla, Huelva y Cádiz. Para el presente estudio, se han elegido cuatro cuadrantes de 25 km², ubicados en las provincias Córdoba, Granada y Sevilla (**Figura 2**), representando cada uno, unas de las principales unidades de paisaje.

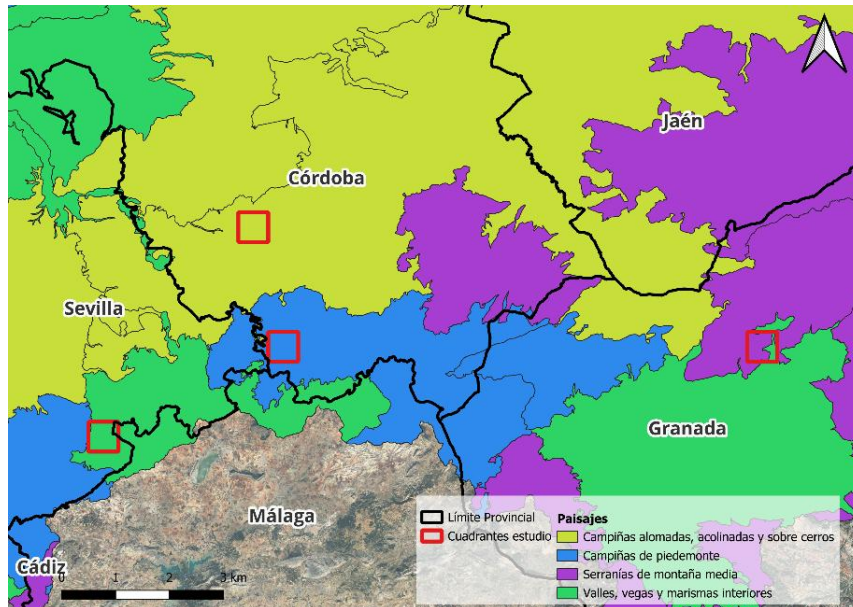


Figura 2. Ubicación de los cuadrantes de estudio

A pesar de que la Cuenca del río Guadalquivir presenta un relieve fundamentalmente llano, se observa una disminución paulatina de la cota desde el este, con unos 800 msnm, hacia el oeste, que llega al nivel del mar. El clima característico de esta área es mediterráneo, con temperaturas promedio de 16,8 °C al año, y unas precipitaciones anuales que se sitúan en torno a los 550 mm. A causa de los extensos periodos de estiaje, que facilitan la creación de costras superficiales, los terrenos de las zonas son bastantes propensos a la erosión. En las zonas más bajas del valle, sobresalen suelos arcillosos, como los vertisoles y luvisoles. En cambio, en las zonas más altas y de mayor pendiente, se encuentran terrenos arenosos poco desarrollados, como los cambisoles y regosoles (Junta de Andalucía, 2014). La erosión constante ha provocado que incluso en las áreas agrícolas más productivas del valle, los suelos sean pocos evolucionados, como los cambisoles o leptosoles.

El olivar es el cultivo principal en la cuenca del Guadalquivir, ocupando cerca de 1,7 millones de hectáreas (Ministerio de Agricultura, Pesca y Alimentación, 2024) (¡Error! No se encuentra el origen de la referencia.3). En dicha cuenca, este cultivo se reparte principalmente en cuatro unidades de paisaje, que comparten rasgos morfológicos, estructurales, texturales y visuales semejantes. Estas unidades son:

- Campiñas alomadas, acolinadas y sobre cerros
- Campiñas de piedemonte
- Serranías de montaña media
- Valles, vegas y marismas interiores

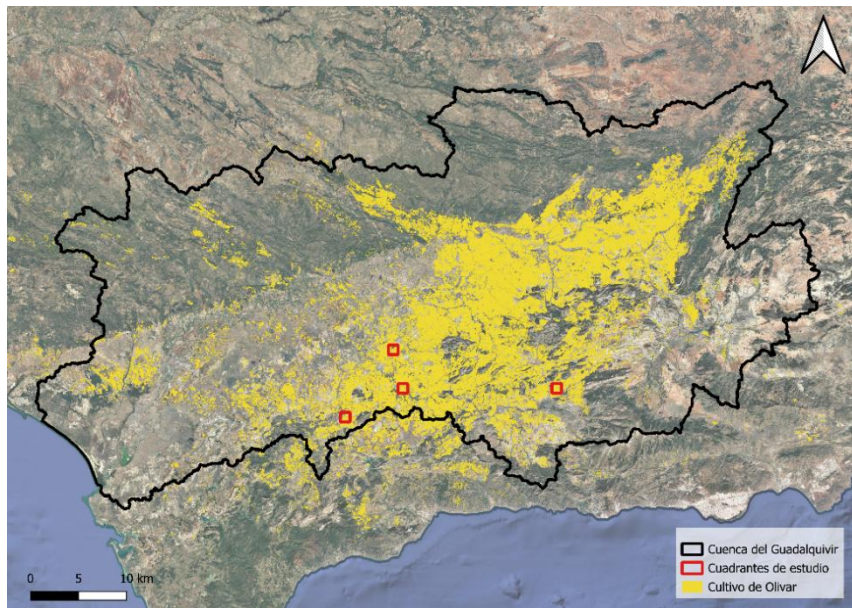


Figura 3. Cultivo de olivar en la cuenca del Guadalquivir

2.2 Variables predictoras

2.2.1 Descripción de variables

Precipitación Máxima (P)

Los datos de precipitación máxima para los cuadrantes de estudio serán obtenidos del conjunto de datos CHIRPS (Climate Hazards Groups Infrared Precipitation with Station data, <https://www.chc.ucsb.edu/data/chirps>), el cual ofrece información de alta resolución espacial ($0,05^\circ$). Este programa fue desarrollado en 1999 por el United States Geological Survey (USGS) y el Climate Hazards Center (CHC), con el objetivo de mejorar el monitoreo ambiental y de sequías, proporcionar alertas tempranas más precisas y contextualizar eventos actuales dentro de registros históricos. Además, fue diseñado para ser útil en regiones con escasas coberturas de datos de superficie, ya que integra observaciones satelitales con datos de estaciones pluviométricas (Funk *et al.* 2015)

Para este estudio la información será procesada y obtenida a través de Google Earth Engine, dónde se encuentra disponible con una resolución temporal diaria y una resolución espacial aproximada de 5 km.

Pendiente local (S), Acumulación de Flujo y Área de drenaje (A)

Para obtener estas variables, se generará un Modelo Digital de Elevación (DEM) con resolución de 2 metros a partir de los datos provenientes de vuelos LiDAR, con una densidad de 0,5 puntos/m², proporcionados por el Plan Nacional de Ortofotografía Aérea (PNOA, <https://pnoa.ign.es/>).

La Pendiente local (S) derivada directamente del DEM generado es definida como el ángulo entre la superficie del terreno y la horizontal, expresada tanto en grados como en porcentaje (Corporación Autónoma Región del Tolima, 2019).

La Acumulación de Flujo representa el número total de celdas que contribuyen al flujo hacia una celda descendiente específica. Las celdas con alta acumulación de flujo suelen indicar zonas de concentración del agua superficial, como cauces o canales, mientras que aquellas con valores bajos o nulos indican zonas elevadas o divisorias de agua (Jenson y Domingue, 1988).

Finalmente, se calculará el valor del Área de drenaje (A), entendido como la superficie total que aporta escorrentía superficial hacia un punto específico. Este valor será calculado a partir de la Ecuación 1:

$$\text{Área de drenaje} = \text{Acumulación de Flujo} * \text{Área de pixel} \quad (1)$$

Número de Curva (NC) y Porcentaje de Arcilla (Pc)

La Red de Información Ambiental de Andalucía (REDIAM, <https://www.juntadeandalucia.es/medioambiente/portal/acceso-rediam>) es una plataforma que integra y difunde información geoespacial en temática ambiental generada por diversos organismos, tantos públicos como privados, dentro de la comunidad autónoma de Andalucía. Entre los datos disponibles en la REDIAM, se encuentran el Número de Curva y el Porcentaje de Arcilla.

El Número de Curva en una metodología para estimar escorrentía superficial en función al uso del suelo y otras características del terreno, en dónde valores cercanos a 0 indican superficies sin escurrimientos aparente, mientras que valores cercanos a 100 representan superficies impermeables (ANA,2015). Por otro lado, el Porcentaje de Arcilla representa la fracción del suelo compuesta por partículas de arcilla, expresada como un porcentaje del peso total de partículas.

Ambos productos se encuentran disponible en formato ráster y con cobertura para todo el territorio Andaluz. Además, dichos rásteres cuentan con una resolución espacial de 20 metros para el número de curva y 100 metros para el porcentaje de arcilla.

GHI índice

El índice de iniciación de cárcavas (GHI) supone que éstas se forman cuando la tensión de corte de escorrentía es mayor que la resistencia del suelo a esta, Ecuación (2):

$$\tau > \tau_{cr} \quad (2)$$

Donde: τ es la tensión cortante de escorrentía [Pa] y τ_{cr} es la tensión cortante crítica del suelo [Pa].

Usando la siguiente ecuación (Nearing et al., 1997) se calcula la tensión cortante de escorrentía, Ecuación (3):

$$\tau > \rho gRS \quad (3)$$

Donde: ρ representa la densidad del agua [kg/m³], g la gravedad [N/kg], R el radio hidráulico [m] y S la pendiente local [m/m].

R es difícil de determinar ya que suelen desconocerse el ancho del canal y la profundidad de flujo. En este caso se utiliza el método del número de curva (NC) para obtener la profundidad de escorrentía. La ecuación del método del NC es la siguiente (Hawkins et al., 2009), según la Ecuación (4):

$$R_d = \frac{(P - \lambda S_\lambda)^2}{P + (1 - \lambda)S_\lambda} \quad (4)$$

Donde: R_d es la profundidad de escorrentía diaria, P es la profundidad de lluvia diaria (mm) y S_λ las pérdidas potenciales máximas de escorrentía.

Para calcular S_λ se utiliza la Ecuación 5 (Hawkins et al., 2009):

$$S_{0,05} = 33,96 \left(\frac{100}{NC} - 10 \right) \quad (5)$$

A continuación, multiplicando R_d por el área de drenaje, A [m²] se obtiene el volumen de descarga diario Q [m³]. Se utiliza Q como sustituto del ratio hidráulica R y, descartando las constantes ρ y g , podemos relacionar la tensión de corte con el índice del esfuerzo de corte, Ecuación (6):

$$SSI = Q * S \quad (6)$$

Para el cálculo del índice esfuerzo de corte crítico (CSS), se utiliza la Ecuación (7) (Nachtergaele et al., 2001):

$$CSS = 0.311 * 10^{0,0182Pc} \quad (7)$$

Donde Pc es el % de arcilla en cada punto analizado en el estudio.

Por último, combinando las ecuaciones 6 y 7, se obtiene el índice de iniciación de cabecera de cárcava, Ecuación (8):

$$GHI = \frac{SSI}{CSS} \quad (8)$$

Cuando mayor sea el valor del GHI, más probabilidad de formarse una cabecera de una cárcava.

Índices Espectrales

Para obtener estos índices, se empleará las imágenes satelitales de Sentinel – 2, la cual es una misión de observación terrestre desarrollado por la Agencia Espacial Europea (ESA), la Comisión Europea y otros actores del sector espacial. Esta misión está compuesta por dos satélites gemelos, Sentinel – 2A y Sentinel – 2B, ubicados en la misma órbita polar, pero con un desfase de 180°, lo que le permite cubrir grandes extensiones de terreno en menos tiempo. Sentinel – 2A fue lanzado el 23 de junio del 2015, mientras que Sentinel – 2B el 7 marzo del 2017 (ESA, 2019)

Ambos satélites están equipados con un sensor óptico multispectral que registra información de 13 bandas espectrales, 4 de ellas con una resolución espacial de 10 metros, 6 con 20 metros y 3 con 60 metros. Individualmente cada satélite ofrece una resolución temporal de 10 días, pero al operar en conjunto, es posible obtener imágenes con una frecuencia de hasta 5 días, bajo las mismas condiciones de observación.

La misión Sentinel – 2 proporciona productos a distintos niveles de procesamiento. Para obtener los índices espectrales, se empleará el producto de Nivel 2A, el cual ya ha sido corregido atmosféricamente. Esto permite trabajar con valores de reflectancia a nivel de superficie (Bottom of Atmosphere Reflectance, BOA), ofreciendo una mejor calidad visual y eliminando efectos de componentes atmosféricos que puedan distorsionar los valores de reflectancia.

Normalized Difference Vegetation Index (NDVI)

Es el más común de los índices de vegetación, basado en la relación entre la reflectancia le región espectral del rojo y el infrarrojo cercano, aprovechando que la vegetación sana absorbe fuertemente la radiación roja y refleja intensamente en el infrarrojo. Valores bajos de reflectancia en la banda roja combinados con altor en la infrarroja indican mayor actividad fotosintética, mayor cantidad de biomasa y un mejor estado de la vegetación. Por ello, el NDVI se asocia con la actividad fotosintética, la fenología y la condición general de las plantas, tanto en cultivos como en la vegetación natural (INEGI, 2022). Su cálculo se realiza mediante la Ecuación (9):

$$NDVI = \frac{NIR - RED}{NIR + RED} \quad (9)$$

Soil Adjusted Vegetation Index (SAVI)

El índice SAVI fue desarrollado por Huete (1998) para el seguimiento de la cobertura vegetal en situaciones en las cuales el NDVI pierde sensibilidad debido a la saturación de sus valores máximos. Se aplica especialmente en cultivos jóvenes y con superficies expuestas del suelo, usando la región espectral del rojo e infrarrojo, agregándole un factor L , el cual corrige los efectos del suelo (Castellanos et al., 2016). Su formulación se presenta en la Ecuación (10):

$$SAVI = \frac{NIR - RED}{NIR + RED + L} * (1 + L) \quad (10)$$

Enhanced Vegetation Index (EVI)

Es un índice espectral desarrollado para superar algunas limitaciones del NDVI, ya que incorpora coeficientes de corrección atmosféricas (C1 y C2) y un factor de ajuste del fondo del suelo y del dosel (L). Estas modificaciones permiten reducir la influencia del suelo y de los efectos de la atmósfera a la señal espectral, mejorando el análisis de la vegetación bajo estas dificultades (Boegh et al., 2002). Se calcula mediante la Ecuación (11):

$$EVI = \frac{NIR - RED}{NIR + C1 * RED - C2 * BLUE + L} \quad (11)$$

Bare Soil Index (BSI)

Es un índice espectral diseñado para identificar y cuantificar áreas de suelo sin cobertura vegetal en un paisaje (INEGI, 2024). Se construye a partir de la combinación de las bandas espectrales rojo, azul infrarrojo cercano (NIR) y de onda corta (SWIR), lo que permite discriminar suelos desnudos de superficies vegetales. Valores positivos indican presencia de suelo desnudo o de escasa vegetación, mientras que valores negativos indicaran áreas con cobertura vegetal. Su cálculo se realiza según la Ecuación (12):

$$BSI = \frac{(SWIR+RED)-(NIR+BLUE)}{(SWIR+RED)+(NIR+BLUE)} \quad (12)$$

Topographic Wetness Index (TWI)

Este índice fue desarrollado por Beven y Kirkby (1979), siendo ampliamente utilizado para describir el control topográfico sobre procesos hidrológicos, como la humedad del suelo y las condiciones de agua (Sørensen, 2006). Dicho índice se calcula a partir del área de drenaje (A) y la pendiente local (S), según la Ecuación (13):

$$TWI = Ln \frac{(\text{Área de drenaje})}{(\text{Pendiente Local})} \quad (13)$$

Normalized Steepness Index (Kns)

Es un índice derivado de la relación entre pendiente y área de drenaje, que se obtiene ajustando los datos de perfiles hídricos a una concavidad de referencia. Su utilidad radica en que permite comparar objetivamente la inclinación de diferentes canales y relacionarlos con factores como la tasa de levantamiento tectónico o procesos erosivos, independientemente de variaciones locales en el perfil longitudinal de drenaje. (Snyder, 2006). Se calcula mediante la Ecuación (14):

$$Kns = \text{Pendiente Local} * (\text{Área de drenaje})^{0,45} \quad (14)$$

2.2.2 Procesamiento de variables

Una vez obtenidas las variables necesarias, se procederá al procesamiento de la información en la IDE Jupyter LAB utilizando el lenguaje de programación Python.

En este proceso, primero se realizará la reproyección de las variables al sistema de coordenadas ETS 89/UTM zona 30N (EPSG: 25830), el cual es adecuado para la ubicación de los cuatro cuadrantes de estudio, permitiendo trabajar con mayor precisión en la zona de estudio.

Posteriormente, se realizará un recorte de los rásteres para ajustar las variables a los límites de los cuatro cuadrantes de estudio, asegurando que solo se incluyera la información relevante para el área de interés y eliminando los datos fuera de estos cuadrantes.

Finalmente, se realizará un resamplio para homogenizar el tamaño de píxel de las distintas variables. Este proceso permitirá establecer un tamaño de píxel uniforme de 2 metros, lo que facilitó la integración adecuada de las variables en los análisis posteriores.

2.3 Análisis de correlación y multicolinealidad

Para evaluar la relación entre las variables predictoras y la variable predicha, así como detectar redundancias entre predictores, se aplicará un análisis de correlación y multicolinealidad. Como primer paso, se calculará la matriz de correlación de Pearson, la cual mide la fuerza de la relación lineal entre pares de variables y toma valores entre -1 y 1, donde los valores próximos a ± 1 indican asociaciones lineales fuertes y los cercanos a 0 reflejan ausencia de correlación (Benesty, 2009). Esto permitirá identificar tanto la correlación de cada variable con la variable predicha (presencia/ ausencia de cárcavas) como la existencia de asociaciones altas entre predictores.

Posteriormente, se evaluará la multicolinealidad entre las variables predictoras mediante el cálculo del Factor de Inflación de Variancia (VIF), el cual cuantifica cuanto se incrementa la varianza de un coeficiente debido a la colinealidad con otros predictores. En esta investigación se adoptará el criterio metodológico de considerar problemáticas aquellas variables predictoras con valores de VIF superiores a 10, ya que asume una multicolinealidad severa (Saha et al, 2020).

En caso de una variable predictora supere este umbral, será excluido del conjunto de variables predictores con el fin de reducir redundancia y evitar inestabilidad en los modelos. De este modo, se permitirá garantizar un conjunto de predictores más estables para la construcción del modelo de clasificación.

2.4 Comparación y selección del algoritmo

Se utilizarán y compararán diversos algoritmos de clasificación de machine learning con el objetivo de identificar el modelo más eficiente para la detección de cárcavas.

2.4.1. Algoritmos evaluados

Regresión Logística (RL)

La regresión logística es un algoritmo de aprendizaje supervisado ampliamente utilizado para problemas de clasificación binaria. Su propósito es estimar la probabilidad de que una observación pertenezca a una de dos clases posibles, lo cual lo convierte en una herramienta fundamental cuando la variable dependiente es categórica dicotómica. A diferencia de la regresión lineal, que puede producir valores fuera del rango de probabilidades, la regresión logística emplea la función logística o sigmoide, garantizando que las estimaciones se encuentren entre 0 y 1. Se caracteriza por su simplicidad, interpretabilidad y eficiencia, aunque presenta limitaciones cuando las relaciones entre las variables no son lineales (García, 2023).

K-Nearest Neighbors (KNN)

KNN es uno de los algoritmos más sencillos de clasificación supervisada, introducido por Cover y Hart (1967). Asigna la clase a una nueva instancia en función de las clases de su K-vecinos más cercanos, de acuerdo con una métrica de distancia (generalmente la euclídea). Si bien su implementación es simple y no requiere una fase de entrenamiento explícita, su desempeño depende de la elección adecuada de K y de la medida de distancia. KNN suele funcionar bien en problemas con fronteras de decisión complejas, pero puede degradar su rendimiento en presencia de ruido o alta dimensionalidad.

Support Vector Machine (SVM)

Fue propuesta por Cortes y Vapnik (1995), siendo un algoritmo supervisado basado en la teoría del aprendizaje estadístico. Su objetivo es encontrar el hiperplano óptimo que maximiza el margen entre las clases en el espacio de las características. Aquellas observaciones más cercanas al hiperplano se denominan “vectores de soporte” y son las que determinan la frontera

de decisión. Una de sus fortalezas es que, mediante funciones Kernel, permiten proyectar los datos a espacios de mayor dimensión para resolver problemas no lineales. Son particularmente eficaces en problemas de alta dimensionalidad y con conjunto de datos limitados, aunque requieren de ajustes cuidados de parámetros como el tipo de Kernel y los coeficientes de regularización.

Árbol de decisión (AD)

Los árboles de decisión son modelos que dividen recursivamente el espacio de las variables en regiones cada vez más homogéneas respecto a la clase objetivo (Quinlan, 1996, 1996b). Su estructura se asemeja a un árbol, los nodos representan condiciones sobre variables de entrada, las ramas reflejan los resultados de esas condiciones y las hojas contienen la predicción final. Su atractivo radica en la simplicidad, facilidad de visualización e interpretación, lo que los hace ampliamente utilizados en ciencias aplicadas. No obstante, presentan limitaciones, como el sobreajuste de los datos si se dejan crecer sin restricciones, y suelen ser menos estables, ya que pequeñas variaciones en los datos pueden cambiar significativamente la estructura del árbol.

Random Forest (RF)

El algoritmo Random Forest, introducido por Breiman (2001), es un método de ensamble que combina múltiples árboles de decisión entrenados sobre diferentes subconjuntos de datos y características. Cada árbol vota por una clase (en clasificación) o da un valor promedio (en regresión), y el resultado final surge de la agregación de todas las predicciones. Esta estrategia permite reducir la varianza respecto a un árbol individual y mejorar la capacidad de generalización del modelo. Una de sus principales ventajas es su robustez frente al ruido y su capacidad de manejar grandes volúmenes de datos y variables, además de ofrecer estimaciones de importancia de variables, lo que facilita la interpretación en contextos aplicados.

Extreme Gradient Boosting (XGBoost)

XGBoost es una implementación optimizada del algoritmo de “Gradient boosting”, diseñada para ser eficiente y escalable (Chen, T., Guestrin, C., 2016). El método construye modelos aditivos en forma secuencial, donde cada nuevo árbol busca corregir los errores cometidos por los anteriores. Se distingue de otros métodos de boosting por la incorporación de técnicas de regularización (L1 y L2) que ayudan a controlar el sobreajuste, así como por optimizaciones por paralelización y manejo de memoria que permiten trabajar con grandes volúmenes de datos. Su efectividad y velocidad lo han convertido en un referente en competiciones de aprendizaje automático y aplicaciones reales en distintas disciplinas.

2.4.2. Validación Cruzada

Para evaluar el desempeño de cada algoritmo, se utilizará la técnica de validación cruzada estratificada, la cual divide el conjunto de datos de entrenamiento en 10 Folds de manera estratificada, asegurando que cada pliegue tenga la misma proporción de clases que el conjunto original. Además, el proceso se repetirá 3 veces con diferentes particiones, lo que permitirá reducir la varianza asociada a una única división de los datos y obtener una evaluación más fiable. Los resultados de cada repetición serán promediados para permitir una comparación más robusta entre los modelos, con el fin de seleccionar el algoritmo que mejor se ajuste a nuestros datos.

Esta técnica busca utilizar una parte limitada de los datos para estimar cómo se espera que los modelos funcionen al hacer predicciones de los datos no vistos durante el entrenamiento, lo cual garantiza una evaluación más fiable (Serra, 2020).

Para ello, se considerarán distintas métricas de rendimiento con el fin de analizar de manera integral el rendimiento de los modelos de clasificación (García, 2023).

- Accuracy (Exactitud): Indica que tan bien acierta el modelo en general, siendo la proporción de predicciones correctas sobre el total de casos.
- Precision (Precisión): Mide que tan confiables son las predicciones positivas del modelo. De todos los casos que el modelo indicó como positivos, la precisión indica cuántos realmente lo eran.
- Recall (Sensibilidad): Indica la capacidad del modelo para encontrar todos los casos positivos.
- F1 Score: Combina la precisión y recall en una sola métrica. Sirve para equilibrar ambos aspectos, sobre todo cuando las clases están desbalanceadas.
- AUC (Área bajo de la Curva): Indica la capacidad del modelo para diferenciar entre clases. Valores cercanos a 1 indican que el modelo separa muy bien las clases, mientras que un valor de 0,5 significa que el modelo no es mejor que adivinar al azar.

2.5 Análisis de importancia de variables

Una vez seleccionado el algoritmo más adecuado, se realizará un análisis de importancia de variables para identificar cuales tienen un mayor peso en la predicción de la red de cárcavas, permitiendo así obtener una mejor comprensión de cómo estas variables influyen en el modelo.

La importancia relativa de cada variable predictora se obtendrá a partir de la contribución de las variables en reducir la impureza en cada división del conjunto de árboles. Para ello, se visualizará mediante un gráfico la importancia en porcentaje de cada variable, lo que facilitará su interpretación.

Además, se mostrará la importancia acumulada mediante una curva de Pareto, al cual permitirá cuales son las variables predictoras que concentran la mayor parte de la capacidad predictiva del modelo. Este gráfico nos permitirá evaluar la posibilidad de reducir la cantidad de variables sin comprometer la capacidad del modelo en la detección de cárcavas.

2.6 Optimización del modelo

Se procederá a realizar el ajuste de los hiperparámetros del algoritmo elegido, mediante la comparación y evaluación de los métodos Grid Search, Random Search y Bayesian Optimization. Esto se realizará con el objetivo de identificar el método que brinde la mayor mejora de las métricas de rendimiento.

El método de Grid Search consiste en una exploración exhaustiva de todas las combinaciones dentro de un espacio de búsqueda predefinida. Esta técnica garantiza la identificación de la mejor configuración dentro del espacio indicado, aunque presenta un elevado coste computacional, especialmente cuando el número de parámetros y valores aumentan (Taiwo y Lyamolere, 2025).

Por su parte, Random Search selecciona de manera aleatoria un subconjunto de configuraciones dentro del mismo espacio. Este método conserva la simplicidad de implementación y resulta más eficiente en la práctica, debido a que con un número limitado de evaluaciones puede encontrar configuraciones cercanas o incluso superiores a las obtenidas mediante Grid Search, evitando así la exploración innecesaria de hiperparámetros poco relevantes (Bergstra y Bengio, 2012).

Finalmente, Bayesian Optimization es un método que no se limita a probar combinaciones al azar, sino que aprende de los intentos anteriores para decidir en qué zonas del espacio de búsqueda conviene seguir explorando. De este modo, concentra los esfuerzos en las configuraciones con mayor probabilidad de mejora, lo que le permite encontrar combinaciones de alto rendimiento utilizando un número reducido de evaluaciones (Garnett, 2023).

En este caso, la métrica específica de evaluación será el Área Bajo de la Curva ROC (AUC), ya que nos permitirá evaluar de manera efectiva la capacidad del modelo para distinguir entre clases, especialmente en problemas de clasificación desbalanceada.

La comparación de estas técnicas permitirá analizar el impacto de la optimización sobre el rendimiento del modelo y determinar si los ajustes realizados contribuyen significativamente a mejorar las métricas de rendimiento.

2.7 Generación de la red actual de cárcavas

Con el algoritmo seleccionado y optimizado, se procederá a la generación de la red de cárcavas realizando una clasificación probabilística, en el que cada píxel se clasificará en función a la probabilidad de representar presencia de cárcavas.

Bajo este enfoque, las clasificaciones fueron agrupadas en las siguientes tres categorías:

- No cárcava (probabilidades menores al 50%)
- Probabilidad media de cárcava (probabilidades entre 50 y 85%)
- Probabilidad alta de cárcava (probabilidades superiores al 85%)

Además, debido al gran tamaño de los datos, se realizará el procesamiento mediante bloques, lo que permitirá manejar grandes volúmenes de datos, sin agotar la memoria del sistema.

Como resultado se obtendrá un ráster categórico que nos permitirá identificar las áreas más susceptibles a la presencia de cárcavas, brindando una herramienta eficaz para la planificación territorial y la priorización de intervenciones según el nivel de riesgo.

3.- Resultados y discusión

3.1 Análisis de correlación y multicolinealidad

Al analizar la correlación de Pearson, se revelaron tendencias importantes entre las variables predictoras y la clasificación de cárcavas, como puede observarse en la **Figura 4**. El Topographic Wetness Index (TWI) presentó la mayor correlación positiva con la clasificación de cárcavas ($r=0,76$), seguido por el Normalized Steepness Index (Kns) ($r=0,51$) y el Gully Head Initiation Index (GHI) ($r=0,30$). Estos resultados concuerdan con estudios previos como los de Rahmani et al. (2016) y De Geeter et al. (2023) que indican que tanto el TWI, como el Kns tienen una correlación positiva e importancia razonablemente aceptable en la aparición de cabeceras de cárcavas. Por el contrario, los índices de vegetación como SAVI, EVI y NDVI mostraron correlaciones negativas con la clasificación de cárcavas, dando a entender que la cobertura vegetal brinda una protección contra la erosión del suelo, reduciendo la formación de cárcavas.




Figura 4. Coeficiente de correlación de Pearson entre las variables predictoras y la clasificación de cárcavas

La **Figura 4** muestra que existen variables que tienen una alta correlación entre sí, lo cual puede generar problemas de multicolinealidad al introducir redundancia en los modelos predictivos. Como resultado de este análisis se obtuvo que la acumulación de flujo y el área de drenaje cuentan con una correlación perfecta ($r=1$), así como entre SAVI, NDVI y EVI ($r=0,94$ - $0,95$). Este comportamiento se mostró con el análisis de Factor de Inflación de Varianza (VIF), con el que se pudo observar que el área de drenaje presentó un valor infinito y el SAVI alcanzó un valor de 26,76, alcanzando una multicolinealidad alta. En consecuencia, estas variables fueron excluidas de las variables predictoras para evitar sobreajustes y redundancia.




Figura 5. Matriz de correlación de Pearson entre las variables predictoras y la clasificación de cárcavas

Como resultado de este análisis, se conservaron 11 variables con valores VIF inferiores a 8, considerados aceptables para evitar multicolinealidad severa. Este criterio es respaldado por trabajos como los de Baiddah et al. (2023), Lei et al. (2020) y Saha et al. (2020), quienes proponen como buenas prácticas mantener los VIF por debajo de 10, al considerar que valores superiores pueden comprometer la calidad del modelo (Tabla 1).

Tabla 1. Factor de Inflación de Varianza (VIF)

Variable	VIF
A Drenaje	Inf
SAVI	26,76
Kns	7,31
EVI	7,22
GHI	5,89
NDVI	4,33
BSI	3,30
TWI	3,14
Flow Acum	2,38
Pendiente	1,99
Arcilla	1,44
Preci max	1,36
Num curv	1,08

3.2 Comparación y elección del algoritmo

Como se muestra en la **Tabla 2**, los modelos que obtuvieron mejores métricas de rendimiento fueron Random Forest (RF), XGBoost y Support Vector Machine (SVM), todos con valores de AUC superiores a 0,989, precision mayores a 0,950, Accuracy por encima de los 0,964 y F1-Score superior a 0,950. Estos resultados están acordes con el estudio de Saha et al. (2020), realizado en la India, dónde se reportó una precision de 1, accuracy de 0,7 y un AUC de 0,96 para RF, destacando como el algoritmo más eficaz en la detección de cárcavas en su área de estudio. De igual manera, Arabameri et al. (2021), en un estudio realizado en Irán, concluyeron que RF y XGBoost presentaron las mejores métricas de rendimiento, con AUC mayores a 0,933, accuracy de 0,684 y un recall superior a 0,909, superando a modelos como SVM y Regresión Logística (RL).

Tabla 2. Algoritmos de clasificación y métricas de evaluación

Algoritmo	F1-Score	Accuracy	Precision	Recall	AUC
RF	0,959	0,967	0,953	0,965	0,989
XGBoost	0,956	0,964	0,950	0,963	0,990
SVM	0,954	0,964	0,955	0,955	0,990
KNN	0,953	0,963	0,944	0,964	0,987
RL	0,949	0,960	0,946	0,954	0,988
AD	0,930	0,945	0,924	0,937	0,943

Otros estudios refuerzan estos hallazgos, como Lei et al. (2020), en Irán, en dónde compararon cuatro modelos de clasificación y concluyeron que RF fue el modelo más eficiente, con un AUC de 0,872, accuracy de 0,826 y recall de 0,853, superando a modelos como Kernel Logistic Regression y variantes de árboles de decisiones. Por su parte, Baiddah et al. (2023), en Marruecos, evaluaron algoritmos como AD, KNN, RL y Linear Discriminate Analysis, siendo KNN el modelo que obtuvo mejores métricas, con un AUC 0,932, accuracy de 0,89 y recall de 0,90. Este resultado es similar a los obtenidos en este estudio, en dónde KNN también superó a RL y AD, aunque sin alcanzar el desempeño de RF, XGBoost y SVM.

A pesar de XGBoost y SVM obtuvieron un AUC ligeramente superior (0,990) respecto a RF (0,989), esta diferencia fue mínima y no significativa. En cambio, RF superó a ambos modelos en métricas como F1-Score (0,959), accuracy (0,967) y recall (0,965), lo que refleja un mayor equilibrio entre precisión y sensibilidad. Además, RF se distingue por su robustez frente al sobreajuste, su capacidad de capturar relaciones no lineales complejas y su facilidad para evaluar la importancia de variables, aspectos especialmente valiosos en contextos geoespaciales con múltiples predictores. En conjunto, estos factores justifican la elección de Random Forest como modelo final para los posteriores análisis.

3.4 Importancia de variables

Los resultados obtenidos en la *¡Error! No se encuentra el origen de la referencia.6* muestran que las variables con mayor influencia en el modelo son el GHI (33,72%), el Normalized Steepness Index (23,82%) y la acumulación de flujo (21,60%) y Estas tres variables, asociadas principalmente a la dinámica hídrica y topográfica del terreno, representan aproximadamente el 80% de la importancia total del modelo. Este hallazgo resalta la relevancia de los procesos geomorfológicos y de ecorrenia en la formación de cárcavas. Además, variables como la precipitación máxima no tienen gran relevancia en la predicción de cárcavas, lo cual sugiere que puedan utilizarse otras variables como valores medios de precipitación o días con precipitaciones superiores a un umbral (Hayas et.al., 2017).

Al comparar estos resultados con otros estudios, como Lei et al (2020), quienes identificaron a la densidad de drenaje como unas de las variables más influyentes en la predicción de cárcavas. Esta variable está estrechamente relacionada con el flujo acumulado, que en nuestro modelo también figura como una de las variables con mayor importancia. Además, también reportaron que tanto la pendiente como el NDVI presentaron una importancia menor al 6%, lo que coincide con los bajos valores de importancia en nuestro análisis para estas variables. De forma similar, los estudios de Baiddah et al. (2023) y Rahmati et al. (2016) destacan que la densidad drenaje tuvo una mayor importancia que otras variables como el TWI, textura del suelo y NDVI, lo cual refuerza la relevancia de variables relacionadas a la acumulación y escurrimiento del agua superficial, también evidenciada en los resultados de la investigación. Finalmente, Gonzales y Peña (2025, comunicación interna) señalaron al GHI como una variable crítica para poder discriminar entre áreas que son cárcavas y que no son cárcavas,

por lo que se validan nuestros resultados al posicionar a esta variable como la más influyente del modelo.




Figura 6. Importancia relativa de las variables predictoras

Además, en el análisis de importancia acumulada de variables presentada en la *¡Error! No se encuentra el origen de la referencia.7* se puede observar que con solo tres variables se alcanza aproximadamente el 80% de la importancia total del modelo. La inclusión de una cuarta variable, el TWI, eleva la importancia acumulada a un valor cercano al 90%, lo que sugiere que estas cuatro variables en conjunto explican la gran mayoría del comportamiento del modelo. Para alcanzar el 95%, se requiere de siete variables, incluyendo los índices espectrales y la pendiente local, aunque su aporte marginal individual es considerablemente menor. Las últimas 3 variables de la figura presentan contribuciones por debajo del 3,5%, lo que las posiciona como factores secundarios en este modelo.




Figura 7. Importancia acumulada de las variables productoras

3.3 Optimización y evaluación del modelo

Después de haber seleccionado al algoritmo Random Forest como el modelo más adecuado, se procedió a definir los hiperparámetros a optimizar mediante las 3 técnicas evaluadas. Los espacios considerados se presentan en la **Tabla 3**.

Tabla 3. Definición de hiperparámetros para las técnicas de optimización

Hiperparámetros	Grid Search y Random Search	Bayesian Optimization
N Estimators	50, 100, 200, 300	Integer (50, 300)
Max Depth	3, 5, 10, 15, 20, None	Integer (3, 20)
Min Samples Split	2, 5, 10, 15	Integer (2, 15)
Min Samples Leaf	1, 2, 4, 8	Integer (1, 8)
Max Features	Sqrt, log ₂ , None	Categorical (Sqrt, log ₂ , None)
Bootstraps	True, False	Categorical (True, False)

Los resultados mostrados en la **Tabla 4** muestran que Grid search obtuvo el mejor rendimiento en comparación de las otras dos técnicas, alcanzando un AUC de 0,996, F1-Score de 0,956, accuracy de 0,964, precision de 0,916 y recall de 1. A pesar de que las técnicas Bayesianas y Random search lograron resultados competitivos con AUC de 0,996 y 0,994 respectivamente, los cuales se observan en la **Figura 10**, Grid Search presentó ventajas en las otras métricas de rendimiento.

Tabla 4. Métricas de rendimiento de las técnicas de optimización

	F1 - Score	Accuracy	Precisión	Recall	AUC
Grid Search	0,956	0,964	0,916	1	0,9957
Random Search	0,948	0,958	0,914	0,985	0,9944
Bayesian optimization	0,949	0,958	0,903	1	0,9956

Este resultado está acorde con los hallazgos de estudios previos que han utilizado técnicas de optimización de hiperparámetros en Random Forest para tareas de clasificación en contexto geoespaciales, como es el caso de Kanwar et al. (2025) en su estudio sobre el mapeo de susceptibilidad de deslizamiento de tierra, aplicaron Grid Search para la optimización de Random Forest, logrando un AUC de 0,932 a comparación de otros algoritmos como SVM y RL, en donde el AUC no superó el valor de 0,86. Este resultado es consistente con los nuestros en cuanto a la efectividad de Grid Search para mejorar el rendimiento del modelo.

En la **Figura 8** se puede observar la matriz de confusión de las 3 técnicas, en donde Grid Search y Bayesian Optimization no cometieron falsos negativos, lo que indica que ambos modelos identificaron correctamente todas las instancias de cárcavas, mostrando un recall perfecto. Sin embargo, ambos modelos presentaron 7 falsos positivos, clasificando erróneamente 7 muestras de no cárcava como cárcava. Por otro lado, Random Search cometió 1 falso negativo y también 7 falsos positivos, lo que sugiere que aunque su recall fue ligeramente inferior, su desempeño sigue siendo sólido. En general, los tres modelos mostraron un buen desempeño en la identificación de cárcavas, pero Grid Search y Bayesian Optimization destacaron por su capacidad de evitar falsos negativos.

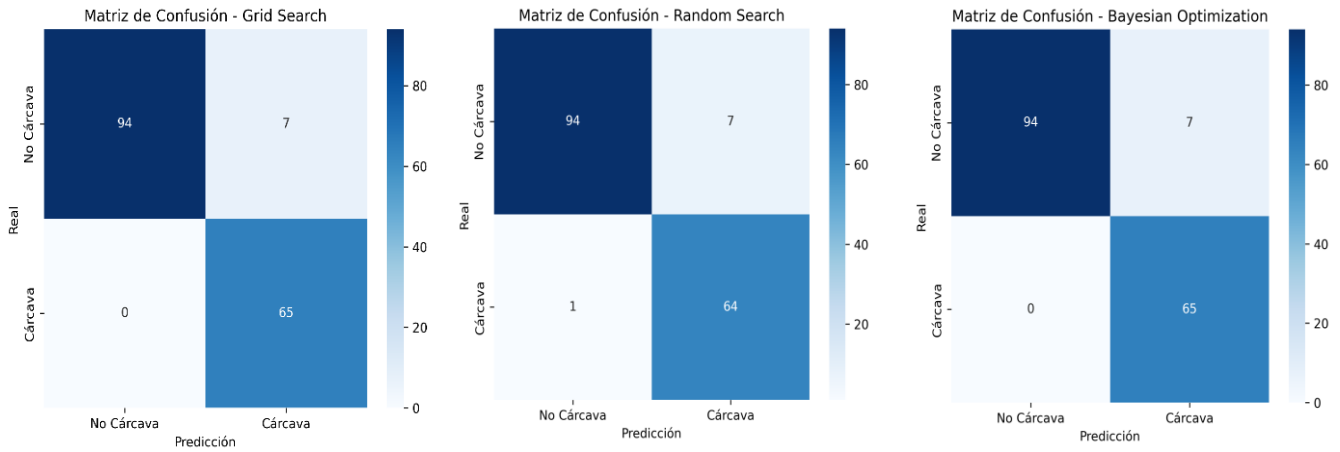


Figura 8. Matriz de confusión de 3 técnicas

En la **Tabla 5** se puede observar los hiperparámetros óptimos obtenidos a través de Grid Search, los cuales fueron claves para maximizar las métricas de rendimiento del modelo, mejorando su capacidad de generalización y evitando el sobreajuste. El uso de Max Depth = 15 permitió controlar la profundidad de los árboles, mientras que Max Features = Log₂ ayudó a mejorar la eficiencia del modelo al seleccionar el número adecuado de características en cada división.

Tabla 5. Hiperparámetros óptimos

Bootstrap	Max Depth	Max Feature	Min samples leaf	Min samples split	n estimators
False	15	Log2	1	5	100

En cuanto a los tiempos de ejecución observados en la **Figura 9**, Random Search fue la técnica más rápida, completando procesos de optimización de 7,9 segundos, seguido por Bayesian Optimization con 142,0 segundos y Grid Search con 163,5 segundos. Estos resultados, aunque no son determinantes para la elección de la mejor técnica, destacan la eficiencia computacional de Random Search, que es útil en situaciones donde el tiempo es un factor crítico, pero las métricas de rendimiento no superan lo obtenido por Grid Search. Taiwo y Lyaomore (2025), en su estudio de reconocimiento de actividades humanas, optimizaron RF mediante las tres técnicas utilizadas en este estudio, identificando mejoras en métricas como el AUC y accuracy. Sin embargo, en este estudio, el proceso Grid Search requirió un tiempo de optimización de 1197 segundos lo que generó preocupaciones sobre los costos computacionales para aplicaciones en su campo de estudio. Este análisis refuerza la necesidad de encontrar un equilibrio entre la capacidad computacional y el rendimiento. Mientras que Random Search es útil en situaciones en donde el tiempo es crucial, Grid Search demuestra ser la mejor opción cuando se busca optimizar métricas claves, aunque a cambio de un mayor costo computacional.

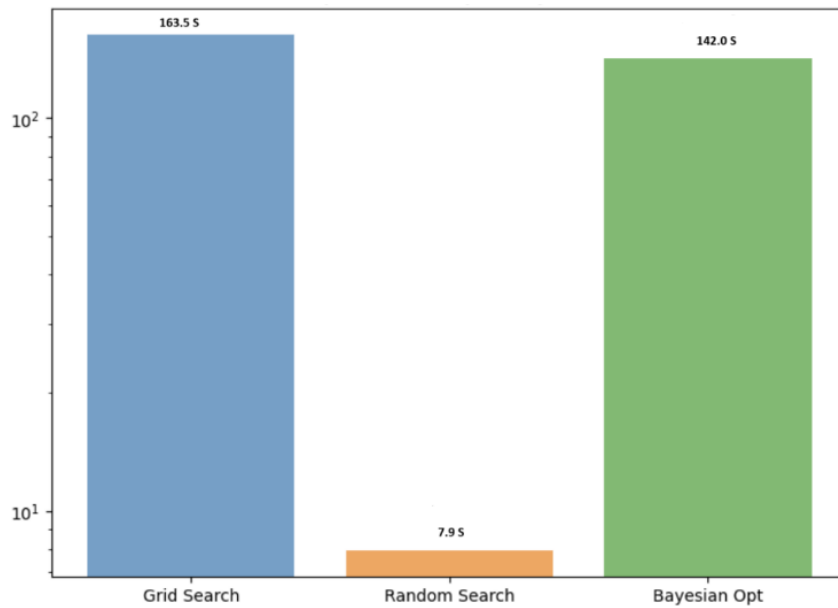


Figura 9. Comparación de tiempo de procesamiento de las técnicas de optimización.

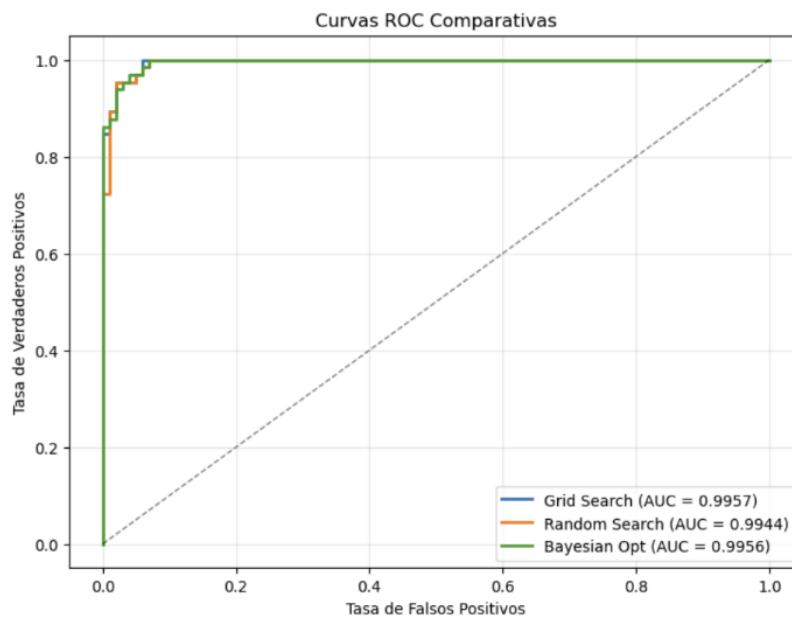


Figura 10. Comparación de AUC de las técnicas de optimización

3.5 Generación de Red de cárcavas

El modelo permitió generar una cartografía de la red de cárcavas a través de una clasificación entre niveles de probabilidad. En la **Figura 11** puede observarse una muestra del resultado en la se puede identificar zonas sin presencia de cárcavas (verde), áreas con probabilidad media de formación de cárcavas (amarillo) y áreas con alta probabilidad de presencia de cárcavas (rojo). Esta representación proporciona una visión espacial clara de las áreas críticas, facilitando su localización.




Figura 11. Mapa de probabilidad de red de cárcavas

La clasificación por rangos de probabilidad aporta un enfoque práctico para la toma de decisiones en la gestión del suelo, ya que permite priorizar intervenciones según el nivel de riesgo. Asimismo, esta información puede ser integrada con proyectos de conservación y restauración del suelo, para mitigar procesos de degradación en zonas de olivares vulnerables a la formación de cárcavas.

4.- Conclusiones

En el presente estudio se pudo analizar distintos algoritmos y técnicas de optimización para poder obtener un modelo que permita detectar la red de cárcavas en cultivos de olivar de una manera óptima.

Mediante el análisis de correlación y multicolinealidad se logró excluir variables redundantes como el área de drenaje y SAVI, las cuales obtuvieron un VIF mayor a 10. Este proceso permitió conservar aquellas variables predictoras con mayor independencia y relevantes para la predicción de la red de cárcavas.

Por medio del análisis de importancia de variables pudo confirmarse que el GHI, la acumulación de flujo y el Kns son variables que concentran más del 80% de la importancia del modelo. Esto permite poder concentrarnos en una menor cantidad de variables sin perjudicar el rendimiento.

Al comparar los distintos algoritmos de clasificación supervisada mediante la técnica de validación cruzada, Random Forest obtuvo mejores métricas de rendimiento que los otros algoritmos. Este resultado es respaldado por distintos estudios relacionados a cárcavas, en dónde Random Forest es utilizado por su versatilidad de análisis.

La optimización del modelo concluyó que Grid Search es la técnica que logró un mejor rendimiento debido a que realiza búsquedas exhaustivas, pero también fue el que se demoró más tiempo debido a el coste computacional que conlleva realizar dicha técnica.

Por último, la generación de una cartografía de red de cárcavas en base a probabilidades proporcionó una herramienta que permitirá realizar intervenciones según el nivel de riesgo, facilitando la toma de decisiones y planificación de acciones para la restauración de zonas afectadas por cárcavas.

En conclusión, los resultados obtenidos en este estudio ratifican la utilidad de las técnicas de machine learning como herramienta precisa para la identificación de la red cárcavas, la cuál puede ser replicada en otros territorios que cuenten con similares condiciones al área de estudio, permitiendo fortalecer estrategias de planificación relacionadas con la restauración del suelo.

5.- Agradecimientos

Esta investigación forma parte del proyecto de investigación “CARCAVA, Influencia climática y agronómica en la formación y evolución de la red de cárcavas en el campo Andaluz”, financiado por la Consejería de Universidades, Investigación e Innovación de la Junta de Andalucía. Quiero expresar mi más sincero agradecimiento a mis directores, Adolfo Peña Acevedo y Rafael Gonzales Perea, por su apoyo constante, dedicación y esfuerzo como tutores a lo largo de este proceso. A Paula Gonzales Garrido por su valiosa orientación académica, profesional y personal, y a Mariana León Chuchón, por su apoyo incondicional y fortaleza que me ayudaron a seguir por este largo camino.

6.- Bibliografía

- Arabameri, A., Chandra Pal, S., Costache, R., Saha, A., Rezaie, F., Seyed Danesh, A., ... Hoang, N. D. (2021). Prediction of gully erosion susceptibility mapping using novel ensemble machine learning algorithms. *Geomatics, Natural Hazards and Risk*, 12(1), 469–498. <https://doi.org/10.1080/19475705.2021.1880977>
- ANA (2015). Generación del mapa temático de curva número (CN). Autoridad Nacional del Agua. Sistema Nacional de Información de Recursos Hídricos. <https://hdl.handle.net/20.500.12543/5675>
- Benesty, J., Chen, J., Huang, Y., Cohen, I. (2009). Noise Reduction in Speech Processing. 10.1007/978-3-642-00296-0. <https://link.springer.com/book/10.1007/978-3-642-00296-0>
- Baiddah, A., Krimissa, S., Hajji, S., Ismaili, M., Abdelrahman, K., El Bouzekraoui, M., Eloudi, H., Elaloui, A., Khouz, A., Badreldin, N., & Namous, M. (2023). Head-cut gully erosion susceptibility mapping in semiarid region using machine learning methods: insight from the high atlas, Morocco. *Frontiers in Earth Science*, 11, 1184038. <https://doi.org/10.3389/feart.2023.1184038>
- Bergstra, James & Bengio, Y. (2012). Random Search for Hyper-Parameter Optimization. *The Journal of Machine Learning Research*. 13. 281–305. <https://jmlr.csail.mit.edu/papers/volume13/bergstra12a/bergstra12a.pdf>
- Beven, K.J. and Kirkby, M.J. (1979). A Physically Based, Variable Contributing Area Model of Basin Hydrology. Un modèle à base physique de zone d'appel variable de l'hydrologie du bassin versant. *Hydrological Sciences Bulletin*, 24, 43–69. <http://dx.doi.org/10.1080/02626667909491834>
- Bernabe Antonio, Virginio. (2015). ANALISIS DE SUELOS EROSIVOS Y CARCAVAS UTILIZANDO IMÁGENES LANDSAT EN EL TRAMO MEDIO DEL RIO JARAMA ESPAÑA. <https://www.scribd.com/document/311444808/ANALISIS-DE-SUELOS-EROSIVOS-Y-CARCAVAS-UTILIZANDO-IMAGENES-LANDSAT-EN-EL-TRAMO-MEDIO-DEL-RIO-JARAMA-ESPANA>
- Boegh E., H. Soegaard, N. Broge, C.B. Hasager, N.O. Jensen, K. Schelde, A. Thomsen, (2002). Airborne multispectral data for quantifying leaf area index, nitrogen concentration, and photosynthetic efficiency in agriculture, *Remote Sensing of Environment*, Volume 81, Issues 2–3, 179–193, [https://doi.org/10.1016/S0034-4257\(01\)00342-X](https://doi.org/10.1016/S0034-4257(01)00342-X).
- Borrelli, P., Panagos, P., Alewell, C., Ballabio, C., De Oliveira Fagundes, H., Haregeweyn, N., Lugato, E., Maerker, M., Poesen, J., Vanmaercke, M., y Robinson, D.A. (2022). Policy implications of multiple concurrent soil erosion processes in European farmland. *Nature Sustainability* 6(1), 103–112. <https://doi.org/10.1038/s41893-022-00988-4>
- Borrelli, P., Matthews, F., Alewell, C., Kaffas, K., Poesen, J., Saggau, P., Právník, R., Vanmaercke, M., Panagos, P. (2025). [A hybrid in situ and on-screen survey to monitor gully erosion across the European Union](#). *Nature Scientific Data* 12, 755
- Breiman, L. (2001). Random Forests. *Machine Learning*. Vol. 45. Pp. 5–32. <https://doi.org/10.1023/A:1010933404324>
- Castellanos, G., Moreno, M., Maldonado, F. (2016). OBTENCIÓN DE IMÁGENES ÍNDICE DE VEGETACIÓN SAVI A PARTIR DE IMÁGENES MILIRREFLECTANCIA TOA. https://www.researchgate.net/profile/Francisco_Maldonado/publication/315738364_SELPER2016_Separata_T504/data/58e0853caca272059aae5979/SELPER2016-Separata-T504.pdf
- Castillo, C., y Gómez, J.A. (2016). A century of gully erosion research: Urgency, complexity and study approaches. *Earth Sci Rev* 160, 300–319. <https://doi.org/10.1016/j.earscirev.2016.07.009>
- Chen, T., Guestrin, C. (2016). XGBoost: A Scalable Tree Boosting System. Vol. 10. Pp. 785–794. <https://doi.org/10.48550/arXiv.1603.02754>
- Corporación Autónoma Región del Tolima (2019). Gestión Integral del Recurso Hídrico - POMCA Río Luisa y otros directos al Magdalena. Fase Diagnóstico – Pendientes. Gobierno Nacional de Colombia Ministerio de Ambiente y Desarrollo Sostenible. Dirección de Gestión Integral de Recurso Hídrico. <https://cortolima.gov.co/planes-y-programas/gestion-integral-del-recurso-hidrico/3405-pomca-rio-luisa-2019>
- Cortes, C. & Vapnik, V. (1995). Support-Vector Networks. *Machine Learning*, 20(3), 273–297. <https://doi.org/10.1023/A:1022627411411>
- Cover, T.M. & Hart, P.E. (1967). *Nearest Neighbor Pattern Classification*. en *IEEE Transactions on Information Theory*. Vol. 13, no. 1, pp. 21–27, January 1967, <https://doi.org/10.1109/TIT.1967.1053964>
- Cutler, A., Cutler, D., Stevens, J. (2011). Random Forests. https://doi.org/10.1007/978-1-4419-9326-7_5
- Deliang S., Haijia W., Danzhou W., Jiahui X. (2020). A random forest model of landslide susceptibility mapping based on hyperparameter optimization using Bayes algorithm, *Geomorphology*, Vol 362, 2020, 107201, ISSN 0169-555X. <https://doi.org/10.1016/j.geomorph.2020.107201>

- De Geeter, S., Poesen, J., Campforts, B., Vanmaercke M. (2023). A data driven gully head susceptibility map of Africa at 30 m resolution, Environmental Research, Volume 224, 2023, 115573, ISSN 0013-9351, <https://doi.org/10.1016/j.envres.2023.115573>
- Dewitte O., Mohamed D., Bosco C., Van Den Edckhaut M. (2015). Predicting the susceptibility to gully initiation in data-poor regions, Geomorphology, Volume 228 (2015), <https://doi.org/10.1016/j.geomorph.2014.08.010>.
- ESA (2019). El Componente Espacio Copernicus. Agencia Espacial Europea (ESA). AECID – 2019. https://www.ign.es/web/resources/docs/IGNCnig/actividades/OBS/Programa_Marco_Copernicus_User_Uptake/12_Componente_InSitu.pdf
- ESP (2024). Advancing gully initiation modelling by means of a Curve Number (CN) method: ¿a way forward? Earth Surface Processes and Landforms. <https://onlinelibrary.wiley.com/journal/10969837>
- European Parliament (2024). Reglamento (UE) 2024/1991 del Parlamento Europeo y del Consejo, de 24 de junio de 2024, relativo a la restauración de la naturaleza y por el que se modifica el Reglamento (UE) 2022/869. <https://eur-lex.europa.eu/eli/reg/2024/1991/oj/eng>
- Funk, C., Peterson, P., Landsfeld, M. *et al.* (2015). The climate hazards infrared precipitation with stations—a new environmental record for monitoring extremes. *Sci Data* 2, 150066 (2015). <https://doi.org/10.1038/sdata.2015.66>
- Gámiz, A. Generación automática de redes de cárcavas topológicamente conectadas empleando tecnología LiDAR y SIG. (2024). Trabajo de Fin de Máster. Universidad de Córdoba. https://helvia.uco.es/handle/10396/25/search-filter?field=subject&offset=20&starts_with=r
- García Ojeda, Juan Gabriel. (2023). *Determinación de algoritmos de clasificación óptimos para la evaluación de riesgo crediticio en el caso de PyMES: caso de estudio: PyMES que operan en plataformas P2P* (Tesis de grado). Mendoza, Universidad Nacional de Cuyo. Facultad de Ciencias Económicas. <https://bdigital.uncu.edu.ar/19342>
- Garnett R. (2023). *Bayesian Optimization*. Cambridge University Press; 2023. <https://doi.org/10.1017/9781108348973>
- Gutiérrez, Á.G., Schnabel, S., y Contador, F.L. (2009). Gully erosion, land use and topographical thresholds during the last 60 years in a small rangeland catchment in SW Spain. *Land Degradation and Development* 20(5), 535–550. <https://doi.org/10.1002/ldr.931>
- Gonzalez, M. (2024). Nuevo Reporte: Descripción de productos SISSA de estimación del estado de la vegetación derivados con datos satelitales. Sistema de Información sobre Sequías para el sur de Sudamérica (SISSA). <https://sisa.crc-sas.org/wp-content/uploads/2024/05/RT-Indices-de-vegetacion-corregido.pdf>
- Gonzalez, P., De Geeter S., Vanmaercke, M., Poesen J., Hayas, A., Vanwallegem, T., Peña, A. (2025). Assessing the effect of precipitation and landscape type on gully activity using a novel gully head susceptibility index: case-study in olive groves of SW Spain. Universidad de Córdoba. <https://www.uco.es/investigacion/grupos/agr-127/>
- Hair, J. F., Black, W. C., Babin, B. J., Anderson, R. E. (2018). *Multivariate Data Analysis* (8). Andover: Cengage Learning. https://eli.johogo.com/Class/CCU/SEM/_Multivariate%20Data%20Analysis_Hair.pdf
- Hayas, A., Vanwallegem, T., Laguna, A., Peña, A., y Giráldez, J.V. (2017). Reconstructing long-term gully dynamics in Mediterranean agricultural areas. *Hydrology and Earth System Sciences* 21(1), 235–249. <https://doi.org/10.5194/hess-21-235-2017>
- Hayas, A., Poesen, J. y T. Vanwallegem, (2017b). Rainfall and Vegetation Effects on Temporal Variation of Topographic Thresholds for Gully Initiation in Mediterranean Cropland and Olive Groves. *Land Degradation & Development* 28, 2540–2552. <https://doi.org/10.1002/ldr.2805>
- Hayas, A. (2019). Análisis y modelización de la contribución de la erosión por cárcavas a la producción de sedimentos en la cuenca del Guadalquivir. Tesis Doctoral. Universidad de Córdoba. <https://helvia.uco.es/bitstream/handle/10396/18805/2019000001952.pdf?sequence=1&isAllowed=y>
- Hawkins, R.H., Ward, T.J., Woodward, D.E., y Van Mullem, J.A. (2009). *Curve Number Hydrology — State of practice*. ASCE publication 978-0-7844-1004-2.
- Huete, A.R. (1988). A soil-adjusted vegetation index (SAVI), *Remote Sensing of Environment*, Volume 25, Issue 3, 295-309. [https://doi.org/10.1016/0034-4257\(88\)90106-X](https://doi.org/10.1016/0034-4257(88)90106-X).
- Imaizumi, F., Hattajji, T., y Hayakawa, Y.S. (2009). Channel initiation by surface and subsurface flows in a steep catchment of the Akaishi Mountains, Japan. *Geomorphology* 115(1–2), 32–42. <https://doi.org/10.1016/j.geomorph.2009.09.026>
- INEGI (2024). Desarrollo de nueva metodología para la generación de información geoespacial de Uso del Suelo y Vegetación. Documento Metodológico. Instituto Nacional de Estadística y Geografía. México. INEGI, c2024. <https://www.inegi.org.mx/contenidos/programas/usyvia/doc/metodologia.pdf>
- INEGI (2022). Índice de Vegetación de Diferencia Normalizada NDVI. Landsat, 1984-2021. Instituto Nacional de Estadística y Geografía. México. INEGI, c2024. https://www.inegi.org.mx/contenidos/productos/prod_serv/contenidos/espanol/bvinegi/productos/nueva_estruc/889463908272.pdf
- Jenson, S. and Domingue, J. (1988) Extracting Topographic Structure from Digital Elevation Data for Geographic Information System Analysis. *Photogrammetric Engineering and Remote Sensing*, 54, 1593-1600.
- Junta de Andalucía (2014). Cuenca del Guadalquivir. Capítulo 14. Confederación Hidrográfica del Guadalquivir (CHG). España. https://www.juntadeandalucia.es/medioambiente/web/ContenidosOrdenacion/red_informacion_ambiental/PDF/Geodiversidad/Geodiversidad_y_Patrimonio_Geologico_Andalucia_2006/capitulo14.pdf

- Kanwar, M., Pokharel, B. & Lim, S. A new random forest method for landslide susceptibility mapping using hyperparameter optimization and grid search techniques. *Int. J. Environ. Sci. Technol.* 22, 10635–10650 (2025). <https://doi.org/10.1007/s13762-024-06310-3>
- Kuhn, C.E.S., Reis, F.A.G.V., Zarfl, C., y Grathwohl, P. (2023). Ravines and gullies, a review about impact valuation. *Natural Hazards* 117, 597–624. <https://doi.org/10.1007/s11069-023-05874-6>
- Lei, X., Chen, W., Avand, M., Janizadeh, S., Kariminejad, N., Shahabi, H., Costache, R-D., Shahabi, H., Shirzadi, A., Mosavi, A. (2020). GIS-Based Machine Learning Algorithms for Gully Erosion Susceptibility Mapping in a Semi-Arid Region of Iran. *Remote Sensing*. <https://doi.org/10.3390/rs12152478>
- Li, S., Jin, N., Dogani, A., Yang, Y., Zhang, M., & Gu, X. (2024). Enhancing LightGBM for Industrial Fault Warning: An Innovative Hybrid Algorithm. *Processes*, 12(1). <https://doi.org/10.3390/pr12010221>
- Liashchynskiy, P. & Liashchynskiy, P. (2019). Grid Search, Random Search, Genetic Algorithm: A Big Comparison for NAS. <https://doi.org/10.48550/arXiv.1912.06059>
- Ministerio de Agricultura, Pesca y Alimentación (2024). Encuesta sobre superficies y rendimientos de cultivos - Análisis de las plantaciones de olivar en España 2024. Secretaría General Técnica. Centro de Publicaciones. <https://www.mapa.gob.es/es/estadistica/temas/estadisticas-agrarias/agricultura/esyrc>
- Nachtergaele, J., Poesen, J., Steegen, A., Takken, I., Beuselinck, L., Vandekerckhove, L., y Govers, G. (2001). The value of a physically based model versus an empirical approach in the prediction of ephemeral gully erosion for loess-derived soils. *Geomorphology* 40(3–4), 237–252. [https://doi.org/10.1016/s0169-555x\(01\)00046-0](https://doi.org/10.1016/s0169-555x(01)00046-0)
- Nearing, M.A., Norton, L.D., Bulgakov, D.A., Larionov, G.A., West, L.T., y Dontsova, K.M. (1997). Hydraulics and erosion in eroding rills. *Water Resources Research* 33(4), 865–876. <https://doi.org/10.1029/97wr00013>
- Panagos, P., Borrelli, P., Poesen, J., Ballabio, C., Lugato, E., Meusburger, K., Montanarella, L., y Alewell, C. (2015). The new assessment of soil loss by water erosion in Europe. *Environmental Science & Policy* 54, 438–447. <https://doi.org/10.1016/j.envsci.2015.08.012>
- Panagos, P., Broothaerts, N., Ballabio, C., Orgiazzi, A., De Rosa, D., Borrelli, P., Jones, A. (2024). How the EU Soil Observatory is providing solid science for healthy soils. *European Journal of Soil Science* 75(3). <https://doi.org/10.1111/ejss.13507>
- Poesen, J., Nachtergaele, J., Verstraeten, G., y Valentin, C. (2003). Gully erosion and environmental change: Importance and research needs. *Catena* 50(2–4), 91–133. [https://doi.org/10.1016/s0341-8162\(02\)00143-1](https://doi.org/10.1016/s0341-8162(02)00143-1)
- Poesen, J., Vandekerckhove, L., Nachtergaele, J., Wijdenes, D.O., Verstraeten, G., y Van Wesemael, B. (2002). Gully erosion in dryland environments. En: *Dryland Rivers: Hydrology and Geomorphology of Semi-arid Channels*, p. 229.
- Quinlan, J.R. (1996). *Improved Use of Continuous Attributes in C4.5*. *Journal of Artificial Intelligence Research (JAIR)*. Vol 4 (1996). pp. 77-90. <https://doi.org/10.1613/jair.279>
- Quinlan, J.R. (1996b). *Induction of Decision Trees*. *Machine Learning*, 1(1), 81–106. <https://doi.org/10.1023/A:1022643204877>
- Rossi, M. (2014). Modeling of landslide phenomena and erosion processes triggered by meteo-climatic factors. [Università degli Studi di Perugia]. <http://dx.doi.org/10.13140/2.1.3835>.
- Rahmati, O. & Haghizadeh, A. & Pourghasemi, H. & Nourmohammadi, F. (2016). Gully erosion susceptibility mapping: the role of GIS-based bivariate statistical models and their comparison. *Natural Hazards*. 82. 1231–1258 (2016). <https://doi.org/10.1007/s11069-016-2239-7>
- Saha, S., Roy, J., Arabameri, A., Blaschke, T., & Tien Bui, D. (2020). Machine Learning-Based Gully Erosion Susceptibility Mapping: A Case Study of Eastern India. *Sensors*, 20(5), 1313. <https://doi.org/10.3390/s20051313>
- Serra, A. (2020). Comparación de algoritmos de clasificación supervisada. Treball de Fi de Grau. Màster Universitari en Enginyeria d'Organització (MUEO). Escola Tècnica Superior d' Enginyeria Industrial de Barcelona. <https://upcommons.upc.edu/bitstreams/721031ab-5094-4133-8941-5c6b6cef7737/download>
- Snyder, E., Johnson, N., Spyropoulou, J., Crosby, K., Wobus, C., Whipple, K., Kirby, E., Snyder, N., Johnson, J., Spyropoulou, K., Crosby, B., Sheehan, D. (2006). Tectonics from topography: Procedures, promise, and pitfalls. *Geological Society of America Special Paper*. 398. 55-742398. 10.1130/2006.2398(04). [https://doi.org/10.1130/2006.2398\(04\)](https://doi.org/10.1130/2006.2398(04))
- Sørensen, R., Zinko, U., and Seibert, J. (2006). On the calculation of the topographic wetness index: evaluation of different methods based on field observations, *Hydrol. Earth Syst. Sci.*, 10, 101–112. https://doi.org/10.5194/hess-10-101-2006_200
- Taiwo, S. A. & Lyaomolere, B. A. (2025). HYPERPARAMETER OPTIMIZATION OF RANDOM FOREST CLASSIFIERS FOR ENHANCED PERFORMANCE IN SENSOR-BASED HUMAN ACTIVITY RECOGNITION. *Advance Journal of Science, Engineering and Technology*, 10(4), 103–119. <https://aspjournals.org/ajset/index.php/ajset/article/view/132>
- Tan, Z., Leung, L.R., Li, H., y Cohen, S. (2021). Representing global soil erosion and sediment flux in Earth system models. *Journal of Advances in Modeling Earth Systems* 14(1). <https://doi.org/10.1029/2021ms002756>
- Torri, D., y Poesen, J. (2014). A review of topographic threshold conditions for gully head development in different environments. *Earth-Science Reviews* 130, 73–85. <https://doi.org/10.1016/j.earscirev.2013.12.006>
- Valentin, C., Poesen, J., y Li, Y. (2005). Gully erosion: Impacts, factors and control. *Catena (Amst)* 63, 132–153. <https://doi.org/10.1016/j.catena.2005.06.001>

- Vanmaercke, M., Vanmaercke, M., Panagos, P., Vanwalleghem, T., Hayas, A., Foerster, S., Borrelli, P., Rossi, M., Torri, D., Casali, J., Borselli, L., Vigiak, O., Märker, M., Haregeweyn, N., De Geeter, S., Zgłobicki, W., Biielders, C., Cerda, A., Conoscenti, C., De Figueiredo, T., Evans, B., Golosov, V., Ionita, I., Karydas, C.G., Kertesz, A., Krasa, J., Le Bouteiller, C., Radoane, M., Ristic, R., Rousseva, S., Stankoviansky, M., Stolte, J., Stolz, C., Bartley, R., Wilkinson, S., Jaribahi, B. and Poesen, J., 2021. Measuring, modelling and managing gully erosion at large scales: A state of the art. *Earth-Science Reviews* 218, 103637. <https://doi.org/10.1016/j.earscirev.2021.103637>
- Vandaele, K., Poesen, J., Govers, G., y Van Wesemael, B. (1996). Geomorphic threshold conditions for ephemeral gully incision. *Geomorphology* 16(2), 161–173. [https://doi.org/10.1016/0169-555x\(95\)00141-q](https://doi.org/10.1016/0169-555x(95)00141-q)
- Vandekerckhove, L., Poesen, J., Wijdenes, D.O., y De Figueiredo, T. (1998). Topographical thresholds for ephemeral gully initiation in intensively cultivated areas of the Mediterranean. *Catena* 33(3–4), 271–292. [https://doi.org/10.1016/s0341-8162\(98\)00068-x](https://doi.org/10.1016/s0341-8162(98)00068-x)