

UNIVERSIDAD COMPLUTENSE DE MADRID  
FACULTAD DE CIENCIAS MATEMÁTICAS

UNIVERSIDAD POLITÉCNICA DE MADRID  
E.T.S. DE INGENIEROS DE MINAS Y ENERGÍA

MÁSTER EN GESTIÓN DE DESASTRES



---

# Modelización del riesgo de incendios mediante redes bayesianas basadas en datos georreferenciados del terreno

TRABAJO DE FIN DE MÁSTER

María Carnicero Pastor

DIRECTORES

Adán Rodríguez Martínez  
Gonzalo Barderas Manchado

Septiembre de 2025



## Resumen

Los incendios forestales constituyen una de las principales amenazas ambientales en el área mediterránea, debido a la combinación de factores climáticos, topográficos y antrópicos. Este trabajo aplica una metodología de evaluación y modelización del riesgo en la Sierra de los Filabres (Almería) mediante redes bayesianas basadas en indicadores de riesgo fundamentados en datos georreferenciados, integrando información topográfica derivada de datos LiDAR, usos del suelo a partir del Sistema de Información sobre Ocupación del Suelo de España, índices del estado de sequedad de la vegetación obtenidos con imágenes Landsat, así como la proximidad a carreteras y núcleos urbanos. El área de estudio se sectorizó en cuencas hidrográficas, sobre las que se calcularon los indicadores de riesgo y se integraron mediante el método multicriterio AHP. Finalmente, el modelo se resolvió bajo distintos escenarios de viento, generando mapas de probabilidad de ignición y propagación que identifican las zonas más vulnerables y aportan una herramienta de apoyo para la prevención y gestión de emergencias.

Palabras clave: Incendios, Modelos estocásticos, Redes Bayesianas, Prevención

## Abstract

Forest fires are one of the main environmental threats in the Mediterranean area, due to a combination of climatic, topographical and anthropogenic factors. This study applies a risk assessment and modelling methodology in the Sierra de los Filabres (Almería) using Bayesian networks based on risk indicators derived from georeferenced data, integrating topographical information derived from LiDAR data, land use from the Spanish Land Use Information System, vegetation dryness indices obtained from Landsat images, and proximity to roads and urban centres. The study area was divided into river basins, for which risk indicators were calculated and integrated using the AHP multi-criteria method. Finally, the model was solved under different wind scenarios, generating ignition and spread probability maps that identify the most vulnerable areas and provide a support tool for emergency prevention and management.

Keywords: Fires, Stochastic models, Bayesian networks, Prevention



# Índice general

<b>1. Introducción</b>	<b>1</b>
1.1. Motivación . . . . .	2
1.2. Objetivos . . . . .	4
1.3. Estructura del trabajo . . . . .	5
<b>2. Planteamiento matemático de la red bayesiana</b>	<b>6</b>
2.1. Introducción a la Inferencia Bayesiana . . . . .	7
2.2. Fundamentos de las Redes Bayesianas . . . . .	7
2.3. Inferencia en Redes Bayesianas . . . . .	8
2.4. Aprendizaje de Redes Bayesianas . . . . .	9
2.5. Implementación con pomegranate en Python . . . . .	10
<b>3. Obtención y modelización de datos georeferenciados</b>	<b>12</b>

3.1. Introducción. Zona de estudio . . . . .	12
3.2. Datos empleados y modelización . . . . .	14
3.2.1. Fuentes de datos . . . . .	14
3.3. Determinación de cuencas hidrográficas . . . . .	16
3.4. Pendientes y orientación . . . . .	20
3.5. Tipo de suelo . . . . .	22
3.6. VCI: Vegetation Condition Index . . . . .	25
3.7. Distancia a carreteras y a núcleos urbanos . . . . .	29
3.7.1. Riesgo asociado a la distancia de carreteras . . . . .	30
3.7.2. Riesgo asociado a la distancia de núcleos urbanos . . . . .	32
<b>4. Resultados</b>	<b>35</b>
4.1. Integración de indicadores de riesgo mediante el método AHP . . . . .	35
4.2. Calculo de la probabilidad de ignición . . . . .	38
4.3. Escenarios de viento . . . . .	41
4.4. Resolución de la red bayesiana . . . . .	43
<b>5. Análisis de resultados y conclusiones</b>	<b>45</b>

<b>Bibliografía</b>	<b>48</b>
<b>Anexo I: Código de Python</b>	<b>52</b>
<b>Anexo II: Series temporales completas</b>	<b>57</b>



# Capítulo 1

## Introducción

Los incendios forestales representan uno de los riesgos ambientales más importantes en gran parte del mundo, especialmente en zonas con climas mediterráneos como el sur de Europa. Últimamente, la intensidad y frecuencia de estos eventos han aumentado notablemente debido principalmente al cambio climático, pero también se han visto afectados por la expansión urbana de grandes ciudades y la acumulación de combustible vegetal derivada del abandono de las zonas rurales y de políticas de gestión forestal ineficaces. Las consecuencias de los incendios no solo afectan al entorno natural, provocando la pérdida de biodiversidad, sino también a las poblaciones, donde generan grandes pérdidas económicas, humanas y riesgos para la salud.

Por esta razón, se hace cada vez más necesaria la incorporación de herramientas para la evaluación y modelización del riesgo de incendios forestales y así mejorar su predicción ([Vitoriano et al., 2015](#)).

Pese a estos avances, existen todavía grandes desafíos y por esta razón ha surgido la idea de realizar este trabajo con el objetivo de evaluar y modelizar estocásticamente el riesgo de incendios forestales buscando mejorar su predicción. En particular, se aplicará una modelización estocástica del terreno para su uso en la gestión de desastres mediante redes bayesianas según [Rodríguez-Martínez \(2021\)](#), al que se incorporará información georreferenciada que permita estimar, para cada zona espacial del territorio analizado, la probabilidad de ocurrencia de un incendio.

Dicha información procederá de distintas fuentes: información topográfica, datos climáticos, uso del suelo, estado de la vegetación, proximidad a infraestructuras humanas..., con las que establecer las probabilidades de ignición y propagación con las que se construye el modelo probabilístico de la red bayesiana.

Como se indica al principio, el riesgo de incendios es especialmente grave en zonas mediterráneas, por lo que este trabajo se enmarca en un contexto territorial específico: la Sierra de los Filabres, una zona montañosa del sureste peninsular con un elevado valor ecológico, lo que la convierte en una zona ideal para la aplicación de este modelo.

## 1.1. Motivación

Debido a las grandes mejoras en prevención en los últimos años, se ha reducido el número de incendios en España. Si se compara con la década anterior, entre 2013 y 2024, los incendios se han reducido en un 37% ([Geolat, 2025](#)).

Sin embargo, si se observan las estadísticas, el número de hectáreas quemadas es muy similar, es decir, con menos incendios la zona afectada por ellos es muy similar, de lo que se puede concluir que los incendios son mucho más agresivos, son lo que se consideran Grandes Incendios Forestales (GIF).

Los Grandes Incendios Forestales hacen referencia a incendios que superan las 500 hectáreas quemadas. Algunas de sus principales características son:

- Alta energía.
- Elevada intensidad de frente de llama.
- Varias cabezas y lenguas de fuegos localizadas a lo largo del perímetro del incendio.
- Fuego en copa.
- Altura de llama considerable.
- Microclima generado por el propio incendio (deseccación, regímenes de vientos propios...).

Algunos Grandes Incendios Forestales en España en los últimos años son, por ejemplo, el incendio en Arafo y Candelaria en Tenerife en agosto del año 2023 donde el incendio tuvo una extensión de 13.600 hectáreas quemadas, el incendio de Navalacruz en Ávila, en agosto del 2021, que es el cuarto peor incendio de nuestra historia por volumen de hectáreas quemadas con un total de 22.000 o los incendios que han sucedido este 2025 que han destacado por su intensidad habiendo aumentado la superficie quemada de forma alarmante: hasta el 5 de agosto, el fuego había afectado a algo más de 47.000 hectáreas, aumentando hasta más de 390.000 hectáreas solo 15 días después. La alta virulencia de estos incendios también se observa en la pérdida de vidas humanas, habiendo llegado a quemar incluso poblaciones enteras ([Constanza V. Paura, 2025](#)).

Estos datos nos indican que necesitamos nuevos métodos de enfrentarnos a los incendios y que centrarse solo en la extinción ya no es suficiente debido a que estos incendios, por sus características, son muy difíciles de controlar. Por lo que la prevención es el arma más importante a la hora de luchar contra ellos.

Derivado de estos datos, teniendo en cuenta que por sus características climáticas y la despoblación de las zonas rurales, España es un país con riesgo de padecer numerosos grandes incendios, este TFM tiene como objetivo estudiar el terreno, gracias a la teledetección, buscando modelizar distintas variables asociadas al riesgo de incendio en una determinada zona y aplicar un modelo probabilístico de propagación para estimar el riesgo total de los incendios en una determinada zona.

El uso de imágenes de satélite en teledetección se ha consolidado como una herramienta clave en la monitorización y análisis del riesgo de incendios forestales. Debido a los avances en la tecnología de los satélites, hoy en día se pueden obtener datos actualizados, de alta resolución espacial y temporal, sobre variables críticas que influyen directamente en la probabilidad de ignición y propagación del fuego. Entre estas variables se incluyen la humedad de la vegetación, el estado de estrés hídrico, la temperatura superficial y el índice de vegetación, entre otros.

Una de las principales ventajas de la teledetección es su capacidad para cubrir amplias extensiones de terreno con una frecuencia de observación constante, lo que permite detectar rápidamente condiciones propicias para la aparición de incendios y estudiar el terreno en los distintos momentos del año.

En el contexto de este trabajo, la información obtenida por satélite permite alimentar modelos espaciales como las redes bayesianas, incorporando datos objetivos y dinámicos

que mejoran la capacidad de calcular las probabilidades de ignición, lo cual puede ayudar a predecir y prevenir incendios forestales. En consecuencia, la teledetección no solo representa una fuente de información eficiente y accesible, sino que también contribuye activamente a la toma de decisiones en tiempo real, optimizando la planificación de medidas preventivas y recursos de extinción.

Además de la información obtenida por satélite, en este trabajo se ha utilizado la tecnología LiDAR (Light Detection and Ranging) una herramienta de gran valor en el ámbito de la teledetección aplicada a la gestión forestal y la prevención de incendios. A través de la emisión y recepción de pulsos láser, el LiDAR permite obtener modelos digitales de elevación y caracterizar con gran precisión tanto la topografía del terreno como la estructura vertical de la vegetación. Esta capacidad resulta especialmente relevante en la evaluación del riesgo de incendios, ya que factores como la pendiente, la orientación, la densidad de la cubierta vegetal o la altura del arbolado influyen de manera directa en la probabilidad de ignición y en la propagación del fuego.

## 1.2. Objetivos

Los objetivos que se han tratado de alcanzar con la realización de este trabajo son los siguientes:

- Planteamiento matemático de la red bayesiana
- Modelización del territorio caso de estudio como una red en nodos y aristas: segmentación del terreno en polígonos homogéneos topográficamente mediante un modelo de pendientes obtenido de datos de LiDAR. Se considerarán nodos de la red aquellas regiones de factible propagación de incendios topográficos. La posible propagación de un incendio entre pares de nodos se representará mediante aristas de la red. Únicamente se considerarán aristas entre polígonos adyacentes.
- Traducción de los datos georreferenciados del terreno en los pesos de la red: probabilidades de ignición y propagación de incendios bajo los distintos escenarios de viento.
- Estimación de las probabilidades marginales de la red para el cálculo de la medida de riesgo de incendio, herramienta que puede ayudar de forma eficaz y segura a gestionar la emergencia en las fases de prevención y mitigación.

### **1.3. Estructura del trabajo**

Derivado de todo lo anterior, este trabajo se estructura como sigue: en el capítulo 2 se presentan los fundamentos matemáticos de las redes bayesianas. Para modelizar el terreno según una red de grafos dirigidos que resolver mediante las funciones presentadas, en el capítulo 3 se presenta el trabajo de campo y las herramientas empleadas para segmentar el terreno como una red de nodos y aristas, y establecer las probabilidades de ignición y propagación entre ellos a partir de datos de teledetección e información climática acerca de la velocidad y dirección del viento. Por último, en el capítulo 4 se presentan los resultados obtenidos de la ejecución del modelo matemático, explicándose los principales resultados y conclusiones más importantes en el capítulo 5.

## Capítulo 2

# Planteamiento matemático de la red bayesiana

Las redes bayesianas se han utilizado con éxito en contextos medioambientales para integrar fuentes heterogéneas de información, como datos meteorológicos, topográficos y de vegetación obtenidos por teledetección (A. L. Westerling et al., 2006; Cheng and Hadjisophocleous, 2009).

En la prevención de incendios forestales, las redes bayesianas permiten modelar la probabilidad de ocurrencia de un incendio en función de variables como: la humedad del combustible, la temperatura y velocidad del viento, la cobertura vegetal o la proximidad a zonas urbanas o actividades humanas. Gracias a la capacidad de inferencia probabilística, estas redes permiten tomar decisiones informadas en la gestión del riesgo (Rodríguez-Martínez, 2021).

Por las razones explicadas en los párrafos anteriores, este capítulo presenta los fundamentos teóricos necesarios para comprender las redes bayesianas desde una perspectiva matemática. La información expuesta ha sido recopilada principalmente de las obras de referencia *Bayesian Artificial Intelligence* (Collins et al., 2021) y *A First Course in Bayesian Statistical Methods* (Kim, 2005), las cuales ofrecen una exposición rigurosa y accesible sobre teoría bayesiana, inferencia y aprendizaje de modelos probabilísticos.

## 2.1. Introducción a la Inferencia Bayesiana

La inferencia bayesiana constituye un marco teórico para el razonamiento probabilístico bajo incertidumbre. Se basa en el teorema de Bayes, el cual permite actualizar la probabilidad de una hipótesis dada la evidencia observada:

$$P(H|E) = \frac{P(E|H)P(H)}{P(E)} \quad (2.1)$$

donde  $P(H|E)$  es la probabilidad posterior de la hipótesis  $H$  dado el evento  $E$ ,  $P(E|H)$  es la verosimilitud,  $P(H)$  es la probabilidad a priori, y  $P(E)$  es la probabilidad marginal de la evidencia.

Este principio es la base de los modelos probabilísticos gráficos conocidos como redes bayesianas.

Las principales ventajas de las redes bayesianas son que tienen una representación intuitiva de dependencias causales, permiten el manejo de la incertidumbre y de datos incompletos, y otorgan mucha flexibilidad para integrar conocimiento experto y datos.

## 2.2. Fundamentos de las Redes Bayesianas

Una red bayesiana es un grafo dirigido acíclico (DAG, por sus siglas en inglés) que representa un conjunto de variables aleatorias y sus dependencias condicionales mediante arcos dirigidos. Formalmente, una red bayesiana  $\mathcal{B}$  está compuesta por:

- Un conjunto de nodos  $X_1, X_2, \dots, X_n$  que representan variables aleatorias.
- Un conjunto de arcos dirigidos que codifican relaciones de dependencia.
- Un conjunto de distribuciones de probabilidad condicional  $P(X_i|\text{Pa}(X_i))$ , donde  $\text{Pa}(X_i)$  son los padres de  $X_i$  en el grafo.

Una de las características más importantes de las redes bayesianas es que la relación entre los nodos es inherentemente bidireccional desde el punto de vista probabilístico: aunque los arcos indiquen una dirección para representar dependencias, la inferencia puede realizarse en ambos sentidos, desde las causas hacia los efectos (inferencia predictiva) y desde los efectos hacia las causas (inferencia diagnóstica). Además, incluso los nodos que no están directamente conectados pueden estar relacionados de forma condicional a través de otros nodos intermedios, lo que significa que su independencia o dependencia está mediada por la estructura global de la red y la evidencia disponible.

La red permite factorizar la distribución conjunta de todas las variables como se muestra en la ecuación (2.2), lo cual reduce drásticamente la complejidad computacional, especialmente en sistemas con muchas variables:

$$P(X_1, \dots, X_n) = \prod_{i=1}^n P(X_i | \text{Pa}(X_i)). \quad (2.2)$$

### 2.3. Inferencia en Redes Bayesianas

La inferencia en Redes Bayesianas es el proceso mediante el cual se resuelve el modelo, es decir, se calcula la probabilidad de ciertas variables de interés dada la observación de otras. Esto permite responder preguntas del tipo “¿cuál es la probabilidad de que ocurra  $X$  si se ha observado  $Y$ ?” y es el objetivo central de su uso en tareas de análisis y predicción. La potencia de las Redes Bayesianas reside precisamente en su capacidad de realizar inferencias eficientes, incluso en presencia de incertidumbre o información parcial.

En redes bayesianas existen diversos enfoques para realizar la inferencia, que pueden clasificarse en exactos y aproximados. Entre los métodos exactos destaca la eliminación de variables, que consiste en marginalizar las variables no observadas siguiendo un orden de eliminación que minimice la complejidad computacional. Otro enfoque exacto es la propagación de creencias, especialmente eficiente en redes en forma de árbol, donde los mensajes de probabilidad se transmiten entre nodos hasta converger en las probabilidades posteriores.

Por otro lado, los métodos aproximados, como el muestreo de Monte Carlo, generan un gran número de muestras aleatorias para estimar las distribuciones posteriores. Ejemplos

incluyen el *Gibbs sampling* y las cadenas de Markov Monte Carlo (MCMC), que permiten aproximar resultados cuando el cálculo exacto es inviable.

En el contexto de este trabajo, el método de resolución utilizado ha sido el estimador de máxima verosimilitud (*Maximum Likelihood Estimation*, MLE), que si bien está más relacionado con el aprendizaje de parámetros que con la inferencia pura, es fundamental para obtener las distribuciones condicionales que alimentan el proceso de inferencia. El MLE busca los valores de parámetros  $\theta$  que maximizan la probabilidad de los datos observados:

$$\hat{\theta}_{MLE} = \arg \max_{\theta} \prod_{i=1}^N P(x^{(i)}|\theta). \quad (2.3)$$

Este enfoque es especialmente apropiado cuando se dispone de datos completos y representativos, permitiendo construir un modelo fiable sobre el que posteriormente se aplican técnicas de inferencia.

## 2.4. Aprendizaje de Redes Bayesianas

Dado un conjunto de datos y una estructura fija, los parámetros (las distribuciones condicionales) se pueden estimar usando métodos como estimación máxima de verosimilitud (MLE) o Bayesiano. El estimador MLE consiste en maximizar la función de verosimilitud de los datos:

$$\hat{\theta} = \arg \max_{\theta} P(\mathcal{D}|\theta), \quad (2.4)$$

donde  $\theta$  representa los parámetros del modelo y  $\mathcal{D}$  es el conjunto de datos observados. Para datos discretos, esto se traduce en contar frecuencias relativas para estimar las distribuciones condicionales.

Aprender la estructura del grafo es más complejo. Los enfoques principales son:

- **Búsqueda y puntuación:** evaluar distintas estructuras según un criterio (BIC, AIC, MDL).
- **Métodos basados en restricciones:** detectar relaciones de independencia condicional.
- **Aprendizaje híbrido:** combina los anteriores.

## 2.5. Implementación con pomegranate en Python

El paquete `pomegranate` ([Jacob Schreiber, 2025](#)) es una biblioteca de Python diseñada para modelado probabilístico, incluyendo redes bayesianas, modelos ocultos de Markov y mezclas gaussianas. Esta biblioteca ofrece una interfaz eficiente y flexible para definir redes, aprender sus parámetros a partir de datos y realizar inferencia.

En el contexto de redes bayesianas, `pomegranate` permite:

- Definir la estructura de la red manualmente o a partir de datos.
- Aprender las probabilidades condicionales usando métodos de máxima verosimilitud (MLE).
- Realizar inferencia exacta utilizando algoritmos internos optimizados en Python.

El aprendizaje de los parámetros en `pomegranate` se basa en el estimador de máxima verosimilitud, definido por:

$$\hat{\theta}_{MLE} = \arg \max_{\theta} \prod_{i=1}^N P(x^{(i)}|\theta), \quad (2.5)$$

donde  $x^{(i)}$  representa las observaciones del conjunto de datos. Esta formulación corresponde a maximizar la verosimilitud conjunta de los datos bajo los parámetros del modelo.

Además, en contextos secuenciales, **pomegranate** implementa el algoritmo *forward-backward*, utilizado en modelos ocultos de Markov (HMM). Este algoritmo permite calcular eficientemente la distribución posterior de los estados ocultos dados los datos observados. Matemáticamente, se define para una secuencia  $X = (x_1, \dots, x_T)$  como:

$$P(z_t|X) = \frac{\alpha_t(z_t)\beta_t(z_t)}{\sum_{z_t} \alpha_t(z_t)\beta_t(z_t)}, \quad (2.6)$$

donde  $\alpha_t(z_t)$  es la probabilidad hacia adelante (forward), y  $\beta_t(z_t)$  es la probabilidad hacia atrás (backward). Aunque este algoritmo es característico de HMMs, su lógica también puede aprovecharse para evaluar la importancia relativa de variables o secuencias en tareas de preprocesamiento para redes bayesianas.

Gracias a su rendimiento y facilidad de uso, **pomegranate** es una herramienta adecuada para la aplicación de redes bayesianas en proyectos de análisis de datos, como la prevención de incendios mediante teledetección.

# Capítulo 3

## Obtención y modelización de datos georeferenciados

La estimación del riesgo de incendio mediante el modelo de propagación según la red bayesiana presentada en el capítulo anterior requiere dividir la zona de trabajo en sectores homogéneos que puedan identificarse con los nodos del modelo, estimar la probabilidad de ignición dentro de estos y de propagación, entre sectores adyacentes. En este capítulo se presentan la zona de trabajo elegida para aplicar la modelización; la información georeferenciada empleada sobre variables ambientales, topográficas y antrópicas, y su tratamiento y modelización para obtener la correcta sectorización del terreno y las probabilidades de ignición y propagación.

### 3.1. Introducción. Zona de estudio

El área de estudio elegida es la Sierra de los Filabres, una zona montañosa localizada en la provincia de Almería, es decir, al sureste peninsular, lo cual la hace especialmente vulnerable a los incendios forestales debido a su compleja orografía, diversidad de combustibles y el clima que se caracteriza por la escasez e irregularidad de las lluvias, que apenas superan los 300 mm en las zonas bajas y rondan los 400 mm en las más altas ([Instituto de Estadística y Cartografía de Andalucía, 2025](#)). A lo largo de la historia, la sierra fue intensamente explotada por la agricultura, la ganadería y la minería, lo que

provocó una fuerte deforestación. La zona de estudio se dividirá en distintos polígonos que se han elegido teniendo en cuenta las cuencas naturales.

En la Figura 3.1 se muestra la zona del trabajo elegida para este caso estudio, abarcando un área aproximada de  $1.466,81 \text{ km}^2$ , cuyas poblaciones más relevantes son Bacaes, Bayarque, Sierró, Serón y Velefique. La zona de trabajo elegida se representa mediante un polígono representado con una línea negra superpuesta sobre el mapa base topográfico de Esri<sup>1</sup>. Esta delimitación se ha obtenido del trabajo de Rodríguez-Martínez (2021) basada en su colaboración con el INFOCA. Se encuentra en el sistema de referencia ETRS89, en proyección UTM huso 30N, por lo que, para asegurar la homogeneidad y consistencia entre datos, se ha elegido este sistema de referencia para trabajar con el resto de datos georreferenciados a lo largo de este trabajo, que se detallan en la sección subsiguiente.

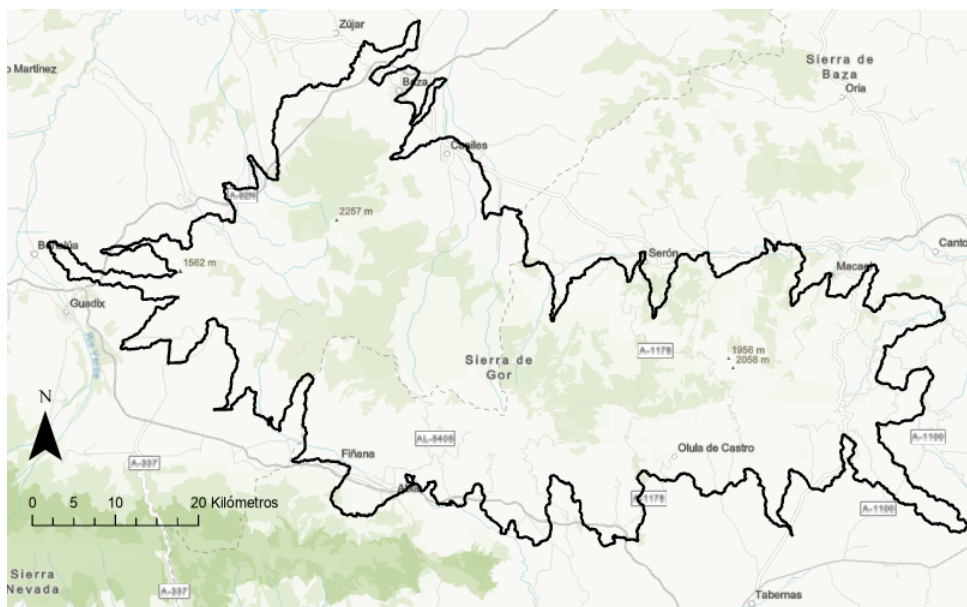


Figura 3.1: Zona elegida para el caso estudio en la Sierra de los Filabres. Fuente: elaboración propia empleando la demarcación de la zona según Rodríguez-Martínez (2021) y el mapa base de la limitación

---

<sup>1</sup><https://blog.esri.es/arcgis/contenidos/contenidos-por-categoria/mapas-base/>

## 3.2. Datos empleados y modelización

Según se ha indicado anteriormente, la sectorización del terreno se realiza mediante la determinación de cuencas hidrográficas, que se asumirá como la entidad mínima a partir de la cual puede propagarse un incendio hacia sectores adyacentes en la definición de red bayesiana. Para la estimación de las probabilidades de ignición se han empleado diversos indicadores de uso habitual para la estimación del riesgo de incendio (Caceres, 2017; Vallejo-Villalta et al., 2019): el índice de estado de la vegetación (VCI, por sus siglas en inglés *Vegetation Condition Index*), el tipo de suelo y combustible presente, la orientación, la pendiente y la distancia a núcleos de población y principales carreteras. En los siguientes apartados se describe en detalle el proceso de cálculo y tratamiento de cada uno de estos parámetros (sectorización e indicadores), las fuentes de datos utilizadas, los criterios de clasificación aplicados y los procedimientos de análisis geoespacial. Toda la modelización se ha realizado por parte de la autora empleando la herramienta ArcGIS Pro (Arcgis, 2025).

### 3.2.1. Fuentes de datos

Como se ha indicado anteriormente, los nodos de la red se asocian con sectores topográficamente homogéneos del terreno, identificados como cuencas hidrográficas. Para su determinación se han empleado datos de LiDAR (*Light detection and Ranging*) (IGN, 2025), del Plan Nacional de Ortofotografía Aérea (PNOA) (IGN, 2025a). A partir de estos datos se han obtenido tanto las cuencas del terreno para poder crear los polígonos en los que se divide la zona de estudio como, posteriormente, para obtener las pendientes y la orientación del terreno, dos de las características necesarias empleadas para el cálculo de la probabilidad de ignición.

Para obtener información del tipo del suelo y su uso, se ha usado la información del Sistema de Información sobre Ocupación del Suelo de España (SIOSE) (Ministerio de Fomento, 2025), integrado dentro del Plan Nacional de Observación del Territorio (PNOT) (IGN, 2025b).

Para la estimación del VCI de la vegetación presente en la zona de estudio se han utilizado imágenes multiespectrales por satélite obtenidas del Servicio Geológico de los Estados Unidos de América (USGS). En particular, se ha empleado una serie temporal de dos años del satélite de observación terrestre de la NASA y el USGS Landsat 8, compuesta

por imágenes multiespectrales ya corregidas atmosféricamente a través del servicio web *earthExplorer* (USGS, 2025a). Todas las imágenes son de acceso libre a través de este servicio web del USGS. La información de este índice VCI, asociada con el contenido de humedad de la vegetación, se ha correlacionado con los datos de precipitaciones en el periodo analizado obtenidos en la web de datos climáticos de la comunidad autónoma de Andalucía también de acceso libre a través del portal Ambiental de Andalucía (Junta de Andalucía, 2025).

Por último, para calcular el índice de riesgo influenciado por la distancia a las poblaciones y las carreteras de la zona de estudio, se han obtenido los datos del centro de descargas del IGN (IGN, 2025b) donde todas las imágenes son de acceso libre. La información georreferenciada de las carreteras de la Península Ibérica se ha obtenido de la Base Topográfica Nacional (BTN100) (IGN, 2025a) y la información de las poblaciones se ha obtenido de la Información Geográfica de Referencia (IGN, 2025a).

La Tabla 3.1 resume los datos empleados y las fuentes consultadas para su obtención.

<b>Dato</b>	<b>Fuente</b>	<b>Formato</b>
Datos de LiDAR (Light detection and Ranging) del Plan Nacional de Ortofotografía Aérea (PNOA)	IGN (2025,b)	Ráster
Sistema de Información sobre Ocupación del Suelo de España (SIOSE)	Ministerio de Fomento (2025)	Tabla de atributos
USGS Landsat 8	USGS (2025a)	Ráster
datos climáticos de la comunidad autónoma de Andalucía	Junta de Andalucía (2025)	Excel
Base Topográfica Nacional (BTN100)	IGN (2025a)	Ráster
Información Geográfica de Referencia	IGN (2025a)	Ráster

Tabla 3.1: Resumen de las fuentes de los datos utilizados.

### 3.3. Determinación de cuencas hidrográficas

Las unidades mínimas de terreno identificadas en este trabajo como posibles nodos de la red bayesiana son las cuencas hidrográficas, asumiendo que un posible incendio se expandiría topográficamente desde estas unidades hacia las adyacentes con diversas probabilidades. De esta manera, en este trabajo, se busca en primer lugar zonificar y poligonalizar el terreno según estas cuencas, empleando para ello modelos digitales del terreno (MDT), obtenidos a partir de los datos LiDAR del PNOT.

Estos ficheros contienen nubes de puntos LiDAR clasificados y editados a partir de datos etiquetados como terreno en la nube de puntos LiDAR con distintos pasos de malla, de 2 ó 5 metros, a partir de los cuales se derivan los subproductos MDT25 y MDT200, respectivamente (IGN, 2025), eliminando posibles artefactos presentes en la escena y editando aquellas zonas de agua embalsada y de mar con una cota constante. Las zonas con ausencia de datos LiDAR se rellenan mediante interpolación.

En este trabajo se han empleado en particular los ficheros MDT200 de segunda cobertura, es decir, los datos que se obtuvieron entre 2015 y 2021, recortados a la cuadrícula MTN25. Exactamente, en Andalucía se tomaron las imágenes aéreas en 2020, con una densidad de puntos mínima de 0,5 puntos por  $m^2$  y máxima de 2 puntos por  $m^2$ . En particular, para cubrir toda la zona de trabajo, resaltada en la Figura 3.1, se requieren 42 páginas de datos del modelo MDT200, cuyas principales características se presentan en la Tabla 3.2.

<b>Característica</b>	<b>Segunda cobertura</b>
Densidad mínima de puntos	0.5 – 2 puntos/m <sup>2</sup>
Años de vuelo	2015 – 2021
Sistema geodésico de referencia	ETRS89 o REGCAN95 husos 28, 29, 30 y 31 según corresponda
Sistema de referencia altimétrico	Altitudes ortométricas, geoide de referencia EGM08
RMSE Z	≤ 20 cm
Precisión planimétrica estimada	≤ 30 cm
Imagen simultánea	Sí, desde 2016
Tamaño ficheros	2 × 2 km (excepción Madrid)
Formato ficheros	LAS 1.2 format 3
Paso de malla del MDE	2 m × 2 m
RMSE Z (MDE)	≤ 25 cm
Precisión planimétrica estimada (MDE)	≤ 50 cm

Tabla 3.2: Especificaciones técnicas de la segunda cobertura LiDAR.

En la Figura 3.2 se presentan los datos sin tratar fusionando todas estas imágenes. La gráfica se presenta en escala de grises desde las zonas más profundas (negro) hasta las más elevadas (blanco), pudiendo distinguirse claramente los valles y crestas de la zona, que representarían la delimitación de las cuencas hidrográficas. Para su determinación física, se ha empleado en primer lugar un algoritmo de determinación de la dirección de flujo desde cada celda hasta su vecina o vecinas con pendiente descendente a partir de los datos de los 8 vecinos más cercanos. El resultado de la aplicación del algoritmo, incluido en ArcgisPro, se presenta en la Figura 3.3.




Figura 3.2: MDT200 de segunda cobertura restringido a la zona de estudio. Fuente: elaboración propia a partir de datos del LiDAR




Figura 3.3: Dirección de flujo de la zona de estudio. Fuente: elaboración propia a partir de datos del LiDAR

A partir de estos datos de dirección de flujo descendente se determina la acumulación

de flujo en cada celda, infiriendo de esta forma la posible descarga y acumulación en ríos de la zona, pudiendo delimitar entonces las distintas cuencas hidrográficas presentes en la zona de trabajo. En particular, para determinar los cauces se ha empleado un algoritmo determinista que asigna la dirección de flujo de cada celda a la dirección de mayor pendiente de entre las 8 direcciones posibles a sus vecinos más cercanos para rejillas  $3 \times 3$  (norte, noreste, este, etc.). Para el cálculo de este algoritmo determinístico de 8 direcciones (algoritmo D-8, O'Callaghan and Mark (1984)), se ha empleado la herramienta *FlowAccumulation* de ArcGis Pro, que permite además contabilizar, calcular para cada celda el flujo procedente de zonas elevadas del relieve. El resultado se muestra en la Figura 3.4, donde los valores más altos (los que muestran unos colores más fuertes) indican aquellas zonas donde hay mayor convergencia de flujo, es decir, una posible mayor acumulación de agua, cauces o redes de drenaje potenciales.

A partir de este resultado, empleando el algoritmo D-8 en sentido inverso a la dirección del flujo para cada celda puede delimitarse la cuenca hidrográfica contributiva a cada uno de estos cauces. Este último cálculo se ha realizado mediante la herramienta *watershed* de Arcgis, presentándose los polígonos correspondientes a cada cuenca superpuestos a los cauces de la Figura 3.4. Se han obtenido un total de 162 cuencas, que conformarán los nodos de la red bayesiana. Para cada una de ellas se estimarán, ponderadas por su superficie, los distintos indicadores considerados: pendiente, orientación del terreno, usos del suelo, etc.




Figura 3.4: Delimitación de las cuencas hidrográficas de la zona de estudio, las líneas coloreadas representan los posibles cauces presentes en la zona, sean estos permanentes o efímeros. Fuente: elaboración propia a partir de datos del LiDAR

### 3.4. Pendientes y orientación

Partiendo de los datos extraídos en el apartado anterior para el cálculo de cuencas de la zona de estudio que se observan en la figura 3.2 y tomando como referencia los aspectos destacados en el trabajo de [Caceres \(2017\)](#), el siguiente paso en la realización de este trabajo es el cálculo de las distintas pendientes y orientaciones. En la memoria de este trabajo se ha agrupado la explicación de estos dos aspectos de riesgo en un mismo punto, ya que para la obtención de ambas se usan los mismos datos de partida, en este caso el MDT200, y los mismos pasos posteriores para la transformación en un índice de riesgo. Para realizar ambas clasificaciones, se han usado los códigos de Python que se encuentran en el Anexo I.

En primer lugar, se ha realizado el cálculo de las pendientes de la zona de estudio, partiendo del Ráster con la información del MDT200 figura 3.2. Para identificar la pendiente (gradiente o inclinación) de cada celda del modelo se ha empleado un método de diferencias centrales para un entorno suyo de  $3 \times 3$  celdas según el algoritmo de [Horn \(1981\)](#), implementado en la herramienta *Slope* de ArcGis Pro. Con esta herramienta se ha obtenido el Ráster que se observa en la Figura 3.5 con la información de la pendiente en cada píxel.




Figura 3.5: Cálculo de las pendientes en la zona de estudio Fuente: elaboración propia a partir de datos del LiDAR

A partir de esta información por cada píxel, se ha calculado la pendiente media en cada uno de los polígonos de la zona de estudio de la sección 3.3, asignándose un índice de riesgo a cada polígono según su pendiente media. La Tabla 3.3 muestra los índices asignados, elegidos siguiendo la clasificación del riesgo según [Caceres \(2017\)](#). Para realizar esta clasificación se han usado los códigos de Python que se encuentran en el Anexo I.

Rango de pendiente (%)	Nivel de riesgo
$< 5$	1
$5 \leq \text{pendiente} < 10$	2
$10 \leq \text{pendiente} < 25$	3
$25 \leq \text{pendiente} < 35$	4
$\geq 35$	5

Tabla 3.3: Clasificación empleada para el riesgo de incendio según la pendiente del terreno.

En segundo lugar, a partir del Ráster con la información de las pendientes (Figura 3.5), se ha realizado el cálculo de las distintas orientaciones de la zona de estudio. A partir de estos datos, empleando la herramienta Aspect de ArcGis Pro, se calcula la orientación desde el norte de cada celda. Con esta herramienta se ha obtenido el Ráster con la información de la orientación en cada píxel que se muestra en la Figura 3.6.




Figura 3.6: Cálculo de la orientación en la zona de estudio Fuente: elaboración propia a partir de datos del LiDAR

Nuevamente, a partir de la información de la orientación para cada píxel, se ha cal-

culado la orientación media en cada uno de los polígonos de la zona de estudio y se ha asignado un índice de riesgo a cada polígono teniendo en cuenta su orientación media. La Tabla 3.4 muestra la clasificación del riesgo empleada (Caceres, 2017).

Rango de ángulo (°)	Dirección cardinal	Valor
< 0	No válido	None
[337.5, 360) o [0, 22.5)	Norte	1
[22.5, 67.5)	Noreste	2
[67.5, 112.5)	Este	3
[112.5, 157.5)	Sureste	4
[157.5, 202.5)	Sur	5
[202.5, 247.5)	Suroeste	4
[247.5, 292.5)	Oeste	3
[292.5, 337.5)	Noroeste	2

Tabla 3.4: Clasificación empleada del riesgo de incendio según la orientación del terreno, medida según un ángulo horario desde el Norte.

### 3.5. Tipo de suelo

Para realizar el análisis del tipo de suelo en este trabajo se ha usado la información del SIOSE, proyecto que está integrado dentro del Plan Nacional de Observación del Territorio (IGN, 2025b) cuyo objetivo es generar una base de datos de Ocupación del Suelo para toda España, desarrollado por el Ministerio de Fomento (2025).

SIOSE es una base de datos de ocupación del suelo de todo el territorio nacional a escala cartográfica de referencia 1:25.000. Divide el territorio en una serie de polígonos, teniendo cada polígono una o varias coberturas con su porcentaje de ocupación y atributos. Los datos proporcionados están compuestos de un fichero comprimido por comunidad autónoma y año de referencia. Uno de esos atributos que proporciona es el CODIIGE que describe el tipo mayoritario de cobertura de cada uno de los polígonos. Hay 46 tipos de CODIIGE (Grupo Técnico de Trabajo de Geología, 2018) para poder contemplar todos los tipos de terrenos.

Una vez obtenida la información del SIOSE de Andalucía, reducimos la información a únicamente la zona de estudio, donde hay 33 CODIIGE distintos, los cuales se han

agrupado en siete grandes grupos para facilitar la asignación de un índice de riesgo. Los grupos finales con su índice de riesgo se pueden observar en la Tabla 3.5.

<b>Tipo suelo</b>	<b>Índice Numérico</b>	<b>Escala de color</b>
Vegetación baja (zona de matorral)	5	Rojo
Zonas de invernaderos	5	Rojo
Pastos y cultivos de secano	4	Naranja
Vegetación alta (olivares, pinares)	3	Amarillo
Zonas urbanas e industriales	2	Verde Oscuro
Zona alta de roca desnuda	1	Verde Claro
Agua	1	Verde Claro

Tabla 3.5: Índice numérico de riesgo aplicado según el tipo de suelo

La Figura 3.7 muestra el riesgo resultante de aplicar el índice numérico y la escala de color que se muestra en la Tabla 3.5 a cada polígono del SIOSE para la zona de estudio, categorizado según este gradiente de colores verde-rojo para indicar el mínimo-máximo riesgo. A partir de este indicador de riesgo, para conocer el riesgo de cada una de las cuencas hidrográficas de la zona de trabajo, se ha realizado una media ponderada por el área, teniendo en cuenta el índice de riesgo y el área de cada una de las unidades poligonales del SIOSE; el resultado se puede observar en la Figura 3.8, la cual tiene también la escala de color que se muestra en la Tabla 3.5.



Figura 3.7: Riesgo por tipo de uso del suelo. Fuente: elaboración propia a partir de los datos del SIOSE




Figura 3.8: Riesgo por tipo de uso del suelo ponderado a las cuencas. Fuente: elaboración propia a partir de los datos del SIOSE

### 3.6. VCI: Vegetation Condition Index

En numerosos estudios para evaluar el riesgo de incendios se evalúa el riesgo según el tipo de vegetación anterior conjuntamente con el grado de humedad que presente (Barrios, 2011; Gilabert, 1997). En particular, en este trabajo se ha utilizado el índice *Vegetation Condition Index* (VCI), empleado habitualmente para evaluar cómo afecta la sequedad a la vegetación y el impacto de las condiciones climáticas sobre ella (Cocero et al., 2001). Su cálculo se basa en el análisis de la serie temporal del índice de diferencia normalizada infrarroja (NDII, por sus siglas en inglés *Normalised Difference Infrared Index*), mediante (Vallejo-Villalta et al., 2019):

$$VCI_i = \left( \frac{NDII_i - NDII_{\min}}{NDII_{\max} - NDII_{\min}} \right) \times 100 \quad (3.1)$$


donde  $NDII_i$  es el índice NDII para estimar la sequedad de una fecha  $i$  particular, y  $NDII_{\min}$  y  $NDII_{\max}$  los índices de sequedad mínimo y máximo de la serie temporal de imágenes multiespectrales que se analice. Los índices  $NDII_i$  de cada imagen de la serie temporal se estiman a partir de las longitudes de onda de los canales infrarrojo cercano (NIR) e infrarrojo de onda corta (SWIR), mediante:

$$NDII = \frac{NIR - SWIR}{NIR + SWIR} \quad (3.2)$$


Este índice es más sensible a los cambios de humedad que otros de uso común como el NDVI o SAVI (Cocero et al., 2001) por la utilización del infrarrojo de onda corta en su cálculo, sensible a la absorción y variabilidad del contenido de agua de las plantas. De esta manera, el NDII puede emplearse para determinar el estrés hídrico, con valores comprendidos en el intervalo  $[-1,1]$ , con valor numérico cercano a  $-1$  para un menor contenido de agua (mayor sequedad) y cercano a  $1$  para mayores contenidos de agua (mayor humedad).

Para el cálculo de ambos índices se han empleado 12 imágenes multiespectrales del satélite Landsat 8 elegidas en lo posible a intervalos regulares durante el periodo 2020–2022, teniendo en cuenta que el periodo de revisita de este satélite sobre una zona de interés limita la posibilidad de obtener imágenes con una visibilidad completa de la zona.

El cálculo se ha efectuado secuencialmente, obteniendo en primer lugar el índice  $NDII_i$  para cada imagen. La imagen b de la Figura 3.9 muestra el cálculo del NDII para la fecha 18/11/2020. Teniendo en cuenta, como se ha indicado, las imágenes se descargaron del servidor EarthExplorer, para comprobar la fiabilidad de los cálculos parciales del índice, se ha obtenido adicionalmente la evaluación de este índice de la arquitectura de procesamiento científico a demanda del USGS (ESPA, por sus siglas en inglés *Earth resources observation and science (EROS) center Science Processing Architecture*) (USGS, 2025b). La imagen a de la Figura 3.9 muestra esta evaluación para la misma fecha, comprobándose la validez del cálculo efectuado.



a. Resultado ESPA



b. Resultado análisis propio

Figura 3.9: Índice NDII para la zona de estudio la fecha 18/11/2020. Comparativa del índice calculado a partir de imágenes multiespectrales frente al resultado del servidor ESPA.

En el Anexo II se muestran todos los resultados para las imágenes de la serie temporal 2020-2022 completa. A partir de ellas, con ayuda del Arcgis Pro se ha obtenido el  $NDII_{min}$  y  $NDII_{max}$  de toda la serie temporal para la posterior determinación del  $VCI_i$  de cada imagen particular según la ecuación 3.1. Este último ofrece, entonces, valores entre 0 y 100 y refleja la variabilidad relativa de las condiciones de vegetación, según la cual los valores cercanos a cero indican condiciones de sequedad severa, mientras que los cercanos a 100 indican condiciones de humedad óptimas (Cocero et al., 2001; Kogan, 1995).

La Figura 3.10 muestra el VCI en julio del 2021, la escala de colores pasa del rojo en el caso de los VCI más bajos, al verde en los VCI más altos. Para comprobar la validez de este cálculo, y en general el de la serie completa, se ha buscado la posible correlación del índice con la pluviometría de la zona en las fechas de cálculo. Los datos de la pluviometría se han obtenido de los datos sobre el clima de la comunidad autónoma de Andalucía (Junta de Andalucía, 2025). En la Figura 3.11 se muestran los resultados de los VCI promedio calculados a partir de los datos de la serie, cuyos resultados se muestran en el Anexo

II y las precipitaciones a lo largo de la serie temporal. Puede verse claramente que el índice fluctúa positivamente o negativamente en función del aumento o disminución de la precipitación.




Figura 3.10: VCI de la zona de estudio en julio del 2021. Fuente: elaboración propia a partir de las imágenes del Landsat 8 de la NASA




Figura 3.11: Relación del VCI con las precipitaciones de la zona de estudio. Fuente: elaboración propia a partir de los datos climáticos de Andalucía.

Por último, el cálculo del índice de riesgo asociado a esta variable se promedia para cada uno de los polígonos de la zonificación según cuencas hidrográficas de la sección 3.3 y se re-escala según una escala numérica homogénea a las anteriormente utilizadas. La Tabla 3.6 recoge la categorización empleada, análoga a (Vallejo-Villalta et al., 2019).

VCI Rango	Indice Numérico	Nivel de sequedad	Escala de color
(0–20)	5	Extremo	Rojo
(20–40)	4	Severo	Naranja
(40–60)	3	Moderado	Amarillo
(60–80)	2	Bajo	Verde Amarillento
(80–100)	1	Muy bajo	Verde

Tabla 3.6: Clasificación del Vegetation Condition Index (VCI).

En particular, la Figura 3.12 muestra el mapa de riesgo por VCI en julio de 2021 para la zona de estudio según la categorización de riesgo y la escala de color que se muestra en la Tabla 3.6. Para esta fecha, según se observa en la Figura 3.11, se ha obtenido el valor medio del VCI más bajo de la serie, de aproximadamente 20.24%. Al ser la imagen de mayor riesgo por VCI y ser este un índice variable para toda la serie temporal, se ha elegido esta imagen para completar el cálculo del riesgo de incendio y probabilidad de ignición en la sección 4.2.




Figura 3.12: Riesgo de la zona del estudio por VCI en julio del 2021. Fuente: elaboración propia a partir de las imágenes del Landsat 8 de la NASA

### 3.7. Distancia a carreteras y a núcleos urbanos

La distancia a carreteras y núcleos urbanos constituye un factor ampliamente reconocido en la modelización del riesgo de incendios forestales, debido a su relación directa con la probabilidad de ignición de origen antrópico. Diversos estudios han documentado que en regiones mediterráneas, como la península ibérica, más del 90 % de los incendios tienen causas humanas, asociadas tanto a actividades accidentales como intencionadas (WWF, 2025). Ambas variables, distancia a vías de comunicación y a núcleos de población, son comúnmente empleadas como indicadores para la evaluación del riesgo de incendios forestales (Caceres, 2017; Cocero et al., 2001; Vallejo-Villalta et al., 2019).

Al igual que en los anteriores apartados de este capítulo, se va a calcular el riesgo de incendio asociado a la distancia a las carreteras y los núcleos urbanos de la zona de estudio, se modelará discretizando el riesgo en 5 clases discretas, según las distancias extraídas de Caceres (2017). En ambos casos se han obtenido los datos del centro de descargas del IGN (IGN, 2025b) y se han tratado posteriormente en ArcGis Pro.

### 3.7.1. Riesgo asociado a la distancia de carreteras

La información georreferenciada de las carreteras de la Península Ibérica se ha obtenido de la Base Topográfica Nacional a escala 1:100.000 (BTN100) del centro de descargas del IGN (IGN, 2025a).

La BTN100 contiene 56 capas de información geográfica que abarcan datos topográficos y temáticos. Diseñado para su explotación mediante Sistemas de Información Geográfica (SIG), es capaz de servir de soporte tanto a consultas geográficas, como a la producción de productos cartográficos. Se encuentra disponible para descarga como un SIG continuo para toda España y agrupado por temática: Unidades administrativas y zonas protegidas, Altimetría, Hidrografía, Entidades de población y construcciones, Redes de transporte, Conducciones y Vértices geodésicos (IGN, 2025a).

Para la realización de este trabajo se ha utilizado la capa con la información de las carreteras. Como se indica en el párrafo anterior, las capas son continuas para toda España, por lo que el primer paso ha sido proyectar la capa en el sistema de referencia que se está utilizando y recortar la capa para obtener únicamente las carreteras de la zona de estudio. El Ráster, ya restringido a la zona de estudio, con el que se va a trabajar es el que se muestra en la Figura 3.13.

A continuación, se ha utilizado la herramienta de ArcGis Pro DistanceAccumulation (ArcGIS, 2025) una herramienta que calcula la distancia acumulada de cada celda a los orígenes, teniendo en cuenta la distancia en línea recta, coste-distancia y verdadera distancia de superficie, así como factores de coste vertical y horizontal. A las distancias así obtenidas se les ha asignado un riesgo numérico, según los indicadores de la Tabla 3.7. La Figura 3.14 muestra el mapa final con este riesgo, etiquetando el riesgo anterior mediante un código de colores empleado en la memoria, desde el rojo para el nivel más alto de riesgo (lo más próximo a la carretera) y verde para el menor nivel de riesgo (más alejado).




Figura 3.13: Carreteras de la zona de estudio Fuente: elaboración propia a partir de los datos del BTN100

Distancia en m	Indice Numérico	Riesgo de incendio	Escala de color
<50 m	5	Muy alto	Rojo
50–100 m	4	Alto	Naranja
100–200 m	3	Moderado	Amarillo
200–300 m	2	Bajo	Verde Amarillento
>300 m	1	Muy bajo	Verde

Tabla 3.7: Clasificación del riesgo de incendio por distancia de carreteras




Figura 3.14: Riesgo por proximidad a carreteras Fuente: propia a partir de los datos del BTN100

A partir de la información de la figura 3.14 se ha calculado el riesgo medio de proximidad a carreteras de cada uno de los polígonos principales de la figura 3.4 para obtener una única cifra por cada polígono, como en los parámetros calculados anteriormente, y así al final poder aplicar un modelo de obtención de riesgo de ignición en cada uno de los polígonos. El resultado es una tabla que contiene, en este caso, la media del valor de riesgo correspondiente a cada polígono.

### 3.7.2. Riesgo asociado a la distancia de núcleos urbanos

La información georreferenciada de las poblaciones de la Península Ibérica se ha obtenido de la Información Geográfica de Referencia del centro de descargas del IGN (IGN, 2025a).

La Base de datos con información georreferenciada de poblaciones, con cobertura nacional, contiene las agrupaciones de uno o más edificios, indistintamente de su uso, que son conocidos por una misma denominación. Incluyen sus espacios asociados y están geométricamente definidas sobre el parcelario catastral, integran el código de la unidad estadística del INE a la que pertenece, el nombre geográfico que lo identifica, el uso representativo,

así como otras características que son interesantes desde el punto de vista poblacional. Este conjunto de datos está diseñado conforme a las directrices definidas para la Gestión de la Información Geoespacial de Referencia de Naciones Unidas (IGN, 2025a). El Ráster final con el que se va a trabajar es el que se muestra en la Figura 3.15.




Figura 3.15: poblaciones de la zona de estudio Fuente: elaboración propia a partir de la Información Geográfica de Referencia del centro de descargas del IGN

Tal como ocurría con el apartado de distancia a carreteras anterior, las capas son continuas para toda España, por lo que se ha seguido un procedimiento análogo al empleado en ese caso: proyectar la capa en el sistema de referencia empleado y restringir el conjunto de datos a los núcleos urbanos de la zona de estudio, calculando en segundo lugar su distancia a cada punto de la zona de estudio. Al resultado se le asigna la puntuación de riesgo siguiendo los indicadores de la Tabla 3.8. La figura 3.16 muestra el mapa final asociado a este riesgo, tomando la escala de color que se explica en la tabla.

Distancia en m	Indice Numérico	Riesgo de incendio	Escala de color
<500 m	5	Muy alto	Rojo
500–1000 m	4	Alto	Naranja
1000–2000 m	3	Moderado	Amarillo
2000–3000 m	2	Bajo	Verde Amarillento
>3000 m	1	Muy bajo	Verde

Tabla 3.8: Clasificación del riesgo de incendio por distancia a poblaciones




Figura 3.16: Riesgo por proximidad a poblaciones Fuente: propia a partir de la Información Georreferenciada del IGN

De la misma manera que en el apartado anterior con la distancia a las carreteras, se ha calculado el riesgo medio de proximidad a poblaciones de cada uno de los polígonos principales y así poder aplicar un modelo de obtención de riesgo de ignición en cada uno de los polígonos.

# Capítulo 4

## Resultados

### 4.1. Integración de indicadores de riesgo mediante el método AHP

Con el objetivo de unificar los distintos indicadores de riesgo empleados en el análisis mostrado en el capítulo anterior en un único valor representativo para transformarlo en una probabilidad que otorgue el peligro de ignición, se ha aplicado una técnica de análisis multicriterio basada en el método Analytic Hierarchy Process (AHP), desarrollado por [Saaty \(1987\)](#). Este enfoque permite asignar pesos relativos a cada una de las variables consideradas en el modelo, a partir de comparaciones por pares que reflejan su importancia relativa.

En nuestro caso, las variables incorporadas al modelo incluyen el contenido de humedad del combustible (FMC), en este trabajo se ha usado VCI que se ha calculado en el capítulo anterior; el tipo de combustible; la pendiente; la orientación del terreno; y las distancias a carreteras y núcleos de población.

La matriz de comparación por pares se construye asignando valores según la escala de Saaty, que establece niveles de importancia de 1 (igual importancia) hasta 9 (importancia extrema), incluyendo los valores inversos para representar menor importancia. En la [Tabla 4.1](#) se muestra la matriz elaborada para este estudio.

Comparación	VCI	Combustible	Pendiente	Orientación	Carreteras	Poblaciones
VCI	1	3	5	5	7	7
Combustible	1/3	1	3	3	5	5
Pendiente	1/5	1/3	1	2	3	3
Orientación	1/5	1/3	1/2	1	2	2
Carreteras	1/7	1/5	1/3	1/2	1	1
Poblaciones	1/7	1/5	1/3	1/2	1	1

Tabla 4.1: Matriz de comparación por pares entre variables según la escala de [Saaty \(1987\)](#)

A partir de la matriz de comparación por pares, se han aplicado los pasos establecidos en el método AHP para obtener los pesos relativos de cada criterio. En primer lugar, se calculan las sumas de cada una de las columnas de la matriz de comparaciones. Posteriormente, se construye la matriz normalizada (4.1) dividiendo cada elemento de la matriz inicial por la suma de su respectiva columna, es decir:

$$a_{ij}^* = \frac{a_{ij}}{\sum_{i=1}^n a_{ij}} \quad (4.1)$$

donde  $a_{ij}$  representa el valor de la comparación entre el criterio  $i$  y el criterio  $j$ , y  $a_{ij}^*$  es el valor normalizado. A continuación, se calcula el promedio de los valores de cada fila de la matriz normalizada, obteniendo así el vector de prioridades (4.2) o pesos relativos de los criterios:

$$w_i = \frac{\sum_{j=1}^n a_{ij}^*}{n} \quad (4.2)$$

donde  $w_i$  es el peso asociado al criterio  $i$  y  $n$  es el número de criterios considerados. De este modo, se determina la importancia relativa de cada variable (VCI, combustible, pendiente, etc.) dentro del índice global de riesgo de ignición.

Por otro lado, con el fin de garantizar que las comparaciones establecidas no sean contradictorias, se ha calculado el Índice de Consistencia (CI). Este se obtiene a partir del valor propio máximo ( $\lambda_{\max}$ ) de la matriz de comparaciones, siguiendo la expresión:

$$CI = \frac{\lambda_{\max} - n}{n - 1}. \quad (4.3)$$

Un valor de  $CI$  cercano a cero indica una adecuada coherencia en las comparaciones, mientras que valores elevados reflejan inconsistencias que requieren revisar la matriz inicial. Para evaluar de forma más precisa la validez del modelo, Saaty (1987) propone además calcular la Razón de Consistencia ( $CR$ ), definida como:

$$CR = \frac{CI}{RI} \quad (4.4)$$

donde  $RI$  es el índice aleatorio obtenido a partir de simulaciones con matrices de igual tamaño. Generalmente, se acepta que el modelo es consistente si  $CR < 0.1$ . Este procedimiento asegura que los pesos asignados a cada variable no provienen de juicios arbitrarios o incoherentes, garantizando la fiabilidad del índice de riesgo de ignición resultante.

Los pesos aproximados obtenidos para cada variable, resultado del proceso anterior, se muestran en la Tabla 4.2.

Variable	Peso AHP
VCI	0.45
Combustible	0.22
Pendiente	0.11
Orientación	0.08
Distancia a carreteras	0.07
Distancia a poblaciones	0.07

Tabla 4.2: Pesos relativos estimados mediante el método AHP

Este modelo reproduce de forma cercana los pesos propuestos en el modelo de Chuvieco et al. (2010), así como en la formulación de Caceres (2017), en la cual el tipo de combustible representa un 66 % del índice total, cifra muy próxima al 67 % obtenido al sumar los pesos de VCI y tipo de combustible en este trabajo. Ya que el modelo propuesto en el trabajo de Caceres (2017) solo se tiene en cuenta el tipo de combustible. Además, se obtiene un  $CI = 0.029$  y un  $CR = 0.023$ , lo cual indica que el modelo es coherente y consistente siguiendo las definiciones de los párrafos anteriores.

La metodología AHP ha sido ampliamente utilizada en estudios recientes que combinan análisis espacial y teledetección para la evaluación del riesgo de incendios forestales (Adelabu et al., 2020; Ajin et al., 2016). Finalmente, en la Figura 4.1 se muestra el índice de riesgo de cada zona una vez que se ha aplicado el modelo AHP.

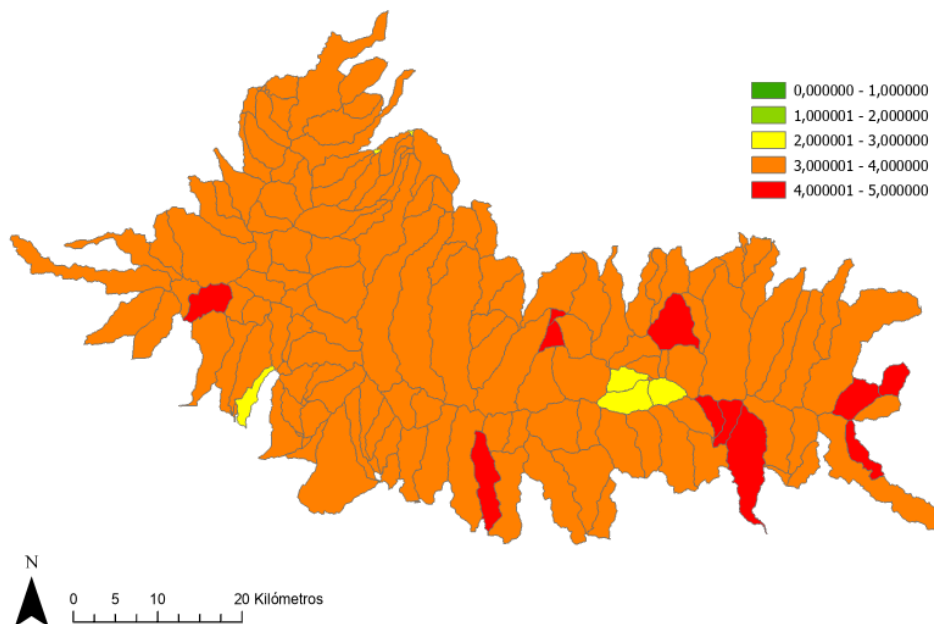


Figura 4.1: Mapa de probabilidad base de ignición Fuente: propia, realizado en Python

## 4.2. Calculo de la probabilidad de ignición

Para transformar el índice numérico de riesgo en una probabilidad, en este trabajo se ha procedido siguiendo la estructura metodológica descrita en el apartado 5.4.2 del trabajo de Rodríguez-Martínez (2021), pero en este caso en vez de tomar únicamente el riesgo de las carreteras se va a introducir el riesgo calculado en este trabajo que contiene muchos más detalles y una evaluación mayor de la zona de la Sierra de los Filabres. Este proceso se ha realizado usando el código que se muestra en el Anexo II donde la función *winds\_points* pertenece al código del trabajo de Rodríguez-Martínez (2021).

Como se ha explicado, partimos del índice de riesgo  $r_i$  que es el obtenido con las

indicaciones de la sección anterior para cada polígono  $i = 1, \dots, N$  que no está en escala probabilística, es decir, es un número entre 1 y 5, en este caso  $N = 162$ . Como se muestra en la ecuación 4.5 primero normalizamos el índice de riesgo para obtener pesos relativos entre 0 y 1.

$$\tilde{r}_i = \frac{r_i}{\sum_{j=1}^N r_j}. \quad (4.5)$$

La probabilidad base de ignición por polígono se muestra en la ecuación 4.6 y en la Figura 4.2 se observa esta probabilidad representada en el mapa de la zona de estudio:

$$p_i^{(0)}(ig_i) = \tilde{r}_i. \quad (4.6)$$

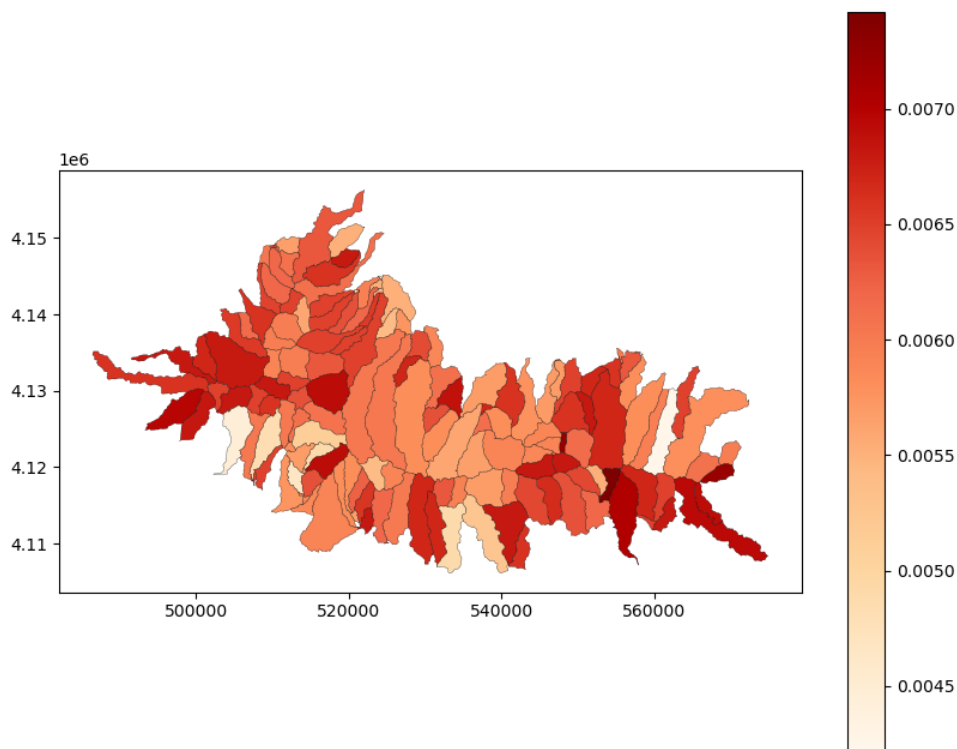


Figura 4.2: Mapa de probabilidad base de ignición Fuente: propia, realizado en Python

En un segundo paso se ha tenido en cuenta la velocidad y dirección del viento. Para

intentar tener una aproximación del efecto que puede tener la velocidad del viento en la probabilidad de ignición se han utilizado las reglas y los modelos de vientos que se proponen en el trabajo de [Rodríguez-Martínez \(2021\)](#):

- Si el viento sopla a menos de 5 km/h en el sector  $i$ , entonces la probabilidad de ignición se reduce a la mitad:

$$\tilde{p}^k(ig_i) \rightarrow \tilde{p}^k(ig_i)^2, \quad (4.7)$$

- Si el viento sopla entre 5 y 10km/h, entonces la probabilidad de ignición no se altera
- Si el viento sopla entre 10 y 15 km/h en el sector  $i$ , entonces la probabilidad de ignición será el doble:

$$\tilde{p}^k(ig_i) \rightarrow 1 - (1 - \tilde{p}^k(ig_i))^2, \quad (4.8)$$

- Si el viento sopla a más de 15 km/h en el sector  $i$ , entonces la probabilidad de ignición será el triple

$$\tilde{p}^k(ig_i) \rightarrow 1 - (1 - \tilde{p}^k(ig_i))^3. \quad (4.9)$$

Teniendo en cuenta los datos de los registros en la zona de estudio, ha habido 29 incendios entre los años 1945 y 2018, por lo que en un último paso para intentar obtener una probabilidad esperada lo más cercana posible a la realidad, se realiza el cálculo de  $\lambda$  para que cumpla la ecuación (4.10).

$$p^k(ig_j) = \tilde{p}^k(ig_j)^\lambda, \quad \hat{\lambda} = \arg \min_{\lambda > 1} \left| \frac{29}{2018 - 1975} - \sum_{k=1}^K p_k \cdot \sum_{i=1}^n \tilde{p}^k(ig_i)^\lambda \right|. \quad (4.10)$$

Finalmente, a través (4.10) se obtiene un  $\lambda = 1.1166$ . Con este  $\lambda$  se obtiene una probabilidad de ignición esperada de 0.6745 la cual es muy similar a 0.6744 que es la probabilidad real según los registros.

Con este procedimiento, el índice  $r_i$  se convierte en una probabilidad de ignición calibrada, ajustada al efecto del viento y coherente con la frecuencia histórica global.

### 4.3. Escenarios de viento

Las probabilidades anteriores representarían las posibles probabilidades de ignición de los nodos de la red bayesiana. Para estimar la posible propagación a nodos adyacentes se consideran pesos entre los arcos o aristas que los unen debido a la dirección del viento anterior. En particular se tomará como referencia base el trabajo de [Rodríguez-Martínez \(2021\)](#) donde se desarrolla la metodología para la construcción de escenarios de viento en la Sierra de los Filabres.

Para realizar el cálculo de los escenarios de viento, en primer lugar, se recopilan y filtran los datos históricos de viento de la región en función de las condiciones de temperatura y humedad relativa, con el objetivo de centrarse en las situaciones más favorables para la propagación del fuego. Posteriormente, se reduce la dimensionalidad de los datos tomando sus primeras componentes principales.

Después, teniendo en cuenta que el modelo que se usa es una mixtura gaussiana, lo que significa que los datos son una suma de muchas normales, se utiliza el algoritmo EM (Expectation-Maximization) para estimar los parámetros de cada componente y sus pesos.

El número de escenarios de viento se determina en un modelo de mixtura de distribuciones Gaussianas. Para seleccionar el número óptimo de componentes, se utilizan contrastes sucesivos de razón de verosimilitud entre modelos con  $K$  y  $K + 1$  distribuciones. El estadístico considerado es

$$\Lambda = \frac{L_K}{L_{K+1}}, \quad (4.11)$$

donde  $L_K$  y  $L_{K+1}$  representan las verosimilitudes máximas de cada modelo. Este valor se contrasta con una distribución  $\chi^2$  cuyos grados de libertad dependen de la diferencia en el número de parámetros entre los modelos. Si  $\Lambda$  resulta significativo, se adopta el modelo con  $K + 1$  componentes; en caso contrario, se mantiene el valor de  $K$ . De esta forma, el número final de escenarios de viento se obtiene de manera objetiva, evitando tanto la infraestimación como el sobreajuste de los datos.

Finalmente, se obtiene el conjunto de escenarios de viento aplicando la transformación

inversa de las componentes principales calculadas en los pasos anteriores a las medias de cada distribución, de modo que cada escenario  $E_s = (\theta_s, v_s)$  queda caracterizado por una dirección dominante  $\theta_s$  y una velocidad media  $v_s$ .

Los escenarios de viento utilizados en este trabajo son los que se calcularon en el trabajo de [Rodríguez-Martínez \(2021\)](#). Los cálculos se realizaron utilizando los datos de CORDEX (Coordinated Regional Climate Downscaling Experiment) del WCRP (World Climate Research Program), con una profundidad histórica desde 1995 hasta 2005 y con una resolución temporal de 6h para los vientos y de 3h en el caso de la temperatura y la humedad.

Los resultados finales se muestran en la Figura 4.3. Como se observa, esta metodología permite representar de manera objetiva la variabilidad del viento y constituye un insumo esencial para la modelización de la propagación de incendios.

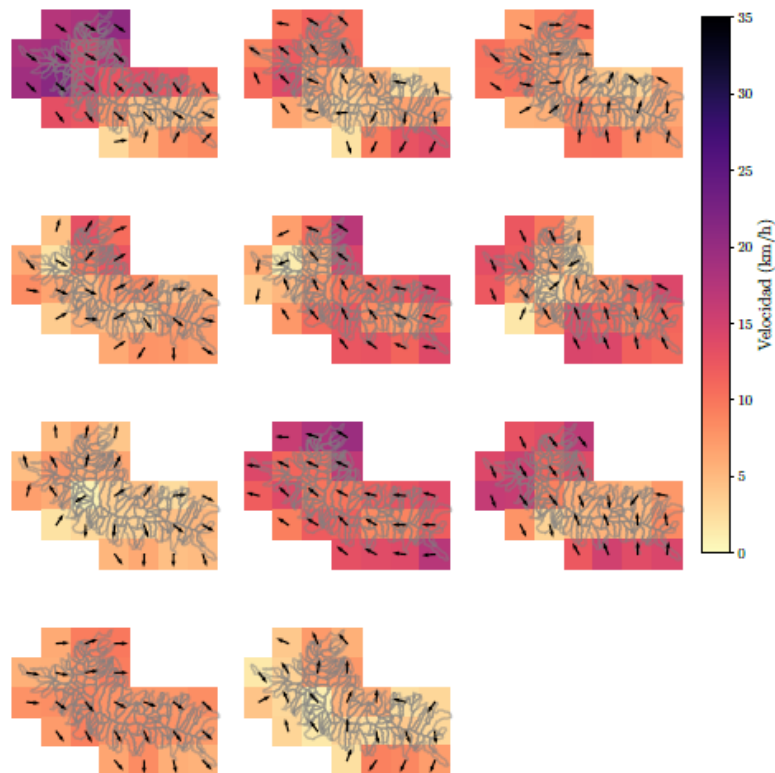


Figura 4.3: Mapas con los once escenarios de viento Fuente: [Rodríguez-Martínez \(2021\)](#)

## 4.4. Resolución de la red bayesiana

El último paso de este trabajo será calcular la probabilidad de propagación, teniendo en cuenta la probabilidad de ignición calculada en el apartado anterior y los once modelos de viento. Para realizar este cálculo se ha realizado un ajuste de una red bayesiana basándose en lo propuesto en el trabajo de [Rodríguez-Martínez \(2021\)](#).

La red de propagación puede contener ciclos, por lo que el método de cálculo no trabaja directamente con una única red cíclica, sino que realiza un preprocesamiento exacto que descompone el problema en un conjunto finito de redes bayesianas acíclicas mutuamente excluyentes y exhaustivas. Cada una se resuelve de forma independiente y sus resultados se combinan ponderando por la probabilidad de la red sin ciclos correspondiente.

Sea  $A = \{a_{ij}\}$  el conjunto de aristas de propagación potencial entre sectores y sea  $p(a_{ij})$  la probabilidad de propagación  $i \rightarrow j$ . El preprocesamiento define un espacio de modelos  $\{\Omega_k\}_{k=1}^K$  indexado por subconjuntos  $A_k \subseteq A$  de aristas, tales que el grafo inducido  $G_k = (V, A_k)$  es acíclico. La probabilidad de cada submodelo es el producto de las probabilidades de activación de sus aristas:

$$p_k = \prod_{a_{ij} \in A_k} p(a_{ij}) \prod_{a_{ij} \in A \setminus A_k} (1 - p(a_{ij})), \quad (4.12)$$

y la colección  $\{\Omega_k\}$  forma una partición probabilística del modelo original (exhaustiva y con eventos disjuntos).

Para la resolución de cada red bayesiana, una vez definidas las probabilidades de ignición  $p_k(\text{ig}_i)$  y de propagación  $p_k(\text{sp}_{ij})$  para cada escenario, cada submodelo  $\Omega_k$  proporciona la probabilidad condicional  $\tilde{p}_k(F_i)$  de incendio en el sector  $i$ . La probabilidad total se obtiene por mezcla:

$$p(F_i) = \sum_{k=1}^K p_k \tilde{p}_k(F_i). \quad (4.13)$$

La resolución de cada red bayesiana acíclica en el caso práctico se implementó en Python apoyándose en el paquete pomegranate de [Schreiber \(2018\)](#) como plantea [Rodríguez-Martínez \(2021\)](#), que ejecuta el algoritmo de *loopy belief propagation* y, en redes sin ciclos, produce la inferencia exacta de las marginales  $p(F_i)$ .

En la figura 4.4 se puede observar la red ya ajustada, teniendo en cuenta los escenarios

de viento y la probabilidad de ignición calculada a partir del índice de riesgo que se ha obtenido durante todo el desarrollo de este trabajo.




Figura 4.4: Solución de la red una vez ha sido ajustada para ser fiel al registro histórico en cuanto a las observaciones globales. Fuente: propia, realizado en Python utilizando los códigos de [Rodríguez-Martínez \(2021\)](#)

# Capítulo 5

## Análisis de resultados y conclusiones

A lo largo de este trabajo se ha desarrollado una metodología integral para la evaluación y modelización del riesgo de incendios forestales en la Sierra de los Filabres, empleando para ello una modelización estocástica del terreno mediante redes bayesianas que permite estimar la probabilidad de sufrir un incendio en sectores del territorio considerado.

Para ello, se sectoriza inicialmente el terreno en unidades homogéneas que puedan identificarse como nodos de la red, estudiándose entonces las probabilidades de ignición de los sectores y de propagación entre ellos a partir de las cuales estimar la probabilidad total y poder identificar los sectores más probables de experimentar un incendio. En este capítulo se presentan las principales conclusiones derivadas de cada una de las etapas realizadas en este proceso de segmentación del terreno y cálculo de probabilidades marginales de ignición a partir de datos de teledetección.

En primer lugar, se identificaron estas unidades mínimas homogéneas asociables a los nodos de la red como las cuencas hidrográficas naturales del área de estudio, asumiendo que un posible incendio se expandiría topográficamente desde estas unidades hacia las adyacentes. A partir de las nubes de puntos del modelo digital del terreno de la zona MDT200 del Plan Nacional de Ortofotografía Aérea, se determinaron las redes de drenaje a partir de la dirección de flujo descendente y se delimitaron las cuencas contributivas a los cauces presentes en la zona en sentido opuesto. Este procedimiento sectoriza el terreno en 162 cuencas hidrográficas.

La probabilidad de ignición de cada una de ellas se obtuvo a partir de indicadores de riesgo de incendio de uso habitual en la literatura, como son la pendiente y orientación del terreno, los distintos usos y coberturas del suelo y el estado de humedad de la vegetación. También se consideró un posible riesgo antrópico, categorizando el riesgo en función de la distancia a carreteras y poblaciones.

Las pendientes y orientaciones del terreno se calcularon nuevamente a partir del MDT200, considerándose como zonas de mayor riesgo aquellas con mayores pendientes y orientación sursuroeste. Siendo la zona montañosa, la pendiente oscila entre unos valores del 0 % en las zonas de pastos y cultivos de invernaderos hasta el 70 %, en las cumbres. La pendiente promedio en la zona de estudio es de 14 % siendo el riesgo promedio de este indicador medio.

Los distintos usos y coberturas del suelo presentes en la zona se estudiaron a partir de datos provenientes del Sistema de Información sobre Ocupación del Suelo de España, que contiene datos de coberturas del terreno de hasta 46 categorías y su porcentaje de ocupación. Estos datos se agruparon y clasificaron en siete grandes categorías principales con diferentes niveles de riesgo según el tipo de vegetación presente (matorrales, pastizales, cultivos, olivares, pinares, ...) y uso del suelo (urbano, industrial, invernaderos, ...). La zona de mayor riesgo según este indicador corresponde al sur-suroeste de la zona de estudio, asociado a varias cuencas con alta presencia de invernaderos. Categorizando el riesgo en 5 niveles, desde muy bajo hasta muy alto, dada la abundancia de zonas de matorral, pastos y cultivos de secano, el riesgo promedio por este indicador resulta ser alto.

Para evaluar cómo afecta la sequedad a esta vegetación y el impacto de las condiciones climáticas sobre ella, el riesgo anterior se ha estudiado conjuntamente con el grado de humedad que presenta. En particular, en este trabajo se ha utilizado el índice porcentual de VCI, de condición de la vegetación, derivado a partir de una serie temporal del índice de diferencias infrarrojo normalizado durante el periodo 2020-2022. Este último índice se obtuvo a partir de la información de los canales infrarrojo cercano e infrarrojo de onda corta, sensibles al estrés hídrico de la vegetación, de imágenes multiespectrales adquiridas por el satélite Landsat 8. En esta serie, se identificó el mes de julio de 2021 como aquel con condiciones de humedad más críticas de la serie, con un VCI promedio de 20.24 %, frente a un valor promedio de la serie de aproximadamente el 40 %. Durante este período se obtuvo el valor más elevado del índice en abril de 2020, con un VCI del 64.92 %. Para validar estos resultados se ha comparado el índice obtenido con datos de precipitaciones de la base de datos sobre el clima de la comunidad autónoma de Andalucía, observándose una clara correlación entre la pluviometría y el índice, siendo pues adecuado para esti-

mar las variaciones en la humedad de la vegetación. Por último, se elaboraron mapas de riesgo asociados a la proximidad de carreteras y poblaciones, factores determinantes en la probabilidad de ignición de origen antrópico.

Para estimar el indicador potencial de incendio que integrase todos los indicadores anteriores se eligió un proceso multicriterio AHP, que permite asignar pesos relativos a cada una de las variables consideradas en el modelo, a partir de comparaciones por pares que reflejan su importancia. La modelización empleada ha permitido obtener unos pesos más altos para el estado de la vegetación (45 %) y usos del suelo y tipo de combustible (22 %); pendientes y orientaciones, y distancias a carreteras y poblaciones tienen un peso inferior, del 11 %, 8 %, 7 % y 7 % respectivamente. El bajo índice de consistencia sugiere que el modelo es consistente, además de ser coherente y acorde con los empleados habitualmente en la literatura. El índice promedio obtenido de esta forma para julio de 2021, mes de peor índice VCI, muestra un riesgo elevado de incendio en toda la zona de estudio, con un índice promedio de 4.07 en una escala donde 1 es el menor riesgo y 5 el riesgo más alto. Por contraposición, el mapa teniendo en cuenta el VCI de abril de 2020 muestra un riesgo medio con un índice promedio de 3.16 utilizando la misma escala numérica que en julio de 2021.

Para integrar este indicador de riesgo potencial de incendio calculado por el método AHP en una probabilidad de ignición para el modelo matemático de propagación de redes bayesianas, se consideró una ponderación adicional según la velocidad de viento, estimada a partir de escenarios de viento de [Rodríguez-Martínez \(2021\)](#) en base a una muestra de datos de 1995-2005. El resultado se moduló y ajustó al registro de incendios del período 1945-2018, obteniéndose de esta forma un mapa probabilístico base de riesgo de ignición de la zona. Este mapa de riesgo espacial sugiere como zonas de probabilidad más alta el este y el oeste de la zona de estudio.

Finalmente, la red bayesiana considera un escenario de viento promedio a partir del cual se estima la probabilidad de propagación de un incendio a sectores adyacentes, obteniéndose una solución probabilística en red del riesgo de incendio. Nuevamente, para el escenario de mayor riesgo con el VCI más bajo en julio de 2021, destacan cuencas de probabilidad muy alta al este y oeste de la zona de estudio con una probabilidad máxima del 3.5 %, si bien varias zonas del centro y sur también se aprecian al considerar la propagación como zonas altamente vulnerables a la aparición y propagación del fuego.

En conjunto, los resultados obtenidos demuestran, por un lado, la utilidad de las redes bayesianas como herramienta para integrar información heterogénea y ofrecer una estimación probabilística del riesgo de incendios forestales, y, por otro lado, la utilidad de

la teledetección para conocer el estado del suelo y obtener una probabilidad de ignición muy precisa. Además, la metodología aplicada proporciona una base para la toma de decisiones en prevención y gestión de emergencias, siendo fácilmente adaptable a otros territorios con características similares.

El mapa de riesgo de incendios generado permite, por un lado, reconocer y ubicar las áreas con mayor probabilidad de verse afectadas a mediano y largo plazo, lo que brinda a las autoridades locales una mejor capacidad para planificar infraestructuras permanentes de prevención y control (como la instalación de torres de vigilancia o la construcción de cortafuegos). Por otro lado, con este método es sencillo hacer una evaluación de la variación del riesgo de incendio a lo largo del año, teniendo en cuenta las precipitaciones, lo cual resulta clave para orientar la atención hacia zonas específicas según la estación o el periodo considerado. Incluso en días hábiles, esta información posibilita la adopción de medidas puntuales, como organizar rutas de patrullaje o establecer restricciones sobre ciertas actividades en áreas determinadas, complementando así las alertas tempranas frente a condiciones meteorológicas extremas.

Asimismo, los mapas de riesgo podrían integrarse en la planificación futura de los planes de emergencia contra incendios, ya que aportan información sobre los sectores de asentamientos concentrados y dispersos, además de las infraestructuras de transporte y energía que podrían verse comprometidas en caso de un incendio forestal.

# Bibliografía

- A. L. Westerling, H. G. Hidalgo, D. R. Cayan, and T. W. Swetnam (2006). Warming and earlier spring increase western U.S. forest wildfire activity. *Science*, 313(5789):940–943.
- Adelabu, S. A., Adepoju, K. A., and Mofokeng, O. D. (2020). Estimation of fire potential index in mountainous protected region using remote sensing. *Geocarto International*, 35(1):29–46.
- Ajin, Loghin, A.-M., Jacob, M. K., P.G., V., and R.R., K. (2016). The Risk Assessment Study of Potential Forest Fire in Idukki Wildlife Sanctuary using RS and GIS Techniques. *International Journal of Advanced Earth Science and Engineering*, 5(1):308–318.
- Arcgis (Recurso en línea [//www.esri.com/](http://www.esri.com/), accedido el 14-01-2025). Software SIG de escritorio — Análisis cartográfico — ArcGIS Pro.
- ArcGIS (Recurso en línea [/www.pro.arcgis.com/](http://www.pro.arcgis.com/), accedido el 21-07-2025). Acumulación de distancia (Spatial Analyst)—ArcGIS Pro — Documentación.
- Barrios, I. (2011). (c) Consejo Superior de Investigaciones Científicas Licencia Creative Commons 3.0 España (by-nc) <http://estudiosgeograficos.revistas.csic.es>. *Investigaciones Científicas*, (0014'1456).
- Caceres, C. F. (2017). Using GIS in Hotspots Analysis and for Forest Fire Risk Zones Mapping in the. (August 2011).
- Cheng, H. and Hadjisophocleous, G. V. (2009). The modeling of fire spread in buildings by Bayesian network. *Fire Safety Journal*, 44(6):901–908.
- Chuvieco, E., Aguado, I., Yebra, M., Nieto, H., Salas, J., Martín, M. P., Vilar, L., Martínez, J., Martín, S., Ibarra, P., de la Riva, J., Baeza, J., Rodríguez, F., Molina, J. R., Herrera, M. A., and Zamora, R. (2010). Development of a framework for fire risk assessment using remote sensing and geographic information system technologies. *Ecological Modelling*, 221(1):46–58.

- Cocero, D., Salas, J., and Chuvieco, E. (2001). El sensor Spot-Vegetation una nueva alternativa en la estimación de la humedad de la vegetación. *Teledetección, Medio Ambiente y Cambio Global*, (April):179–182.
- Collins, S. P., Storrow, A., Liu, D., Jenkins, C. A., Miller, K. F., Kampe, C., and Butler, J. (2021). *Bayesian Artificial Intelligence*.
- Constanza V. Paura (2025). Los peores incendios forestales en la historia de España: 2025 ya es el año más catastrófico del siglo XXI. *National Geographic*.
- Geolat (Recurso en línea [ww.geolat.es](http://ww.geolat.es), accedido el 08-07-2025). La realidad desoladora de los Grandes Incendios Forestales (GIF) — Geolat.
- Gilabert, M. A. (1997). Acerca de los índices de vegetación. (January).
- Grupo Técnico de Trabajo de Geología (2018). Guía de transformación de conjuntos de datos espaciales de Geología al marco INSPIRE. page 94.
- Horn, B. K. P. (1981). Hill shading and the reflectance map. *Proceedings of the IEEE*, 69(1):14–47.
- IGN (Recurso en línea [www.centrodedescargas.cnig.es/](http://www.centrodedescargas.cnig.es/), accedido el 10-05-2025b). Centro de Descargas del CNIG (IGN).
- IGN (Recurso en línea [www.centrodedescargas.cnig.es/](http://www.centrodedescargas.cnig.es/), accedido el 21-07-2025a). Información Georreferenciada, Centro de Descargas del CNIG (IGN).
- IGN (Recurso en línea [www.centrodedescargas.cnig.es/](http://www.centrodedescargas.cnig.es/), accedido el 21-07-2025a). Modelo digital del terrero, Centro de Descargas del CNIG (IGN).
- IGN (Recurso en línea [www.ign.es/](http://www.ign.es/), accedido el 21-07-2025a). Aspectos técnicos del proyecto - Plan Nacional de Ortofotografía Aérea.
- IGN (Recurso en línea [www.ign.es/](http://www.ign.es/), accedido el 21-07-2025b). Plan Nacional de observación del territorio - Instituto Geográfico Nacional.
- IGN (Recurso en línea [www.pnoa.ign.es/](http://www.pnoa.ign.es/), accedido el 10-05-2025). Mapa LiDAR - Plan Nacional de Ortofotografía Aérea.
- IGN (Recurso en línea [www.pnoa.ign.es/](http://www.pnoa.ign.es/), accedido el 21-07-2025b). Inicio - Plan Nacional de Ortofotografía Aérea.
- Instituto de Estadística y Cartografía de Andalucía (Recurso en línea [www.juntadeandalucia.es/institutodeestadisticaycartografia/](http://www.juntadeandalucia.es/institutodeestadisticaycartografia/), accedido el 17-08-2025). Didáctica. Material didáctico y educativo — Instituto de Estadística y Cartografía de Andalucía.

- Jacob Schreiber (Recurso en línea [/www.pomegranate.readthedocs.io/](http://www.pomegranate.readthedocs.io/), accedido el 21-07-2025). Home — pomegranate 1.0.0 documentation.
- Junta de Andalucía (Recurso en línea [/www.juntadeandalucia.es/](http://www.juntadeandalucia.es/), accedido el 21-07-2025). Estadísticas de climatología y meteorología en Andalucía - Portal Ambiental de Andalucía.
- Kim, H. (2005). *A First Course in Statistical Methods*, volume 47.
- Kogan, F. N. (1995). Application of vegetation index and brightness temperature for drought detection. *Advances in Space Research*, 15(11):91–100.
- Ministerio de Fomento (Recurso en línea [/www.siose.es/](http://www.siose.es/), accedido el 10-05-2025). Documentación SIOSE.
- O’Callaghan, J. F. and Mark, D. M. (1984). The extraction of drainage networks from digital elevation data. *Computer Vision, Graphics, and Image Processing*, 28(3):323–344.
- Rodríguez-Martínez, A. (2021). Modelización estocástica y generación de escenarios para gestión de desastres.
- Saaty, R. W. (1987). The analytic hierarchy process-what it is and how it is used. *Mathematical Modelling*, 9(3-5):161–176.
- Schreiber, J. (2018). pomegranate: Fast and flexible probabilistic modeling in python. *Journal of Machine Learning Research*, 18:1–6.
- USGS (Recurso en línea [/www.earthexplorer.usgs.gov/](http://www.earthexplorer.usgs.gov/), accedido el 21-07-2025a). EarthExplorer.
- USGS (Recurso en línea [/www.espa.cr.usgs.gov/](http://www.espa.cr.usgs.gov/), accedido el 21-07-2025b). ESPA - LSRD.
- Vallejo-Villalta, I., Rodríguez-Navas, E., and Márquez-Pérez, J. (2019). Mapping forest fire risk at a local scale—A case study in Andalusia (Spain). *Environments - MDPI*, 6(3).
- Vitoriano, B., Rodríguez, J. T., Tirado, G., Martín-Campo, F. J., Ortuño, M. T., and Montero, J. (2015). Intelligent Decision-Making Models for Disaster Management. *Human and Ecological Risk Assessment*, 21(5):1341–1360.
- WWF (Recurso en línea [/www.wwf.es/](http://www.wwf.es/), accedido el 08-07-2025). Bosques Los peores Incendios forestales en España — WWF España.

# Anexo I: Código de Python

## Código para clasificar la pendiente

```
1 def clasificar(valor):
2     if valor < 5:
3         return 1
4     elif valor < 10:
5         return 2
6     elif valor < 25:
7         return 3
8     elif valor < 35:
9         return 4
10    elif valor >= 35:
11        return 5
```

## Código para clasificar la orientación

```
1 def clasificar(valor):
2     if valor < 0:
3         return None
4     elif valor < 22.5 or valor >= 337.5:
5         return 1 #Norte
6     elif valor < 67.5:
```

```

7         return 2  #Noreste
8     elif valor < 112.5:
9         return 3  #Este
10    elif valor < 157.5:
11        return 4  #Sureste
12    elif valor < 202.5:
13        return 5  #Sur
14    elif valor < 247.5:
15        return 4  #Suroeste
16    elif valor < 292.5:
17        return 3  #Oeste
18    elif valor < 337.5:
19        return 2  #Noroeste

```

## Código para clasificar el VCI

```

1  def clasificar_vci(valor):
2      if valor < 20:
3          return 5
4      elif valor < 40:
5          return 4
6      elif valor < 60:
7          return 3
8      elif valor < 80:
9          return 2
10     else:  #valor entre 80 y 100
11         return 1

```

## Código para clasificar la distancia a las carreteras

```

1  def clasificar_vci(valor):
2      if valor < 50:

```

```
3         return 5
4     elif valor < 100:
5         return 4
6     elif valor < 200:
7         return 3
8     elif valor < 300:
9         return 2
10    else:
11        return 1
```

## Código para clasificar la distancia a las poblaciones

```
1 def clasificar_vci(valor):
2     if valor < 500:
3         return 5
4     elif valor < 1000:
5         return 4
6     elif valor < 2000:
7         return 3
8     elif valor < 3000:
9         return 2
10    else:
11        return 1
```

## Código para el cálculo de las probabilidades por escenario de viento

```
1 import numpy as np
2 import pandas as pd
3 import geopandas as gpd
4 import matplotlib.pyplot as plt
5
```

```

6 from copernicus_data import lambert_xy
7
8 shape_file_infoca_plus= '*/INFOCA_with_roads_info.shp'
9 csv_file_ir = "*/indice_riesgo.csv"
10 scn_prob_file = "*/GM_11_weights.npy"
11 means_file = "*/GM_11_means_transformed.npy"
12
13 def interp_func(distance):
14      $\alpha=1/10000$ 
15     return np.exp(- $\alpha$ *distance)
16
17 def winds_points(puntos,winds_scn):
18     pass
19     global lambert_xy
20     distance_matrix = np.sqrt(np.sum((lambert_xy[np.newaxis,::]-pu
21     ↪ ntos[:,np.newaxis,:])**2,axis=-1))
22     tr_distance_matrix = interp_func(distance_matrix)
23     B = tr_distance_matrix/np.sum(tr_distance_matrix,axis=1)[: ,np.n
24     ↪ ewaxis]
25     if len(winds_scn.shape)==3:
26         W = np.sum(winds_scn[:,np.newaxis,::]*B[np.newaxis,::,
27         ↪ ,np.newaxis],axis=-2)
28     else:
29         W = np.sum(winds_scn[np.newaxis,::,]*B[:,::,np.newaxis],
30         ↪ axis=-2)
31     return W
32
33 infoca = gpd.read_file(shape_file_infoca_plus)
34 df_ir = pd.read_csv(csv_file_ir, dtype=str)
35
36 print(df_ir)
37 if 'indice_riesgo' in df_ir.columns:
38     ir = df_ir['indice_riesgo'].values.astype(float)
39 else:
40     ir = df_ir.iloc[:,0].values.astype(float)
41
42 if len(ir) != infoca.shape[0]:
43     raise ValueError(f"El CSV tiene {len(ir)} filas pero el shapefile
44     ↪ tiene {infoca.shape[0]} polígonos.")
45
46 ir_norm = ir / ir.sum()

```

```

42 N = len(ir)
43 a = ir_norm
44 infoca['prob_ignicion'] = a
45 print("Probabilidades base calculadas desde índice de riesgo.")
46 print(a)
47
48 #mapa con las probabilidades de ignición
49 fig, ax = plt.subplots(1,1, figsize=(10,8))
50 infoca.plot(column="prob_ignicion", cmap="OrRd", legend=True, ax=ax,
51 ↪ edgecolor="black", linewidth=0.2)
52 ax.set_title("Mapa de Probabilidad Base de Ignición por Polígono",
53 ↪ fontsize=14)
54 plt.show()
55
56 centroides = np.array([poly.centroid.coords[0] for poly in
57 ↪ infoca.geometry])
58
59 scn_prob = np.load(scn_prob_file)           # probabilidad de cada escenario
60 means = np.load(means_file)                # vectores medios de viento
61 winds_at_centra = winds_points(centroides, means)
62 vel_at_centra = np.sqrt(winds_at_centra[... ,0]**2 +
63 ↪ winds_at_centra[... ,1]**2)
64
65 num_escenarios = scn_prob.shape[0]
66 ignitions = np.zeros((num_escenarios, N))
67
68 for k in range(num_escenarios):
69     ignitions[k] = a
70
71 # Ajuste según velocidad del viento
72 ignitions[vel_at_centra<5] = ignitions[vel_at_centra<5]**2
73 ignitions[np.logical_and(10<=vel_at_centra, vel_at_centra<15)] = \
74     (1-(1-ignitions[np.logical_and(10<=vel_at_centra,
75     ↪ vel_at_centra<15)])**2)
76 ignitions[15<=vel_at_centra] = (1-(1-ignitions[15<=vel_at_centra])**3)
77
78 ignitions = ignitions**1.1166
79 np.save('*/ignitions.npy', ignitions)
80 print("Archivo 'ignitions.npy' guardado con éxito.")
81

```

# Anexo II: Series temporales completas

## NDII Serie temporal completa




Figura 1: NDII de la zona de estudio en febrero del 2020. Fuente: elaboración propia a partir de las imágenes del Landsat 8 de la NASA




Figura 2: NDII de la zona de estudio en abril del 2020. Fuente: elaboración propia a partir de las imágenes del Landsat 8 de la NASA




Figura 3: NDII de la zona de estudio en agosto del 2020. Fuente: elaboración propia a partir de las imágenes del Landsat 8 de la NASA




Figura 4: NDII de la zona de estudio en noviembre del 2020. Fuente: elaboración propia a partir de las imágenes del Landsat 8 de la NASA




Figura 5: NDII de la zona de estudio en mayo del 2021. Fuente: elaboración propia a partir de las imágenes del Landsat 8 de la NASA




Figura 6: NDII de la zona de estudio en julio del 2021. Fuente: elaboración propia a partir de las imágenes del Landsat 8 de la NASA




Figura 7: NDII de la zona de estudio en octubre del 2021. Fuente: elaboración propia a partir de las imágenes del Landsat 8 de la NASA




Figura 8: NDII de la zona de estudio en noviembre del 2021. Fuente: elaboración propia a partir de las imágenes del Landsat 8 de la NASA




Figura 9: NDII de la zona de estudio en enero del 2022. Fuente: elaboración propia a partir de las imágenes del Landsat 8 de la NASA




Figura 10: NDII de la zona de estudio en junio del 2022. Fuente: elaboración propia a partir de las imágenes del Landsat 8 de la NASA




Figura 11: NDII de la zona de estudio en septiembre del 2022. Fuente: elaboración propia a partir de las imágenes del Landsat 8 de la NASA




Figura 12: NDII de la zona de estudio en octubre del 2022. Fuente: elaboración propia a partir de las imágenes del Landsat 8 de la NASA

## VCI Serie temporal completa




Figura 13: VCI de la zona de estudio en febrero del 2020. Fuente: elaboración propia a partir de las imágenes del Landsat 8 de la NASA




Figura 14: VCI de la zona de estudio en abril del 2020. Fuente: elaboración propia a partir de las imágenes del Landsat 8 de la NASA




Figura 15: VCI de la zona de estudio en agosto del 2020. Fuente: elaboración propia a partir de las imágenes del Landsat 8 de la NASA




Figura 16: VCI de la zona de estudio en noviembre del 2020. Fuente: elaboración propia a partir de las imágenes del Landsat 8 de la NASA




Figura 17: VCI de la zona de estudio en mayo del 2021. Fuente: elaboración propia a partir de las imágenes del Landsat 8 de la NASA




Figura 18: VCI de la zona de estudio en julio del 2021. Fuente: elaboración propia a partir de las imágenes del Landsat 8 de la NASA




Figura 19: VCI de la zona de estudio en octubre del 2021. Fuente: elaboración propia a partir de las imágenes del Landsat 8 de la NASA




Figura 20: VCI de la zona de estudio en noviembre del 2021. Fuente: elaboración propia a partir de las imágenes del Landsat 8 de la NASA




Figura 21: VCI de la zona de estudio en enero del 2022. Fuente: elaboración propia a partir de las imágenes del Landsat 8 de la NASA




Figura 22: VCI de la zona de estudio en junio del 2022. Fuente: elaboración propia a partir de las imágenes del Landsat 8 de la NASA




Figura 23: VCI de la zona de estudio en septiembre del 2022. Fuente: elaboración propia a partir de las imágenes del Landsat 8 de la NASA




Figura 24: VCI de la zona de estudio en octubre del 2022. Fuente: elaboración propia a partir de las imágenes del Landsat 8 de la NASA