

# **TRABAJO FIN DE MÁSTER**

## **ANÁLISIS MULTIESCALA DE LA CICATRIZ TÉRMICA POSFUEGO EN ECOSISTEMAS FORESTALES DE ARAGÓN, MEDIANTE SERIES TEMPORALES DE LANDSAT Y OBSERVACIONES UAV**

***Autor: Erick Sebastián Villacis Bustos***

***Director: Fernando Pérez Cabello***

**Máster Universitario en**

**Tecnologías de la información geográfica para la ordenación del territorio: sistemas de información geográfica y teledetección**

**Septiembre de 2025**



**Universidad  
Zaragoza**

**Departamento de Geografía  
y Ordenación del Territorio**



## Resumen

*Los incendios forestales dejan una "cicatriz térmica" duradera en el paisaje, alterando significativamente la Temperatura Superficial Terrestre (LST). Este Trabajo de fin de máster investiga la dinámica de esta cicatriz en los ecosistemas mediterráneos de Aragón, analizando cómo se recupera en el tiempo y qué factores controlan su persistencia. Para ello, se implementa un flujo de trabajo que, mediante un enfoque de controles pareados ("puntos gemelos"), permitió analizar las series temporales de imágenes Landsat para un extenso grupo de 95 incendios que datan de 1985 a 2019.*

*El estudio revela que la recuperación térmica sigue un patrón no lineal, con una rápida atenuación inicial seguida de una estabilización a largo plazo, fuertemente influenciada por los ciclos estacionales. A través de modelos estadísticos, se confirma que la persistencia de la cicatriz depende tanto de la magnitud del daño inicial (severidad) como de factores del paisaje como la elevación.*

Adicionalmente, se realizó una comparación multiescala entre los datos satelitales y mediciones de un vehículo no tripulado de muy alta resolución (3 cm). Los resultados demuestran un profundo desacoplamiento entre las escalas: el satélite captura una visión promediada y homogénea, mientras que el dron revela una heterogeneidad térmica extrema a microescala que es enmascarada desde el espacio. Se descubrió que las condiciones del paisaje previas al fuego son un mejor predictor de la micro-temperatura actual que la propia medición térmica del satélite, subrayando la existencia de una "memoria ecológica" que condiciona la respuesta del ecosistema décadas después de la perturbación.

**Palabras Clave:** cicatriz térmica, LST, teledetección, Landsat, incendios forestales, recuperación posfuego, multiescala, dron, ecología del paisaje.

## Abstract

*Forest fires leave a lasting "thermal scar" on the landscape, significantly altering the Land Surface Temperature (LST). This Master's thesis investigates the dynamics of this scar in the Mediterranean ecosystems of Aragon (Spain), analyzing how it recovers over time and which factors control its persistence. To this end, a workflow was implemented that, through a paired-control approach ("twin points"), allowed for the analysis of Landsat image time series for an extensive group of 95 wildfires dating from 1985 to 2019.*

*The study reveals that thermal recovery follows a non-linear pattern, with a rapid initial attenuation followed by long-term stabilization, strongly influenced by seasonal cycles. Through statistical models, it is confirmed that the scar's persistence depends on both the magnitude of the initial damage (severity) and landscape factors such as elevation.*

*Additionally, a multiscale comparison was conducted between satellite data and very high-resolution (3 cm) measurements from an unmanned aerial vehicle (UAV). The results demonstrate a profound decoupling between scales: the satellite captures an averaged, homogeneous view, whereas the UAV reveals extreme thermal heterogeneity at the microscale that is masked from space. It was discovered that pre-fire landscape conditions are a better predictor of current micro-temperature than the satellite's own thermal measurement, highlighting an "ecological memory" that shapes the ecosystem's response decades after the disturbance.*

**Key Words:** thermal scar, LST, remote sensing, Landsat, forest fires, post-fire recovery, multiscale, UAV, landscape ecology.

## Índice

1.	INTRODUCCIÓN .....	pág. 1
1.1.	Marco teórico y justificación .....	pág. 2
1.2.	Hipótesis .....	pág. 2
1.3.	Objetivos .....	pág. 2
2.	ÁREA DE ESTUDIO Y DATOS.....	pág. 2
2.1.	Descripción del área de estudio .....	pág. 2
2.2.	Datos de partida y selección de incendios .....	pág. 3
2.3.	Datos satelitales: Colecciones del programa Landsat .....	pág. 4
2.4.	Datos de alta resolución: orto mosaicos térmicos de dron .....	pág. 5
2.5.	Datos auxiliares .....	pág. 6
2.5.1.	Modelo Digital del Terreno (MDT) .....	pág. 6
2.5.2.	Datos de vegetación pre-incendio .....	pág. 6
3.	METODOLOGÍA .....	pág. 8
3.1.	Flujo de trabajo general.....	pág. 8
3.2.	Estrategia de muestreo y generación de puntos de control .....	pág. 9
3.2.1.	Generación de puntos de muestreo (escala satélite y dron) .....	pág. 9
3.2.2.	Metodología de emparejamiento de "puntos gemelos" .....	pág. 10
3.2.3.	Validación del emparejamiento .....	pág. 12
3.3.	Procesamiento de datos satelitales en <i>Google Earth Engine</i> .....	pág. 13
3.3.1.	Preprocesamiento de imágenes Landsat .....	pág. 13
3.3.2.	Creación de <i>composites</i> y series temporales (diaria, mensual, anual).....	pág. 13
3.4.	Procesamiento y depuración de series temporales.....	pág. 14
3.4.1.	Cálculo de las variables de diferencias.....	pág. 14
3.4.2.	Tratamiento de valores atípicos .....	pág. 14
3.5.	Análisis estadístico .....	pág. 15
3.5.1.	Análisis exploratorio de datos.....	pág. 15
3.5.2.	Modelado de la normalización térmica: Modelos Lineales Mixtos (LMM) .....	pág. 15
3.5.3.	Ánálsis comparativo multiescala .....	pág. 15
3.5.4.	Discretización de variables para análisis exploratorio .....	pág. 16
4.	RESULTADOS .....	pág. 16
4.1.	Validación del emparejamiento de puntos .....	pág. 16
4.2.	Auditoría del procesamiento de datos .....	pág. 18
4.3.	Ánálsis exploratorio de la dinámica de la Diferencia de LST .....	pág. 19
4.3.1.	Relación entre la anomalía térmica y la recuperación de la vegetación.....	pág. 19
4.3.2.	Patrón general y estacionalidad de la estabilización térmica.....	pág. 20
4.3.3.	Influencia de los factores de control en la estabilización térmica.....	pág. 23
4.3.4.	Heterogeneidad en las trayectorias de recuperación: Casos de estudio .....	pág. 25
4.4.	Modelado de la normalización térmica .....	pág. 26
4.4.1.	Resultados del modelo mensual.....	pág. 27
4.4.2.	Resultados del modelo anual.....	pág. 27
4.4.3.	Resultados del modelo diario.....	pág. 28
4.4.4.	Interpretación de los efectos del modelo .....	pág. 29

4.5. Análisis multiescala: comparación de la anomalía térmica Dron vs. Satélite.....	pág. 29
4.5.1. Distribución y variabilidad de las diferencias de temperatura.....	pág. 29
4.5.2. Relación lineal entre las mediciones de ambos sensores ...	pág. 31
4.5.3. Modelado predictivo de la anomalía térmica a microescala.....	pág. 32
5. DISCUSIÓN .....	pág. 33
5.1. Dinámica temporal de la cicatriz térmica.....	pág. 33
5.2. Recuperación de la vegetación como actor principal de la recuperación térmica .....	pág. 33
5.3. Heterogeneidad entre incendios: la importancia de los factores locales .....	pág. 34
5.4. Efecto de la escala de observación: implicaciones del análisis dron vs. satélite.....	pág. 34
5.5. Fortalezas y limitaciones del estudio.....	pág. 35
5.6. Futuras líneas de investigación .....	pág. 35
6. CONCLUSIONES.....	pág. 36
7. GLOSARIO DE TÉRMINOS Y ACRÓNIMOS .....	pág. 37
BIBLIOGRAFIA .....	pág. 38
ANEXOS .....	pág. 40

## 1. INTRODUCCIÓN

### 1.1. Marco teórico y justificación.

Los incendios forestales constituyen una de las perturbaciones más importantes que afectan a los ecosistemas a nivel global. Estos eventos no solo alteran la estructura y la biodiversidad de los bosques, sino que también ejercen un profundo impacto en el ciclo global del carbono y, en consecuencia, en el cambio climático (Kurbanov et al., 2022; Li et al., 2023). La problemática de los incendios es especialmente significativa en ecosistemas como el Mediterráneo, donde la recurrencia e intensidad de los fuegos no son considerados un simple desastre, sino que modelan el paisaje y la dinámica ecológica a lo largo de milenarios (Vlassova et al., 2014). En este contexto, evaluar la magnitud de los daños (severidad del fuego) y monitorizar la posterior recuperación de la vegetación son tareas fundamentales. Estas evaluaciones son cruciales para comprender el impacto ecológico de las perturbaciones y para diseñar estrategias de gestión y restauración efectivas tras el paso del fuego (Quintano et al., 2019).

Un parámetro biofísico clave que puede ser medido desde el espacio para llevar a cabo esta monitorización es la Temperatura de la Superficie Terrestre (LST, por sus siglas en inglés). La LST es un indicador fundamental de los procesos de intercambio de energía y agua en la interfaz superficie-atmósfera y juega un papel crucial en el estudio del clima a escala local y global (Li et al., 2013). Tras un incendio, la eliminación de la cubierta vegetal altera drásticamente el balance energético de la superficie. Por un lado, disminuye el enfriamiento latente asociado a la evapotranspiración; por otro, el oscurecimiento del suelo por la presencia de cenizas y carbón puede reducir su albedo, aumentando la absorción de radiación solar. Ambos factores provocan un incremento significativo y persistente de la LST en las zonas quemadas (Vlassova et al., 2014; Ezzaher et al., 2024). Este fenómeno, conocido como "cicatriz térmica", convierte a la LST en un efectivo indicador para evaluar tanto la severidad del fuego como el estado de la recuperación del ecosistema post-incendio. Sin embargo, su correcta estimación desde satélite es un desafío, ya que requiere de complejas correcciones atmosféricas y un conocimiento preciso de la emisividad de la superficie (Li et al., 2023).

En las últimas décadas, la teledetección se ha consolidado como una herramienta indispensable para el estudio de estas dinámicas. Su capacidad para proporcionar una visión sinóptica, multitemporal y rentable de grandes extensiones de terreno la convierte en una alternativa de gran valor frente a los costosos y espacialmente limitados trabajos de campo (Kurbanov et al., 2022; Morante-Carballo et al., 2022). La disponibilidad de archivos históricos de imágenes satelitales, como el proporcionado por la serie de satélites Landsat, ha permitido generar series temporales de datos cruciales para analizar no solo los efectos inmediatos del fuego, sino también los patrones de recuperación a largo plazo. El análisis de estas grandes cantidades de datos se ha visto, a su vez, revolucionado por la llegada de plataformas de procesamiento como *Google Earth Engine* (GEE). Estas plataformas han permitido el acceso y el análisis de archivos de datos geoespaciales a escala planetaria, facilitando la ejecución de estudios complejos sobre la dinámica post-incendio que antes eran computacionalmente inaccesibles (Koutsias et al., 2023).

En este marco, el presente Trabajo de Fin de Máster explora la dinámica de la cicatriz térmica en los ecosistemas mediterráneos de Aragón. Aprovechando las herramientas mencionadas, se ha desarrollado un flujo de trabajo para analizar un grupo extenso de 95 incendios (1984-2019), lo que permite caracterizar las trayectorias de normalización de la LST y explorar la heterogeneidad de las respuestas en un conjunto de datos más amplio que un estudio de caso único. De forma simultánea, el trabajo aborda una reflexión metodológica sobre la influencia de la escala de observación, para lo cual incorpora un componente multiescala que contrasta las mediciones satelitales a escala métrica, con datos de alta resolución centimétrica obtenidos por dron, para un subconjunto de los incendios analizados.

## **1.2. Hipótesis.**

A partir del marco teórico expuesto, la presente investigación se guía por una serie de hipótesis fundamentales sobre la dinámica de la cicatriz térmica posfuego. En primer lugar, partiendo de la conocida interacción entre la vegetación y el balance energético, se postula que la anomalía térmica entre las zonas quemadas y las de control no es un fenómeno estático. Se espera que esta Diferencia de Temperatura Superficial Terrestre muestre una clara tendencia de recuperación a lo largo del tiempo, y que esta normalización térmica esté fuertemente acoplada a la progresiva regeneración de la cubierta vegetal, actuando esta última como el principal motor del enfriamiento de la superficie.

Sin embargo, dado que los incendios ocurren en paisajes heterogéneos, se hipotetiza que esta trayectoria de recuperación no será uniforme en todos los casos. Se prevé que la magnitud de la anomalía térmica y la velocidad de su recuperación estén significativamente influenciadas por las características morfo-estructurales y biofísicas de cada sitio, así como por la severidad del fuego.

Finalmente, se aborda la cuestión metodológica de la escala. Se plantean dos hipótesis interrelacionadas sobre el efecto de la escala espacial de observación. Primero, se hipotetiza que las mediciones de alta resolución (dron, 3 cm), al capturar la heterogeneidad a microescala, presentarán una variabilidad estadística significativamente mayor que las mediciones de resolución media (satélite, 30 m), las cuales promedian dicha variabilidad. Segundo, y como consecuencia de lo anterior, se postula que existirá un profundo desacoplamiento predictivo entre ambas escalas, de tal forma que la medición de LST del satélite no será un predictor significativo de la LST a nivel de punto, anticipando una considerable pérdida de información al pasar de una escala métrica a una fina.

## **1.3. Objetivos.**

En consonancia con el marco de investigación y las hipótesis planteadas, los objetivos principales de este Trabajo de Fin de Máster son los siguientes:

- Desarrollar y documentar un flujo de trabajo metodológico en R, diseñado para el análisis replicable y escalable de múltiples áreas de estudio, que implementa un algoritmo flexible de emparejamiento para la generación de zonas de control basadas en cualquier conjunto de variables geoespaciales.
- Caracterizar la dinámica temporal de la anomalía térmica post-incendio en un grupo extenso de incendios forestales en Aragón, analizando su evolución a escalas diaria, mensual y anual y su relación con la recuperación de la vegetación.
- Evaluar la influencia de factores biofísicos, morfo-topográficos y relacionados con la severidad del fuego en la heterogeneidad de las trayectorias de normalización térmica, mediante la aplicación de modelos estadísticos de efectos mixtos.
- Realizar un análisis comparativo multiescala de la *Diferencia de Temperatura Superficial Terrestre*, contrastando las mediciones obtenidas a partir de datos satelitales de resolución media (Landsat, 30 m) con las obtenidas mediante datos de alta resolución centimétrica (dron, 3 cm) para cuantificar el efecto de la escala de observación.

## **2. ÁREA DE ESTUDIO Y DATOS**

### **2.1. Descripción del área de estudio.**

El área de estudio para esta investigación comprende la totalidad de la Comunidad Autónoma de Aragón, situada en el noreste de España, con una superficie de 47,720 km<sup>2</sup>. Orográficamente, el territorio aragonés se encuentra estructurado por tres grandes unidades. Al norte, se origina las sierras y depresiones pirenaicas, que alcanzan altitudes superiores a los 3,000 metros y alberga ecosistemas de alta y media montaña. En el extremo sur y oeste se desarrolla el Sistema Ibérico, una cordillera de altitudes más moderadas, pero de gran complejidad topográfica. Entre ambas formaciones montañosas se extiende la Depresión del Valle del Ebro, una extensa cuenca sedimentaria de baja altitud que constituye el eje central de la región. Esta diversidad de relieves genera un gradiente altitudinal y topográfico muy marcado, que influye directamente en los patrones climáticos y en la distribución de la vegetación.

Desde el punto de vista climático, aunque predomina el clima Mediterráneo continentalizado, caracterizado por una fuerte aridez estival, inviernos fríos y una notable amplitud térmica anual, que introducen importantes variaciones locales. Se encuentran desde climas de alta montaña en los Pirineos, con abundantes precipitaciones, hasta condiciones de semiaridez del Valle del Ebro y climas mediterráneos continentalizados de montaña media.

Esta matriz físico-geográfica sustenta una diversidad de formaciones vegetales. Las masas forestales están dominadas por diversas especies de coníferas, principalmente pinares de *Pinus halepensis*, *Pinus nigra* y *Pinus sylvestris*, adaptados a diferentes condiciones de altitud y suelo. Junto a ellas, se desarrollan bosques de quercíneas como encinares (*Quercus ilex*) y quejigares (*Quercus faginea*), además de extensas áreas de matorral y maquia mediterránea, cuya distribución se detalla en el Mapa Forestal de España (Ministerio de Agricultura, Pesca y Alimentación, 2017). La combinación de estas condiciones climáticas y la abundancia de vegetación propensa al fuego hacen de Aragón un escenario recurrente de incendios forestales, lo que lo convierte en un área idónea para el análisis regional de sus cicatrices térmicas (Figura 1).



**Figura 1.** Localización de Aragón en el contexto del estado español.

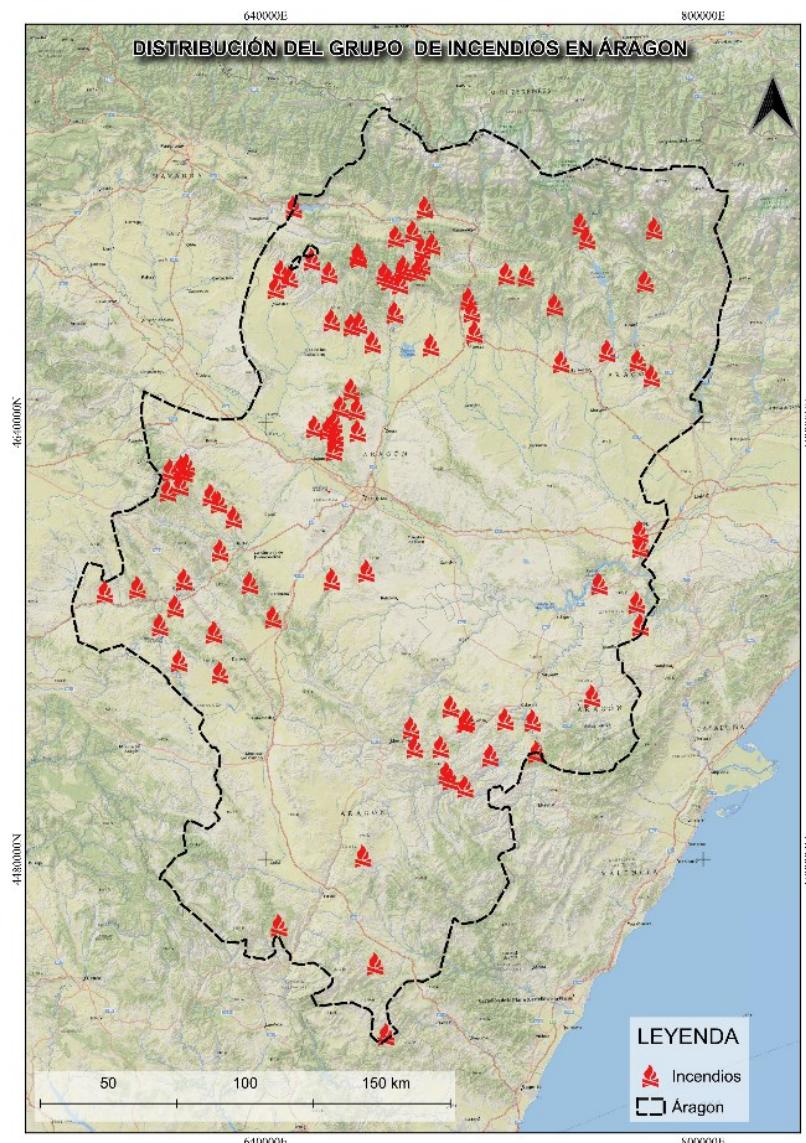
## 2.2. Datos de partida y selección de incendios.

La base conceptual, metodológica y cartográfica de esta investigación se incluye en el proyecto titulado: “Análisis dinámico de la resiliencia de los paisajes forestales afectados por el fuego mediante indicadores espectrales multisensor (PaF)” (Proyectos de I+D+i Retos Investigación; PID2020-118886RB-I00), centrado en el estudio histórico de los incendios forestales en Aragón. Este conjunto de datos original consta de una capa de información geográfica en formato vectorial que contiene los perímetros de 159 incendios ocurridos en la región desde el año 1967. Cada polígono cuenta con atributos fundamentales para el análisis, incluyendo un identificador único para cada evento de fuego (IDPAF) y la fecha exacta de su ocurrencia.

A partir de esta base de datos, se aplicó un proceso de filtrado para conformar el grupo de incendios final para el estudio. En una primera etapa, se descartaron todos los incendios anteriores al año 1984, fecha de inicio de operaciones del satélite Landsat 4, ya que no se dispone de datos de Temperatura Superficial Terrestre (LST) fiables para fechas previas. Este filtro redujo el número de incendios candidatos a 124.

En una segunda etapa, la selección final se condicionó a la disponibilidad de datos cartográficos de las condiciones de la vegetación pre-incendio. Para este fin, se utilizó el Índice Normalizado de Quemadura (NBR) del periodo previo a cada fuego, un producto derivado y facilitado por el mismo proyecto de investigación. Tras verificar la disponibilidad de esta capa PRE-NBR para cada uno de los 124 incendios candidatos, el número de eventos que contaban con todos los datos necesarios para el estudio

se estableció finalmente en 95. Este grupo final, cuya distribución geográfica se muestra en la Figura 2, constituye el universo de estudio sobre el cual se han desarrollado todos los análisis posteriores.



**Figura 2.** Distribución espacial de los incendios forestales incluidos en el análisis.

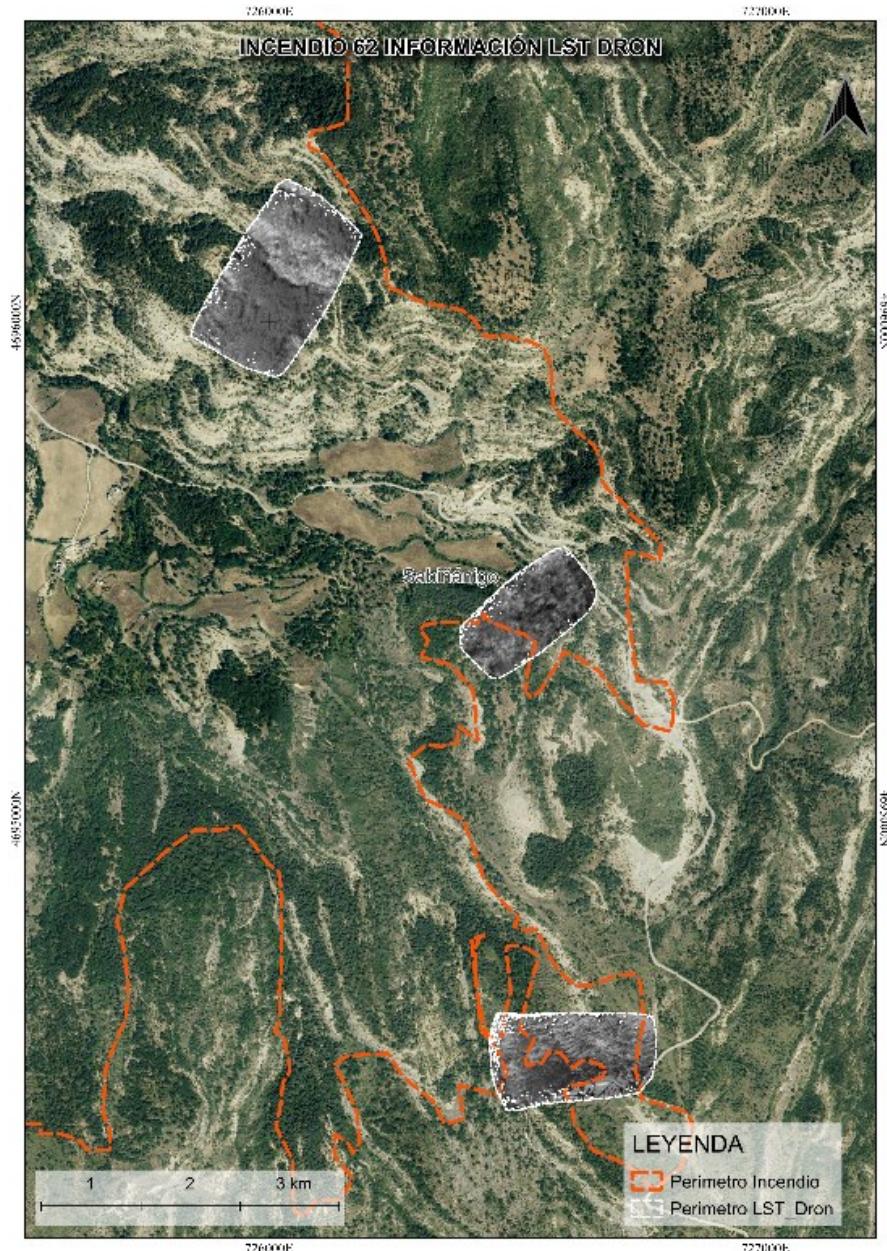
### 2.3. Datos satelitales: Colecciones del programa Landsat.

El principal conjunto de datos para el análisis de series temporales se obtuvo del archivo del programa Landsat, gestionado por el Servicio Geológico de los Estados Unidos (USGS). Se utilizaron las colecciones de Nivel 2, que proporcionan datos de Reflectancia de Superficie (SR) y Temperatura de Superficie (ST) ya corregidos desde el punto de vista radiométricos y atmosférico. Para cubrir el extenso periodo de análisis, se emplearon de forma combinada los datos de los sensores *Thematic Mapper* (TM) a bordo de Landsat 5, *Enhanced Thematic Mapper Plus* (ETM+) de Landsat 7, y *Operational Land Imager* (OLI) y *Thermal Infrared Sensor* (TIRS) de Landsat 8 y 9. Todos los datos ópticos presentan una resolución espacial de 30 metros.

### 2.4. Datos de alta resolución: orto mosaicos térmicos de dron.

Para el análisis comparativo a escala detalle, se utilizó un conjunto de datos de alta resolución para un subconjunto de 12 eventos representativos de los incendios estudiados. Estos datos, proporcionados por el proyecto, consisten en ortomosaicos de Temperatura Superficial Terrestre generados a partir de vuelos de vehículos aéreos no tripulados (dron) equipados con sensores térmicos, ofreciendo un nivel de detalle que permite el análisis de la heterogeneidad térmica a microescala espacial.

Específicamente, se empleó un Parrot Anafi Thermal, un dron multirrotor equipado con cámaras TIR y RGB que operan de forma conjunta. La estimación de la LST se realizó con el sensor térmico, un radiómetro FLIR Lepton 3.5 con una resolución de  $160 \times 120$  píxeles que opera en la región del infrarrojo térmico (TIR), entre 8 y 14  $\mu\text{m}$ . Para la adquisición de datos, el UAV voló a una altitud aproximada de 80 metros sobre el terreno, con un ángulo de incidencia nadiral ( $90^\circ$ ). Esta configuración de vuelo permitió obtener datos de LST con una resolución espacial final de 3 cm/px. El procesamiento de los datos brutos TIR para generar los ortomosaicos térmicos se llevó a cabo mediante el software PIX4Dmapper. La Figura 3 muestra un ejemplo de la cobertura de estos datos para uno de los incendios analizados.



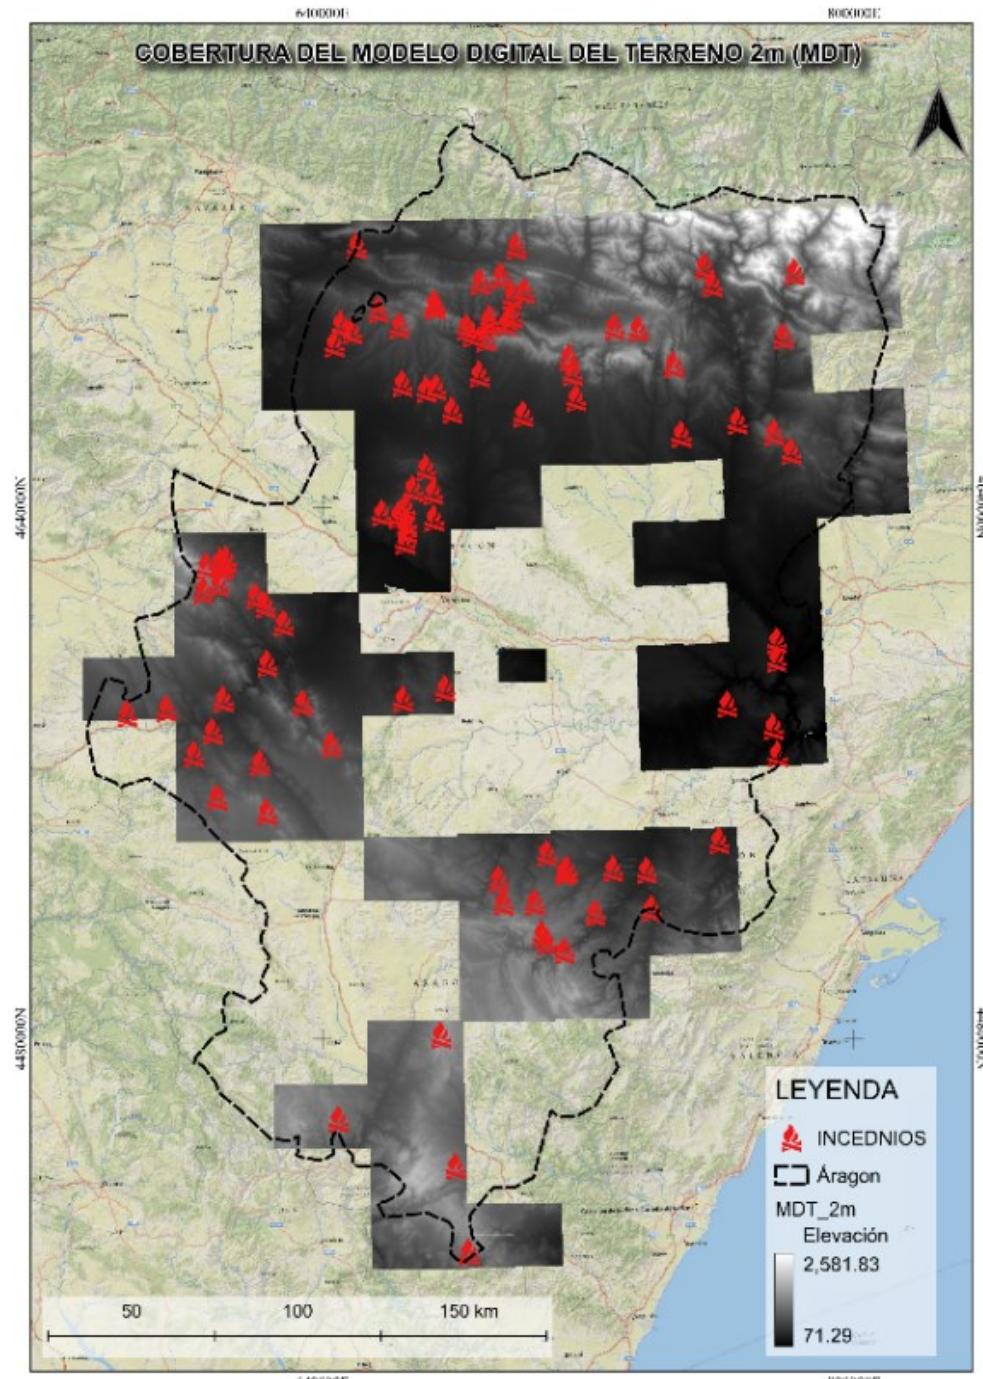
**Figura 3.** Localización de los *footprints* (perímetros en blanco) correspondientes a los vuelos UAV adquiridos en el incendio de Lasosa 1986 (Municipios de Sabiñanigo y Nueno –Prepirineo oscense) (línea roja intermitente).

## 2.5. Datos auxiliares.

Para el desarrollo de la metodología, se emplearon dos conjuntos de datos auxiliares fundamentales que sirvieron como variables de control en el proceso de emparejamiento de puntos.

### 2.5.1. Modelo Digital del Terreno (MDT).

Se utilizó una colección de 272 Modelos Digitales del Terreno (MDT) de alta resolución, con un tamaño de píxel de 2 metros. Este producto, derivado de datos LiDAR y distribuido por el Centro Nacional de Información Geográfica (CNIG) disponible en <https://centrodedescargas.cnig.es>, fue la base para la extracción de las variables topográficas claves utilizadas en el análisis: la elevación, la pendiente, la exposición general, el Índice de Posición Topográfica (TPI) y el Índice de Rugosidad del Terreno (TRI). La siguiente Figura 4 muestra la extensión del MDT en el estudio.

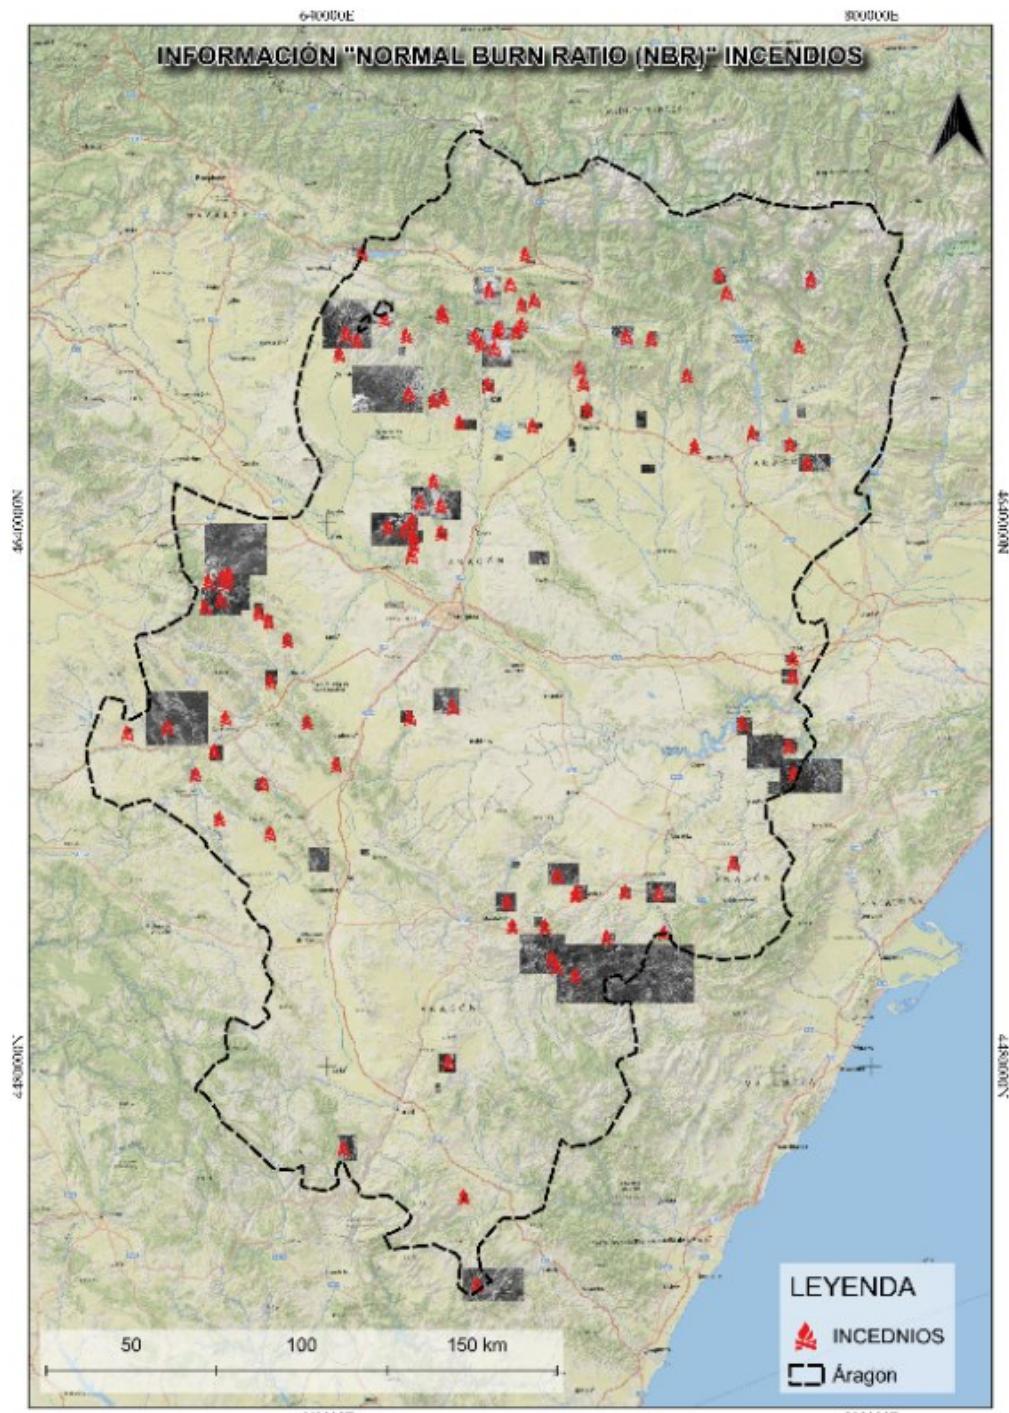


**Figura 4.** Distribución espacial de los ficheros del Modelo Digital del Terreno –MDT02- correspondientes a las zonas quemadas analizadas.

### 2.5.2. Datos de vegetación pre-incendio.

Para controlar el efecto de la condición de la vegetación antes del fuego, se utilizó como variable proxy el *Índice Normalizado de Quemadura* o área quemada (NBR) (Key and Benson, 1999), del periodo inmediatamente anterior al incendio. Estas capas, con una resolución de 30 metros, fueron gene-

radas y proporcionadas por el proyecto PaF, y resultaron cruciales para asegurar la similitud en las condiciones espetrales de la vegetación entre los puntos de incendio y sus correspondientes controles. La siguiente Figura 5 se muestra la extensión de los ráster con respecto a los incendios. Por cuestiones de escala y dimensionalidad estos no se pueden representar por completo en el mapa, pero esta información cubre en su totalidad las áreas del grupo de incendios para el estudio.



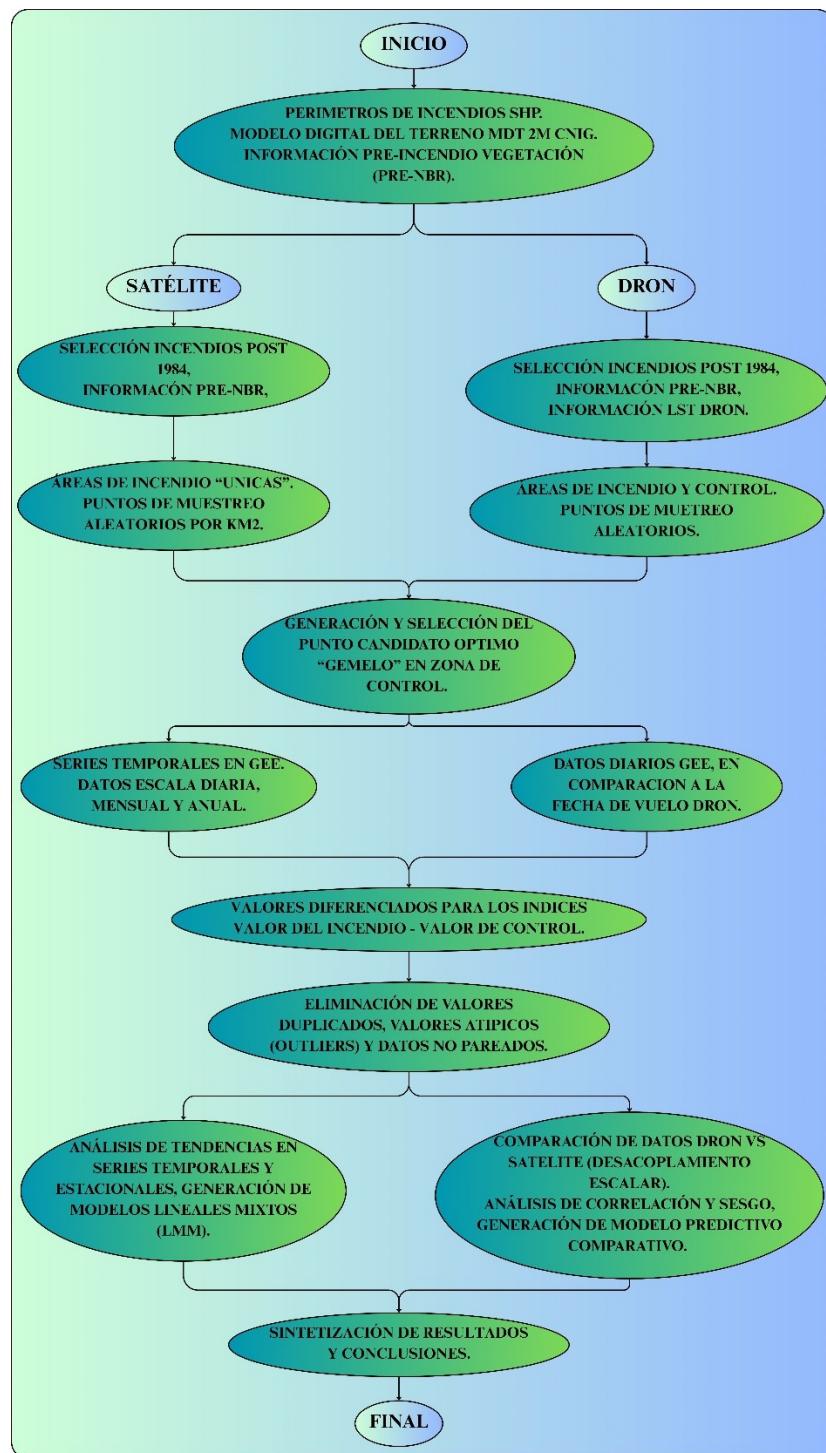
**Figura 5.** Distribución espacial de los ficheros del *Índice Normalizado de Quemadura* previo al evento – PRE-NBR- correspondientes a las zonas quemadas analizadas.

### 3. METODOLOGÍA

#### 3.1. Flujo de trabajo general.

La metodología empleada en este estudio se estructuró en un flujo de trabajo secuencial y replicable, diseñado para procesar y analizar los datos de teledetección a múltiples escalas. El proceso, implementado mayoritariamente en el entorno de programación R y en la plataforma *Google Earth Engine*, puede

dividirse en cuatro grandes fases: (1) Diseño y Validación, donde se generaron los puntos de muestreo y se validó el método de emparejamiento; (2) Extracción de Series Temporales, donde se obtuvieron los datos satelitales para cada punto; (3) Procesamiento y Limpieza de Datos, donde se calcularon las variables de diferencia y se depuraron los datos; y (4) Análisis Estadístico y Comparativo, donde se ajustaron los modelos y se contrastaron los resultados entre escalas. En la Figura 6 se presenta un diagrama de flujo que resume las etapas principales de la metodología.



**Figura 6.** Diagrama de flujo metodológico aplicado a la generación del trabajo (resumido).

### 3.2. Estrategia de muestreo y generación de puntos de control.

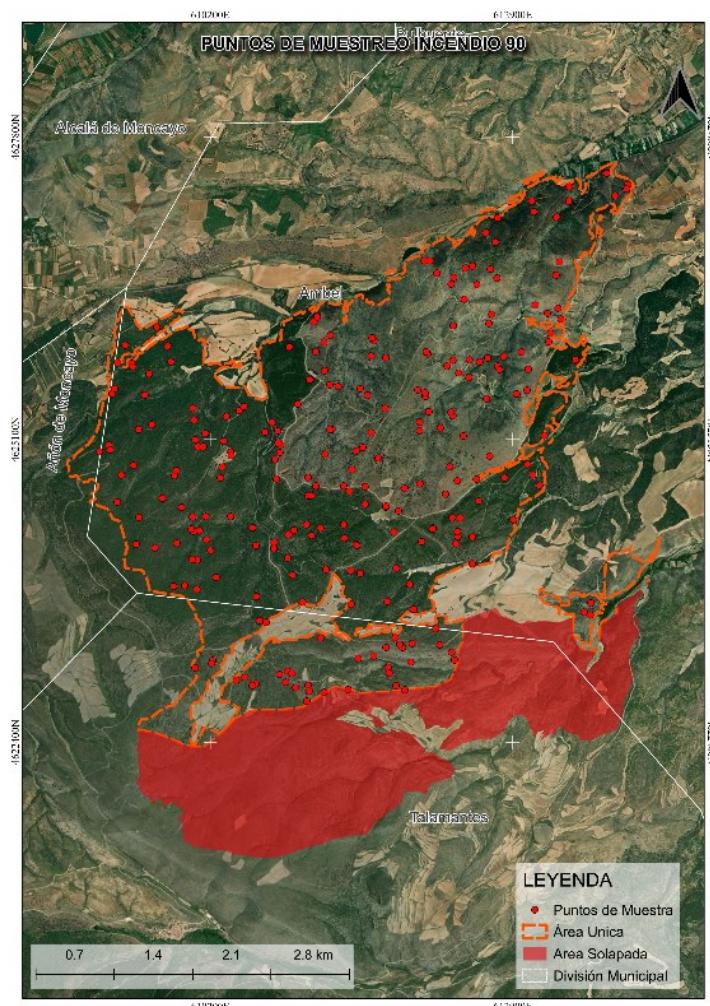
La validez del estudio se fundamenta en una estrategia de muestras y controles pareados, diseñada para aislar el efecto neto de los incendios de otras fuentes de variabilidad ambiental. El principio metodológico consistió en comparar, a lo largo del tiempo, las mediciones de LST de puntos de muestreo

localizados dentro de áreas quemadas (muestras) con las de "puntos gemelos" análogos situados en zonas adyacentes no afectadas (controles). Para implementar este diseño, se desarrolló un flujo de trabajo en R que abarcó dos procesos principales: primero, la generación de los puntos de muestreo base para cada escala de análisis (satélite y dron); y segundo, la posterior búsqueda de su correspondiente punto de control, como se detallará en el apartado 3.2.2.

### 3.2.1. Generación de puntos de muestreo (escala satélite y dron).

El proceso para crear la población de puntos de muestreo iniciales se lo implementó con un algoritmo en R y se adaptó a las características y objetivos de cada escala de análisis.

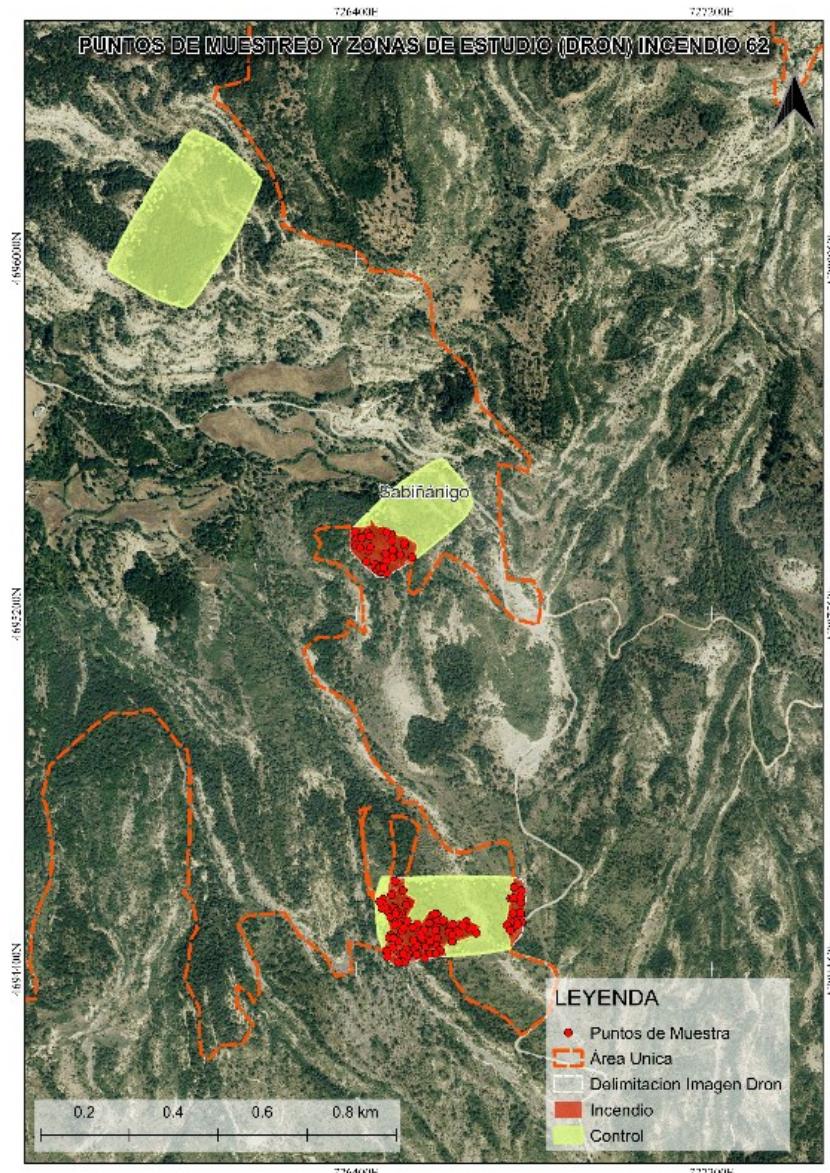
Para el análisis a escala de satélite, el objetivo era evaluar la estabilización a largo plazo. Por ello, fue crucial asegurar que las áreas de estudio no estuvieran contaminadas por perturbaciones posteriores. Partiendo de la cartografía de 95 perímetros de incendio y sus respectivas fechas de ocurrencia, se ejecutó un proceso de análisis espacial iterativo. Para cada incendio, el script (Anexo 1) identificó y excluyó cualquier porción de su área que se hubiera solapado con un incendio posterior. El resultado de este filtrado fue un conjunto de polígonos de "área de quema única", garantizando que la recuperación observada en ellos correspondiera exclusivamente al evento de fuego original. Sobre estas áreas únicas validadas, se generó una muestra de puntos aleatorios con una densidad de 20 puntos por km<sup>2</sup>. La siguiente Figura 7 muestra un ejemplo de "Área única" y los puntos de muestra.



**Figura 7.** Generación de las áreas únicas y puntos de muestra, ejemplo del incendio código IDPAF: 90 (Ambel, Zaragoza).

Para el análisis a escala de dron, el objetivo era caracterizar la anomalía térmica a muy alta resolución (Anexo 2). El punto de partida fueron los 12 ortomosaicos térmicos georreferenciados. Se implementó un procedimiento para crear una "huella de datos válidos" para cada ortomosaico. Este proceso convirtió el ráster térmico en un polígono vectorial, excluyendo automáticamente las celdas sin datos

(valores NoData), que se manifiestan como huecos o bordes irregulares en el área de cobertura. Este polígono de datos válidos fue posteriormente segmentado en zonas de "Incendio" y "Control" mediante su intersección con los perímetros oficiales. Finalmente, se generó una muestra de 150 puntos aleatorios dentro de cada una de las zonas de "Incendio", con la certeza de que todos los puntos se localizaban en áreas con mediciones térmicas válidas (Figura 8).



**Figura 8.** Generación de las áreas “Incendio”, “Control” y puntos de muestra, ejemplo del incendio código IDPAF: 62 (Lasosa, Huesca).

### 3.2.2. Metodología de emparejamiento de "puntos gemelos".

Para cada punto de muestreo generado, se implementó un algoritmo en R con el objetivo de encontrar su "punto gemelo" o control ambientalmente análogo. Este proceso es crucial para aislar el efecto del fuego de la variabilidad intrínseca del paisaje (Barbet-Massin et al., 2012). Al asegurar que cada punto de incendio tenga su análogo en una zona no quemada, se neutralizan las variables de confusión, permitiendo que las diferencias observadas puedan ser atribuidas con mayor confianza al impacto de la perturbación (VanDerWal et al., 2009).

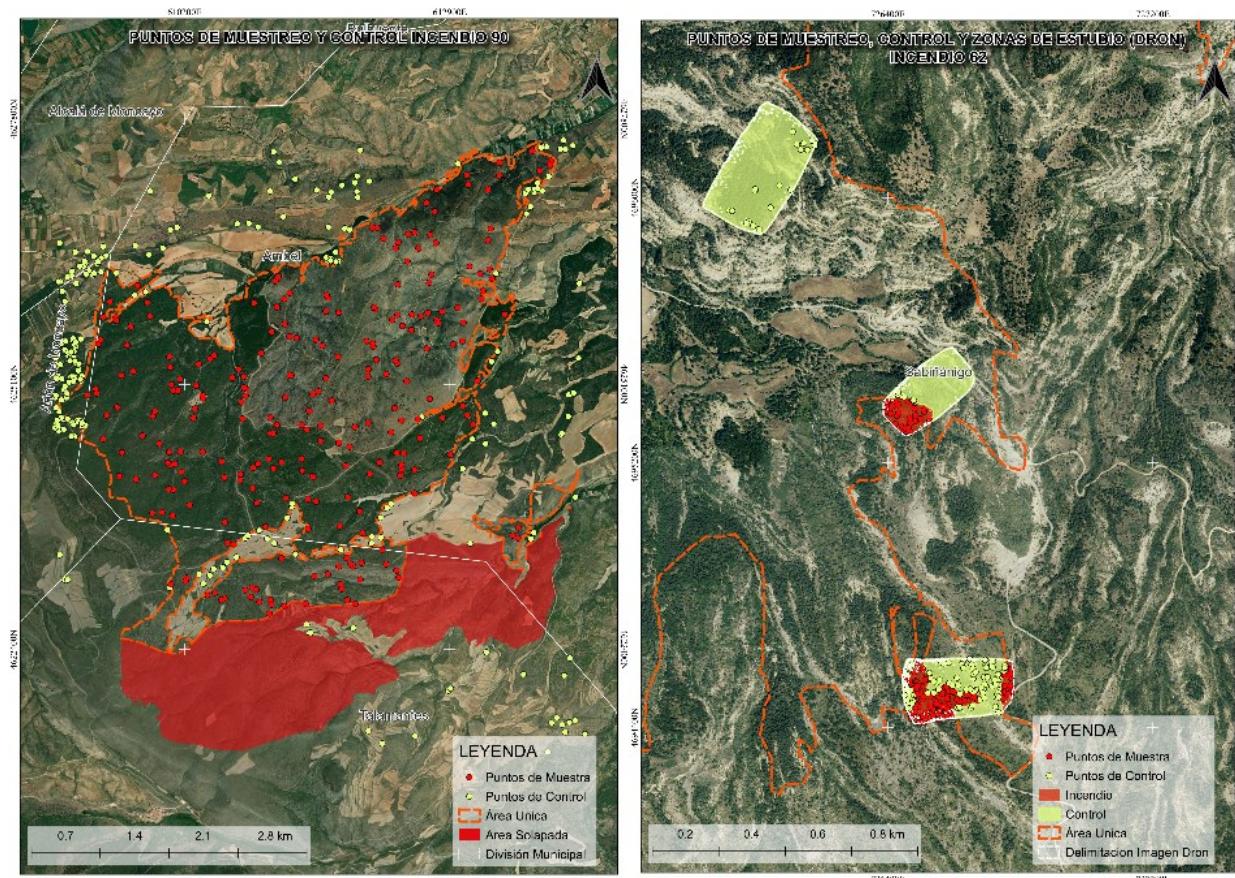
El paso fundamental de este proceso fue la construcción de un perfil ambiental para cada punto de incendio, seleccionando un conjunto de descriptores que, en conjunto, modelan los procesos biofísicos primarios que gobiernan el régimen térmico de la superficie. La base de este análisis fue el MDT de 2 metros de resolución, a partir del cual se derivaron las siguientes variables topográficas:

- Elevación: Extraída directamente del MDT. Es un factor de primer orden que modula la temperatura a través del gradiente adiabático atmosférico, donde a mayor altitud, la temperatura tiende a ser menor (Li et al., 2013). Se estableció una tolerancia de emparejamiento de  $\pm 20$  metros.
- Pendiente (Slope): Calculada en grados. Determina el ángulo de incidencia de la radiación solar. Pendientes más pronunciadas y orientadas hacia el sol reciben una mayor irradiancia, lo que puede resultar en una LST más elevada. Además, influye en procesos hidrológicos que afectan indirectamente a la LST a través de la humedad del suelo (Vlassova et al., 2014). Se fijó una tolerancia de  $\pm 10$  grados.
- Exposición General (Iluminación Multidireccional): Para superar el sesgo de un índice de iluminación unidireccional (que depende de una fuente de luz arbitraria), se implementó un indicador de exposición general más robusto. El cálculo de este índice se realizó en cuatro pasos: primero, se generaron cuatro capas de iluminación (hillshade) individuales desde las cuatro direcciones cardinales intermedias (Noroeste  $315^\circ$ , Noreste  $45^\circ$ , Sureste  $135^\circ$  y Suroeste  $225^\circ$ ). Segundo, cada una de estas capas se normalizó de forma independiente a un rango de 0 a 1 para asegurar que ninguna dirección dominara el resultado final. Tercero, las cuatro capas normalizadas se promediaron, resultando en un único índice que representa el grado de protección o apertura topográfica de un punto. Finalmente, se impuso una tolerancia estricta de  $\pm 0.05$  sobre este índice compuesto (en su escala de 0 a 1), garantizando un balance energético y una exposición al viento prácticamente idénticos entre los puntos emparejados.
- Índice de Posición Topográfica (TPI): Calculado como la diferencia entre la elevación de cada celda y la media de su vecindad (en este caso, una ventana de  $3 \times 3$  celdas). Este índice cuantifica la posición relativa de un punto en el paisaje (cresta, valle o ladera), lo cual es vital para capturar procesos microclimáticos clave, como el drenaje de aire frío o la acumulación de humedad en los valles, ambos con un fuerte impacto sobre la LST (Weiss, 2001). Se estableció una tolerancia de  $\pm 1.0$  metros sobre el valor de este índice.
- Índice de Rugosidad del Terreno (TRI): Calculado como la raíz cuadrada de la suma de los cuadrados de las diferencias de elevación entre una celda central y sus ocho vecinas. El TRI mide la heterogeneidad y complejidad del terreno. Un terreno muy rugoso (TRI alto) presenta una mayor variabilidad de microclimas, con más zonas de auto-sombreado que pueden moderar las temperaturas superficiales (Riley et al., 1999). Se fijó una tolerancia de  $\pm 0.5$  sobre el valor de este índice para asegurar que la complejidad microclimática de los puntos comparados fuera análoga.
- Índice Normalizado de Quemadura Pre-Incendio (PRE\_NBR): A diferencia de las variables topográficas estáticas, el NBR captura las características espectrales de la vegetación antes del evento. Actúa como un proxy directo de los procesos biológicos que regulan la LST, como el enfriamiento por evapotranspiración y la modificación del albedo superficial. Incluir esta variable es fundamental para asegurar que el estado fisiológico de la cobertura vegetal era equivalente entre los puntos de incendio y control antes de la perturbación. Se fijó una tolerancia rigurosa de  $\pm 0.1$  sobre este índice (cuyo rango teórico es de -1 a +1).

Una vez definidas estas variables de control, el algoritmo de emparejamiento procedió de la siguiente manera. Para cada punto de muestreo dentro de un incendio, el script generó primero una nube de puntos candidatos aleatorios en su correspondiente zona de búsqueda asignando un identificador único a cada punto (ID\_Punto). A continuación, cada punto candidato fue "enriquecido", extrayendo para su localización los valores de todas las variables de control descritas. Posteriormente, se aplicó un filtro estricto, descartando todos aquellos candidatos que no cumplían con las tolerancias absolutas predefinidas para cada una de las seis variables.

Del subconjunto de candidatos "cualificados" que superaron este filtro, se utilizó la distancia euclídea multidimensional como criterio de desempate final para seleccionar al "gemelo" óptimo. Para calcular esta distancia de forma robusta, primero se realizó una normalización Min-Max de todas las variables continuas. Es crucial destacar que esta normalización se aplicó sobre el conjunto global de datos, utilizando los valores mínimos y máximos de todos los puntos de muestreo y todos los puntos candidatos de todos los incendios combinados. Este procedimiento asegura que los valores se escalen a un rango adimensional (0 a 1) utilizando un estándar común, lo que permite una comparación equitativa

entre incendios que operan en rangos de valores distintos (ej. un incendio de baja altitud frente a uno de alta montaña). La distancia euclíadiana se calculó entonces en este espacio n-dimensional normalizado, seleccionando como "punto gemelo" definitivo aquel candidato que presentaba el menor valor de distancia, garantizando así la elección del análogo ambiental más similar posible. Como paso final se le asigna el mismo identificador único que su par de incendio. Este paso final es crucial, ya que establece un vínculo entre cada caso y su control, permitiendo el análisis pareado posterior. Como paso final se realizó la eliminación de los puntos de muestreo que no encontraron un "gemelo" para su análisis. La siguiente figura 8 presentada son un ejemplo de los puntos de control obtenidos, se mantiene el mismo incendio, tanto para la escala Dron y Satélite. El script de uso para este proceso se lo presenta en el Anexo 3.



**Figura 8.** Izquierda la distribución de los puntos de "Control" correspondientes al análisis de las colecciones Landsat, a la Derecha correspondiente para el análisis con imágenes de UAV.

### 3.2.3. Validación del emparejamiento.

Una vez generado el conjunto completo de pares de puntos, fue necesario realizar una validación estadística para confirmar que los puntos de control y los de incendio eran funcionalmente similares en sus características ambientales antes del fuego. Esta validación se estructuró en dos niveles: un análisis univariado para cada variable de control individual y una validación multivariada global.

Para el análisis univariado, se seleccionó la prueba no paramétrica de los rangos con signo de Wilcoxon (Wilcoxon, 1945). Esta prueba es especialmente adecuada para un diseño pareado, ya que analiza las diferencias dentro de cada par, un enfoque crucial para controlar la variabilidad que existe entre los diferentes incendios de la región. Al ser una prueba no paramétrica, no requiere que estas irregularidades sigan una distribución normal. El objetivo de esta prueba fue verificar si la mediana de las diferencias para cada variable de control era estadísticamente indistinguible de cero.

Para la validación multivariada global, se seleccionó la prueba T-cuadrado de Hotelling. Esta prueba, que constituye la generalización multivariada de la prueba t de Student, permite responder a la pregunta fundamental: considerando el conjunto de variables de control simultáneamente, ¿son los perfiles ambientales de los grupos de Incendio y Control diferentes? Un paso inicial para esta prueba es la

ausencia de multicolinealidad severa. Por ello, se realizó un análisis previo de la matriz de correlación para identificar y excluir las variables redundantes, asegurando así la robustez del resultado final.

### 3.3. Procesamiento de datos satelitales en *Google Earth Engine*.

Una vez definido el universo de puntos de muestreo y sus controles pareados, se procedió a la extracción de las series temporales de datos satelitales. Este proceso se realizó en la plataforma de computación en la nube *Google Earth Engine* (GEE), para lo cual se desarrollaron tres scripts diferenciados, cada uno para generar una serie temporal a una escala específica: diaria, mensual y anual.

La lógica de extracción fue consistente en los tres casos. Para cada incendio, el script utilizó el año del evento como punto de partida temporal, filtrando el archivo histórico de imágenes Landsat para construir una colección de imágenes relevante solo para ese incendio. Espacialmente, para evitar errores de cómputo con geometrías de polígonos complejos y optimizar el rendimiento, la búsqueda de imágenes no se limitó al perímetro exacto del incendio, sino a su rectángulo envolvente (bounding box). Esta estrategia asegura la captura de todas las imágenes que cubren el área de interés de una forma computacionalmente eficiente.

#### 3.3.1. Preprocesamiento de imágenes Landsat.

Para asegurar la calidad y comparabilidad de los datos a lo largo de toda la serie temporal, cada imagen satelital dentro de una colección fue sometida a un riguroso flujo de pre-procesamiento estandarizado. Este proceso consistió en tres pasos metodológicos principales.

Primero, se realizó una limpieza radiométrica para enmascarar los píxeles inutilizables. Para ello, se utilizó la banda de evaluación de calidad (QA\_PIXEL) que acompaña a cada imagen de Nivel 2. Esta banda permite identificar de forma fiable las observaciones contaminadas por nubes, sombras de nubes o nieve, las cuales fueron excluidas de todos los análisis posteriores para garantizar que únicamente se trabajara con datos de cielo despejado.

Segundo, los valores de número digital de cada banda fueron convertidos a unidades físicas estándar. Las bandas ópticas se transformaron en valores de reflectancia de superficie y la banda térmica se convirtió a Temperatura de la Superficie Terrestre (LST) en grados Celsius, aplicando para ello los factores de escala y desplazamiento oficiales proporcionados por el USGS. A partir de las bandas de reflectancia de superficie, se calcularon en este paso los principales índices espectrales de vegetación y agua, como el Índice de Vegetación de Diferencia Normalizada (NDVI) y el Índice Normalizado de Quemadura (NBR).

Finalmente, se aplicó un proceso de armonización espectral para asegurar la consistencia entre los diferentes sensores de la serie Landsat (TM, ETM+, OLI/TIRS). Este paso ajusta las pequeñas diferencias en las respuestas espectrales de los sensores, permitiendo la creación de una serie temporal continua y homogénea, fundamental para el análisis multitemporal.

#### 3.3.2. Creación de *composites* y series temporales (diaria, mensual, anual).

A partir de las colecciones de imágenes pre-procesadas, que ya contenían tanto la LST como los índices espectrales calculados, se procedió a la extracción de valores para generar tres series temporales distintas, cada una diseñada para un objetivo de análisis específico:

- La serie temporal diaria se construyó extrayendo los valores de LST y de todos los índices espectrales (NDVI, LST, NDWI, BAI y NBR) de cada observación individual disponible durante los tres primeros años posfuego. Este enfoque preserva la máxima resolución temporal de los datos y está orientado al análisis detallado de la dinámica de la anomalía térmica a corto plazo, incluyendo la identificación de patrones estacionales.
- La serie temporal mensual se generó con el objetivo de analizar las tendencias a medio y largo plazo, mitigando el ruido inherente a las observaciones diarias. Para ello, se creó una imagen "compuesta" para cada mes, desde el año del incendio hasta la fecha más reciente disponible. Cada *composite* mensual se obtuvo calculando la mediana de los valores de cada píxel (tanto para la LST

- como para cada índice) a partir de todas las observaciones válidas de ese mes. Se eligió la mediana por ser un estadístico robusto que minimiza el efecto de posibles valores atípicos residuales, generando así un único valor representativo mensual.
- La serie temporal anual fue diseñada para el análisis de las tendencias de normalización a la escala más larga. De forma análoga a la serie mensual, se creó un composite para cada año posfuego calculando el valor promedio de la LST y de cada uno de los índices a partir de todas las observaciones válidas contenidas en ese año.

Una vez generadas estas tres colecciones de imágenes (diarias, composites mensuales y composites anuales), se extrajeron los valores de todas las variables para cada punto de muestreo y de control, conformando así los tres conjuntos de datos brutos que sirvieron de entrada para la siguiente fase de procesamiento en R.

### **3.4. Procesamiento y depuración de series temporales.**

Tras la extracción de las series temporales desde *Google Earth Engine*, los datos brutos fueron sometidos a una fase de procesamiento y depuración en R con el fin de prepararlos para el análisis estadístico. Este proceso se estructuró en una cascada de filtrado y transformación que incluyó, secuencialmente: (1) un filtrado temporal para excluir las observaciones previas al evento de fuego; (2) la consolidación de observaciones duplicadas; (3) el cálculo de las variables de diferencia a partir de los pares de puntos; y (4) la detección y eliminación de valores atípicos. Los siguientes apartados detallan los pasos metodológicos más relevantes de este flujo de trabajo.

#### **3.4.1. Cálculo de las variables de diferencias.**

El primer paso consistió en la consolidación de los datos para el análisis pareado. Para cada identificador de punto (ID\_Punto) y en cada fecha u año de observación, se verificó la existencia simultánea de datos tanto para el punto de la muestra en la zona de "Incendio" como para su correspondiente "Control". Aquellas observaciones que no contaban con su par fueron descartadas.

Una vez asegurada la estructura de pares, se procedió a calcular la variable principal del estudio: la Diferencia de Temperatura Superficial Terrestre. Esta se obtuvo restando el valor de LST del punto de control al del punto de incendio ( $LST_{Incendio} - LST_{Control}$ ). Este mismo procedimiento se aplicó a todos los índices espectrales extraídos, generando las variables de diferencia correspondientes (Diferencia de NBR, Diferencia de NDVI, Diferencia de BAI y Diferencia de NDWI). Estas variables representan la anomalía neta atribuible al efecto del incendio.

#### **3.4.2. Tratamiento de valores atípicos.**

Como paso final en la depuración de los datos, se aplicó un procedimiento estadístico para identificar y eliminar valores atípicos (outliers). El objetivo de este filtro fue asegurar que el análisis posterior no se viera distorsionado por mediciones extremas, que probablemente se originan en artefactos de los datos satelitales o en condiciones microclimáticas puntuales no representativas.

El método seleccionado fue el del Rango Intercuartílico (IQR). Esta es una técnica estándar y robusta en el análisis exploratorio de datos (Tukey, 1977) que define los límites de la variabilidad normal basándose en la propia distribución de los datos. Este procedimiento se aplicó de forma independiente a la variable Diferencia de Temperatura Superficial Terrestre (Dif\_LST) para cada una de las tres escalas temporales.

Para cada escala, el proceso consistió en los siguientes pasos: primero, se calcularon el primer cuartil (Q1) y el tercer cuartil (Q3) de la distribución de todos los valores de Dif\_LST. Segundo, se calculó el Rango Intercuartílico como la diferencia entre ambos ( $IQR = Q3 - Q1$ ). Tercero, se establecieron los umbrales de detección, definiendo el límite inferior como  $Q1 - 1.5 * IQR$  y el límite superior como  $Q3 + 1.5 * IQR$ , siguiendo la convención estándar. Finalmente, todas las observaciones cuyo valor de Dif\_LST se encontraba fuera de este rango fueron clasificadas como atípicas y eliminadas de los con-

juntos de datos finales. Aunque este enfoque puede conllevar la eliminación de valores válidos en distribuciones sesgadas, se lo seleccionó ya que no se requiere asumir una normalidad en la distribución de los datos.

### 3.5. Análisis estadístico.

Para cuantificar e interpretar los patrones observados en los datos depurados, se aplicaron diferentes técnicas estadísticas. El análisis se estructuró en una fase exploratoria inicial, seguida de un modelado estadístico formal para probar las hipótesis del estudio.

#### 3.5.1. Análisis exploratorio de datos.

El análisis exploratorio de datos (EDA), siguiendo los principios propuestos por Tukey (1977), se centró en la visualización de los datos para identificar tendencias, patrones y relaciones fundamentales. Se generaron gráficos de series temporales para visualizar la normalización de la Diferencia de temperatura superficial terrestre a lo largo del tiempo en las diferentes escalas. La estacionalidad se exploró mediante gráficos de violín, mientras que la influencia de las variables de control se analizó visualmente a través de gráficos facetados. Adicionalmente, se utilizó una matriz de correlación para cuantificar la asociación lineal entre las principales variables de diferencia. El protocolo general de exploración de datos se basó en las recomendaciones de Zuur et al. (2010) para evitar problemas comunes en el análisis estadístico.

#### 3.5.2. Modelado de la normalización térmica: Modelos Lineales Mixtos (LMM).

Para cuantificar específicamente las relaciones identificadas en la fase exploratoria, se seleccionaron los Modelos Lineales Mixtos (LMM). Esta herramienta es el estándar para el análisis de datos con una estructura jerárquica o anidada, como es el caso en este estudio, donde existen múltiples observaciones temporales para cada par de puntos, y múltiples pares anidados dentro de cada incendio (Pinheiro & Bates, 2000). Los LMM resuelven el problema de la no independencia de las observaciones al incorporar "efectos aleatorios" ( $1 | IDPAF/ID\_Punto$ ), que modelan la variabilidad inherente a cada sitio y punto de muestreo. Esto permite obtener estimaciones más precisas y generalizables de los "efectos fijos", que son las variables de interés.

La variable respuesta para todos los modelos fue la diferencia del LST. Todas las variables predictoras continuas fueron rescaladas (centradas a media 0 y con desviación estándar 1) para facilitar la convergencia del modelo y la comparación de la magnitud de los coeficientes. La selección del modelo final para cada escala se realizó mediante un procedimiento por pasos hacia adelante, utilizando el Criterio de Información de Akaike (AIC) para comparar el ajuste y la complejidad de los modelos anidados (Burnham & Anderson, 2002).

#### 3.5.3. Análisis comparativo multiescala.

Para abordar el objetivo de comparar las mediciones de la anomalía térmica a diferentes escalas espaciales, se implementó un flujo de trabajo específico para integrar los datos de alta resolución del dron (3 cm) con los datos de resolución media de Landsat (30 m). La premisa de este análisis fue garantizar la máxima comparabilidad temporal entre ambos sensores.

El proceso se estructuró en los siguientes pasos:

- Procesamiento de Datos Independiente: Los conjuntos de datos del dron y del satélite (este último consistente en una serie temporal diaria extraída de GEE para las coordenadas de los puntos de la campaña de dron) fueron sometidos a procesos de limpieza paralelos e independientes. Para cada conjunto, se aseguró la existencia de pares de puntos (Incendio y Control), se pivotaron los datos para obtener un formato ancho y se calculó la variable de diferencia (Dif\_LST\_dron y Dif\_LST\_satelite, respectivamente). Finalmente, se aplicó un filtro de valores atípicos basado en el Rango Intercuartílico (IQR) a cada variable Dif\_LST de forma separada.
- Cruce por Fecha Más Cercana: Utilizando un archivo de referencia con las fechas exactas de los vuelos del dron para cada uno de los 12 incendios (IDPAF), se realizó un cruce temporal inteligente.

Para cada punto de muestreo del dron, el script buscó en la serie temporal satelital la observación cuya fecha era la más próxima a la fecha del vuelo, minimizando así la diferencia temporal entre ambas mediciones.

- Generación de la Tabla Maestra: El resultado de este cruce fue una tabla de análisis final donde cada fila representaba un único punto de muestreo, conteniendo tanto el valor de Dif\_LST\_dron como el de Dif\_LST\_satelite para fechas casi idénticas.
- Análisis Estadístico Integrado: Sobre esta tabla maestra se realizaron tres análisis clave: (a) una comparación de las distribuciones de Dif\_LST mediante estadísticos descriptivos y gráficos de violín; (b) un análisis de correlación de Pearson para cuantificar el grado de asociación lineal entre las mediciones de ambos sensores; y (c) un modelado predictivo mediante un Modelo Lineal Mixto (LMM), donde la Dif\_LST\_dron fue la variable respuesta y la Dif\_LST\_satelite, junto con las variables estáticas del paisaje, actuaron como predictores.

### 3.5.4. Discretización de variables para análisis exploratorio.

Para facilitar la visualización de la influencia de las variables de control en el análisis exploratorio, las variables continuas (topográficas, NBR Pre-Incendio y Severidad Inicial) fueron discretizadas en tres niveles categóricos: "Bajo", "Medio" y "Alto". Para asegurar que estos niveles fueran consistentes y comparables a lo largo de toda el área de estudio, se utilizó un método de terciles globales. Para cada variable, se calcularon los cuantiles del 33% y del 66% sobre el conjunto total de datos de los 95 incendios. Estos dos valores se usaron como umbrales fijos para clasificar todos los puntos, garantizando así que un nivel (ej. "Alto" en elevación) representara el mismo rango de valores para todos los incendios analizados.

## 4. RESULTADOS

### 4.1. Validación del emparejamiento de puntos.

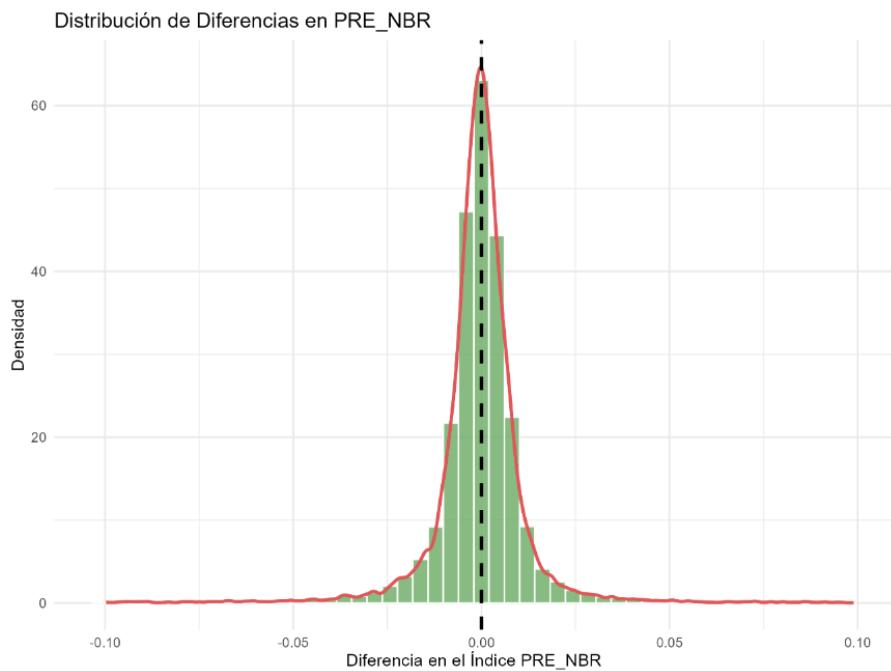
El algoritmo de emparejamiento demostró una alta eficacia, encontrando un "punto gemelo" válido para 17,941 de los 18,108 puntos de muestra iniciales, lo que representa una tasa de éxito global del 99.08%. El desglose por incendio se detalla en el Anexo 4.

Los resultados de la prueba de Wilcoxon (Tabla 1) indican que, si bien se detectaron diferencias estadísticamente significativas ( $p < 0.05$ ) en cinco de las seis variables, la mediana de la diferencia fue de una magnitud prácticamente irrelevante, como los -0.275 metros observados para la elevación.

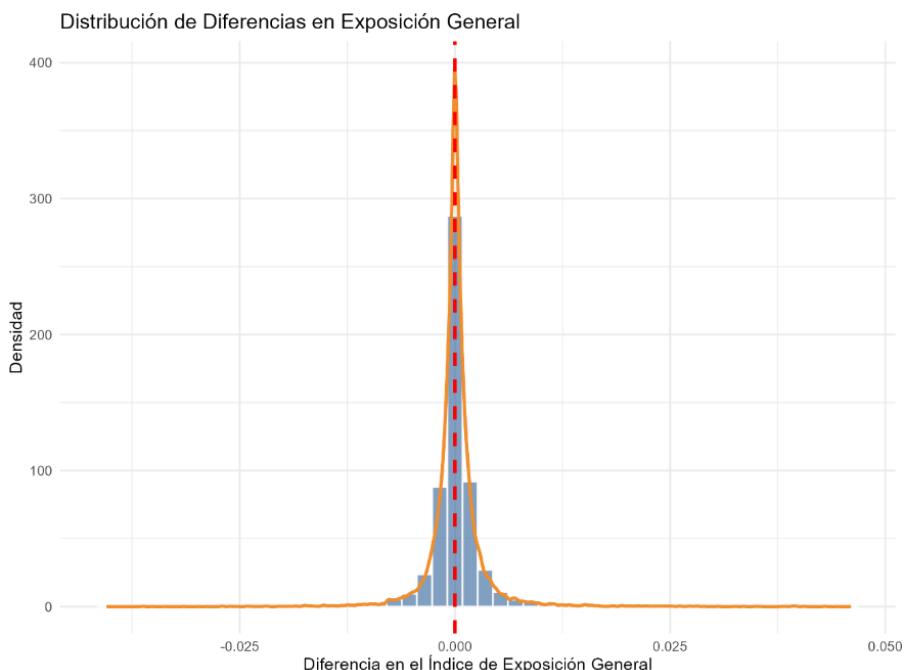
**Tabla 1.** Resultados prueba Wilcoxon puntos emparejados.

Variable	Mediana de la diferencia	Estad. V	p valor
elevacion2m	-0.28	82976236.00	0.00
pendiente2m	-0.01	83477587.00	0.00
expo_general2m	0.00	77191628.50	0.00
tpi2m	0.00	81268325.50	0.24
tri2m	0.00	86674706.50	0.00
PRE_NBR	0.00	82985567.00	0.00

La distribución de estas diferencias entre los pares de puntos confirma visualmente este hallazgo. Para variables clave como el NBR Pre-Incendio (Figura 9) y la Exposición General (Figura 10), se observa una distribución marcadamente leptocúrtica, con un pico muy agudo y perfectamente centrado en cero, lo que demuestra que la gran mayoría de los pares tienen diferencias nulas o casi nulas.



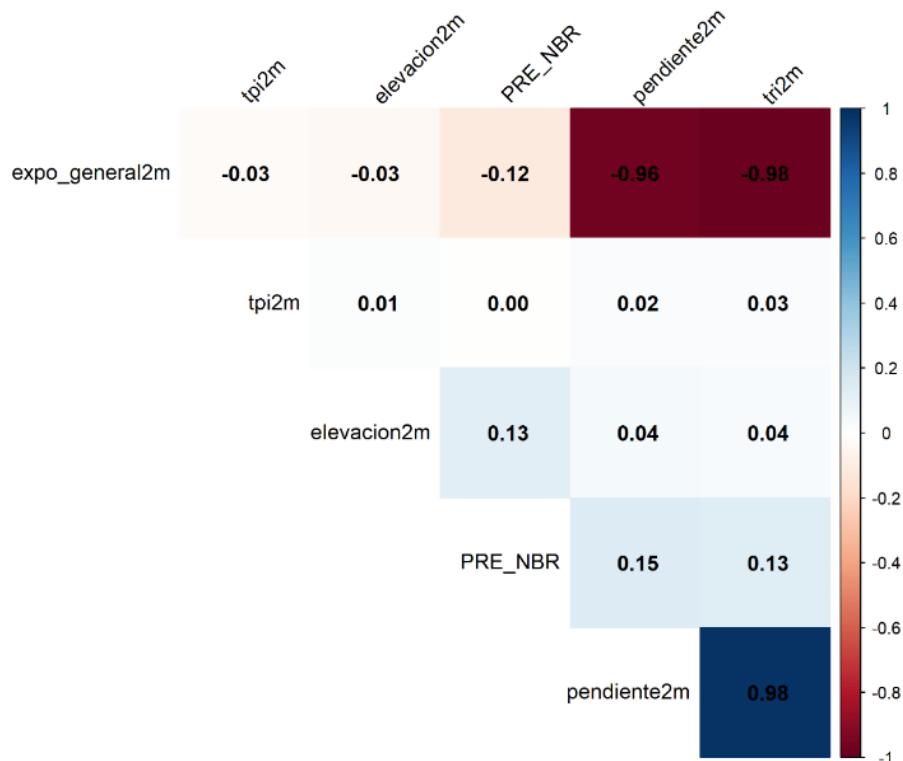
**Figura 9.** Distribución de los valores de diferencia NBR Pre-Incendio, emparejamiento de puntos.



**Figura 10.** Distribución de los valores de Exposición General, emparejamiento de puntos.

Posteriormente, el análisis de multicolinealidad entre las variables de control (Figura 11) identificó una fuerte correlación ( $r > |0.95|$ ) entre las variables topográficas de pendiente, rugosidad y exposición. Este resultado fue determinante para seleccionar un subconjunto de variables no redundantes para la validación multivariada.

### Correlograma de Variables de Control



**Figura 11.** Multicolinealidad de las variables de control del estudio.

Finalmente, la prueba T-cuadrado de Hotelling, ejecutada sobre las variables no correlacionadas, arrojó un p-valor de 0.97 (Tabla 2). Este resultado permite determinar que no se tiene cualquier diferencia significativa entre los perfiles ambientales de los grupos. En conjunto, estos análisis validan el conjunto de puntos pareados para los análisis posteriores.

**Tabla 2.** Resultados estadísticos de la prueba T-cuadrado de Hotelling.

Prueba	Estadístico F	Libertad 1	Libertad 2	p valor
Hotelling (Pendiente y PRE_NBR)	0.07	2	35879	0.97

#### 4.2. Auditoría del procesamiento de datos.

Las series temporales brutas extraídas de *Google Earth Engine* fueron sometidas a un riguroso proceso de depuración en R. La Tabla 3 detalla el procesamiento y la reducción progresiva del número de observaciones en cada una de sus etapas para las tres escalas temporales.

**Tabla 3.** Proceso de depuración de la información de series temporales.

Paso	Diario	Mensual	Anual
Observaciones iniciales GEE	3267497	9765789	951779
Filtrado temporal	2749922	9543002	915897
Consolidación duplicados	2393530	9543002	915897
Filtrado pares incompletos	2056117	9174603	915896
Eliminación outliers Dif LST	1991852	8869602	897336
Obs. Finales pareadas	995926	4434801	448668

El proceso partió de más de 9.7 millones de observaciones individuales en la escala mensual, de las cuales aproximadamente 4.4 millones de pares de observaciones sobrevivieron a la limpieza completa. Como se observa en la tabla, las fases de "Filtrado temporal" y "Filtrado pares incompletos" fueron las que ocasionaron la mayor parte de la reducción de datos. La consolidación de duplicados fue un fenómeno relevante únicamente en los datos diarios.

El paso final de depuración fue la eliminación de valores atípicos en la variable Diferencia de LST. La Tabla 4 resume los umbrales calculados para este filtro y el número de observaciones eliminadas. Este procedimiento resultó en la exclusión de aproximadamente un 3% de las observaciones pareadas restantes en las escalas diaria y mensual. Notablemente, en la escala anual no se detectó ningún valor atípico, lo que evidencia el efecto de suavizado del promedio anual.

**Tabla 4.** Filtro de eliminación de valores atípicos (outliers).

Escala	Q1	Q3	IQR	Lim. Inferior	Lim. Superior	Obs. Inicio	Obs. Eliminadas	% Eliminado
Anual	-0.89	2.82	3.71	-6.46	8.38	457948	0	0.00
Diario	-0.54	4.40	4.94	-7.96	11.81	1028059	32133	3.13
Mensual	-1.26	3.18	4.44	-7.93	9.85	4587302	152501	3.32

El resultado final de esta fase de preparación se resume en la Tabla 5. A pesar de la considerable reducción en el número de observaciones temporales, el proceso de limpieza mantuvo una alta retención de los puntos de muestreo geográficos originales, conservando más del 99% de los 17,941 puntos emparejados en todas las escalas. Este resultado confirma que la pérdida de datos se debió a factores aleatorios (como la nubosidad) y no a un sesgo sistemático, validando la muestra espacial a lo largo de todo el análisis.

**Tabla 5.** Resumen del proceso de limpieza datos.

Escala	Muestra inicial	Emparejamiento	Lim-pieza	% de éxito	% de conser-vación	Obs. Ini-ciales GEE	Pares de Obs. lim-pias	Obs. Conserva-das GEE %
Diario	18108	17941	17941	99.08	99.08	3267497	995926	60.96
Mensual	18108	17941	17941	99.08	99.08	9765789	4434801	90.82
Anual	18108	17941	17939	99.08	99.07	951779	448668	94.28

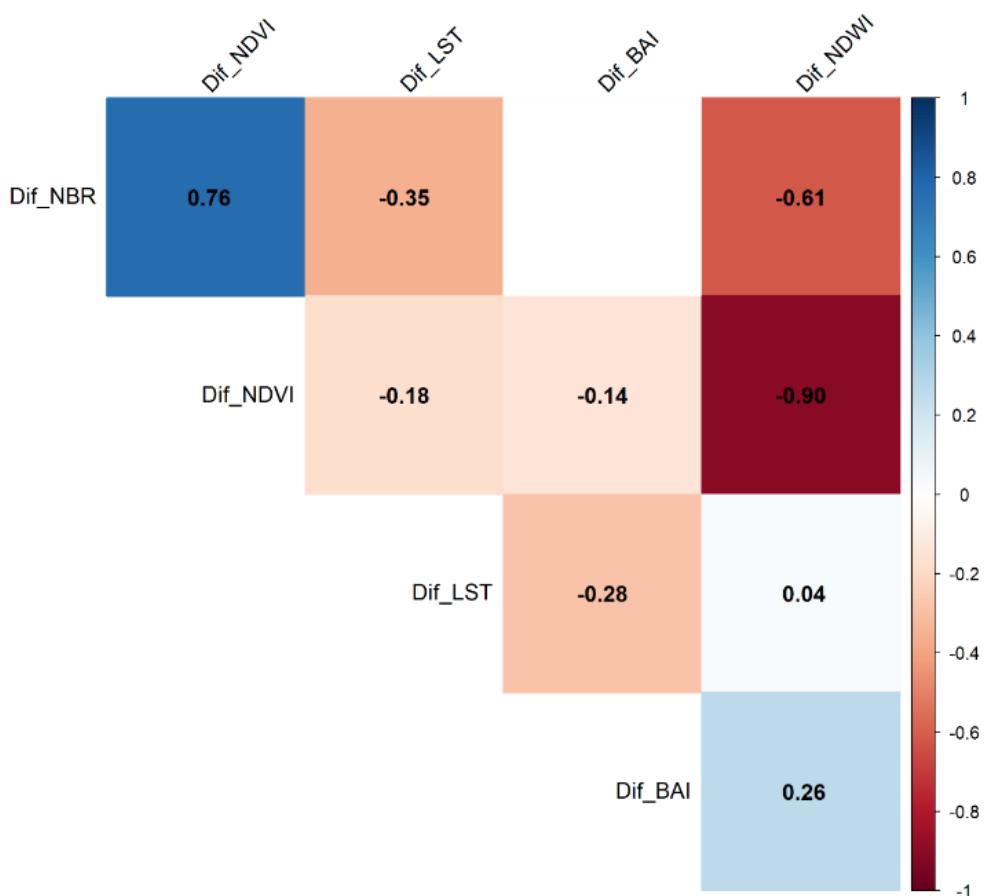
Además de la evaluación global, se analizó la consistencia del proceso de depuración a nivel de cada incendio individual (ver Anexo 5 para el desglose completo). A modo de ejemplo, para el incendio con IDPAF 55, se conservó un 65.4% de las observaciones diarias y un 64.6% de las mensuales. Estos valores, representativos del grupo, ilustran cómo la retención de datos se mantuvo no solo a nivel global, sino también a escala de cada evento de fuego.

#### 4.3. Análisis exploratorio de la dinámica de la Diferencia de LST.

Tras la depuración de los datos, se realizó un análisis exploratorio visual para identificar los patrones y relaciones fundamentales en las series temporales.

##### 4.3.1. Relación entre la anomalía térmica y la recuperación de la vegetación.

El primer paso del análisis fue cuantificar la relación entre la anomalía térmica (Dif\_LST) y las anomalías de los principales índices espectrales. La matriz de correlación Figura 12 revela dos patrones clave.



**Figura 12.** Correlogramma entre la anomalía térmica y los índices espectrales.

Primero, se observa una correlación negativa, moderada y significativa entre la Diferencia de LST y los índices de vegetación. La correlación con la Diferencia de NBR es de  $r = -0.35$ , mientras que con la Diferencia de NDVI es de  $r = -0.18$ . Este resultado confirma la hipótesis de que, a mayor recuperación vegetal, la anomalía térmica disminuye.

Segundo, se evidencia una alta colinealidad entre los propios índices de vegetación, particularmente entre la Diferencia de NBR y la Diferencia de NDVI ( $r = 0.76$ ). Dado que ambos índices miden procesos ecológicos similares y que el NBR es el estándar en la literatura sobre incendios, se seleccionó la Diferencia de NBR como el principal indicador de la recuperación de la vegetación para los análisis posteriores.

#### 4.3.2. Patrón general y estacionalidad de la estabilización térmica.

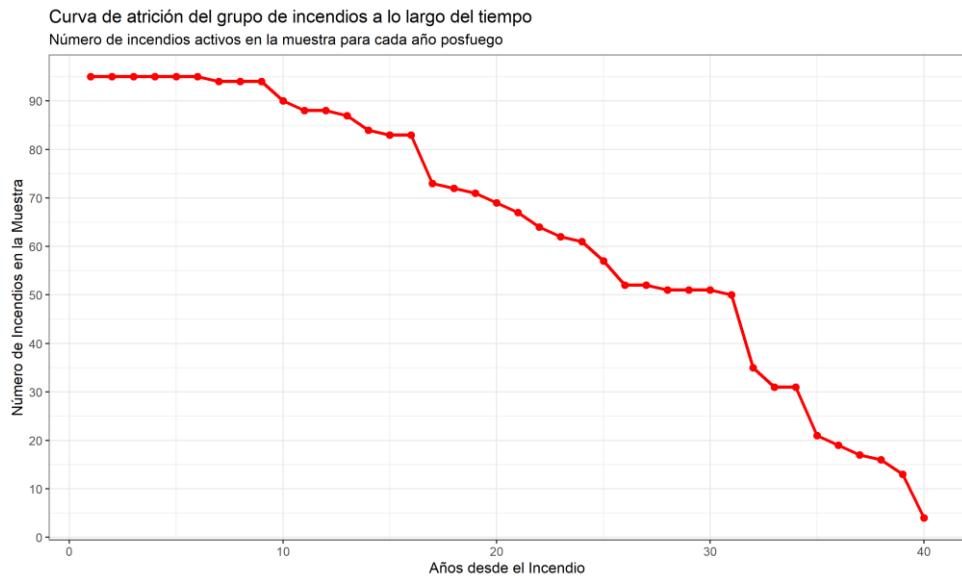
El análisis de las series temporales revela un patrón de recuperación general consistente a lo largo del tiempo para las tres escalas de análisis (Figura 13). Inmediatamente después del fuego (año 0), la Diferencia de LST media es elevada, superando los  $2.5^{\circ}\text{C}$  en la escala diaria. Durante los primeros 10 a 15 años, se observa una fase de recuperación rápida con una disminución pronunciada de la anomalía térmica. Posteriormente, la recuperación se ralentiza y la Diferencia de LST tiende a estabilizarse en valores cercanos a cero. El Anexo 6 presenta los valores promedio para cada año y escala.

### Comparación de la Tendencia de Recuperación de Dif\_LST a Tres Escalas Temporales



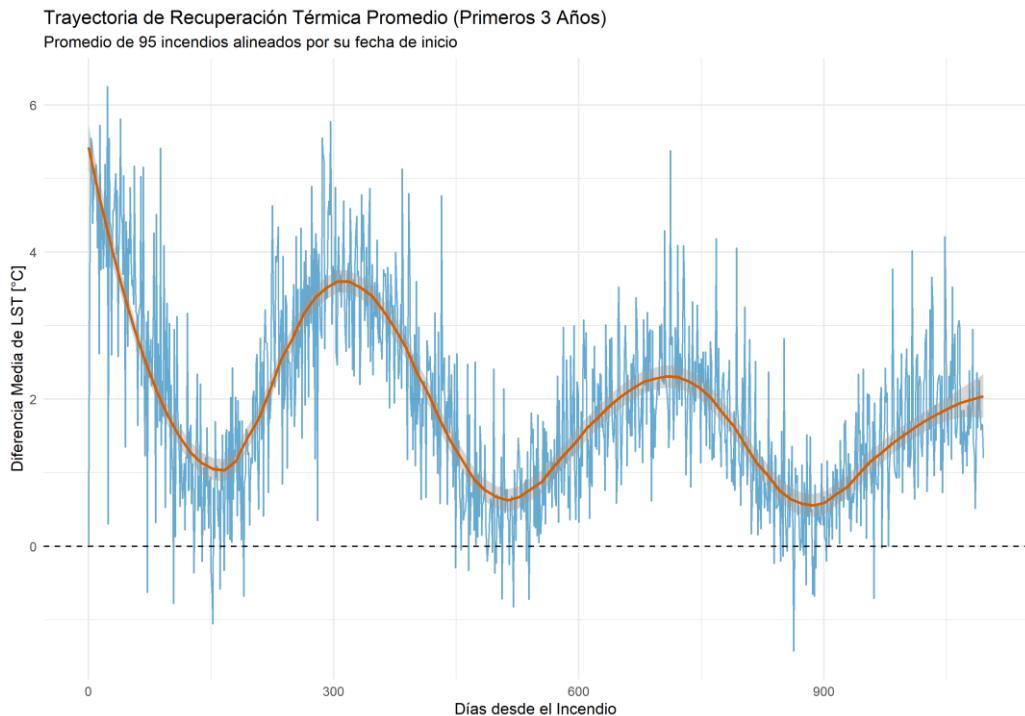
**Figura 13.** Tendencia de recuperación de la Diferencia de LST a escalas diaria, mensual y anual. La figura muestra la Diferencia de LST media para cada año transcurrido desde el incendio. Las áreas sombreadas representan el error estándar de la media. El patrón general muestra una rápida atenuación inicial seguida de una estabilización a largo plazo.

Es importante notar que la trayectoria de la media global, particularmente las fluctuaciones a medio y largo plazo, debe interpretarse con cautela. Dado que el estudio abarca un grupo de incendios ocurridos en diferentes años, la composición de la muestra utilizada para calcular la media de cada "año desde el incendio" cambia a lo largo del tiempo. A medida que avanzan los años, los incendios más recientes "salen" del análisis, y la tendencia pasa a estar determinada por un subconjunto decreciente de incendios más antiguos. Este efecto de composición de la muestra (detallado en el Anexo 7, que muestra las trayectorias individuales) puede introducir artefactos en la tendencia agregada, como los ligeros repuntes observados a lo largo de la serie temporal. No obstante, el patrón dominante de una rápida atenuación inicial seguida de una estabilización a largo plazo se mantiene. La siguiente Figura 14 se puede apreciar la perdida de observaciones de estudio en el análisis temporal.



**Figura 14.** Curva de atrición del grupo de incendios.

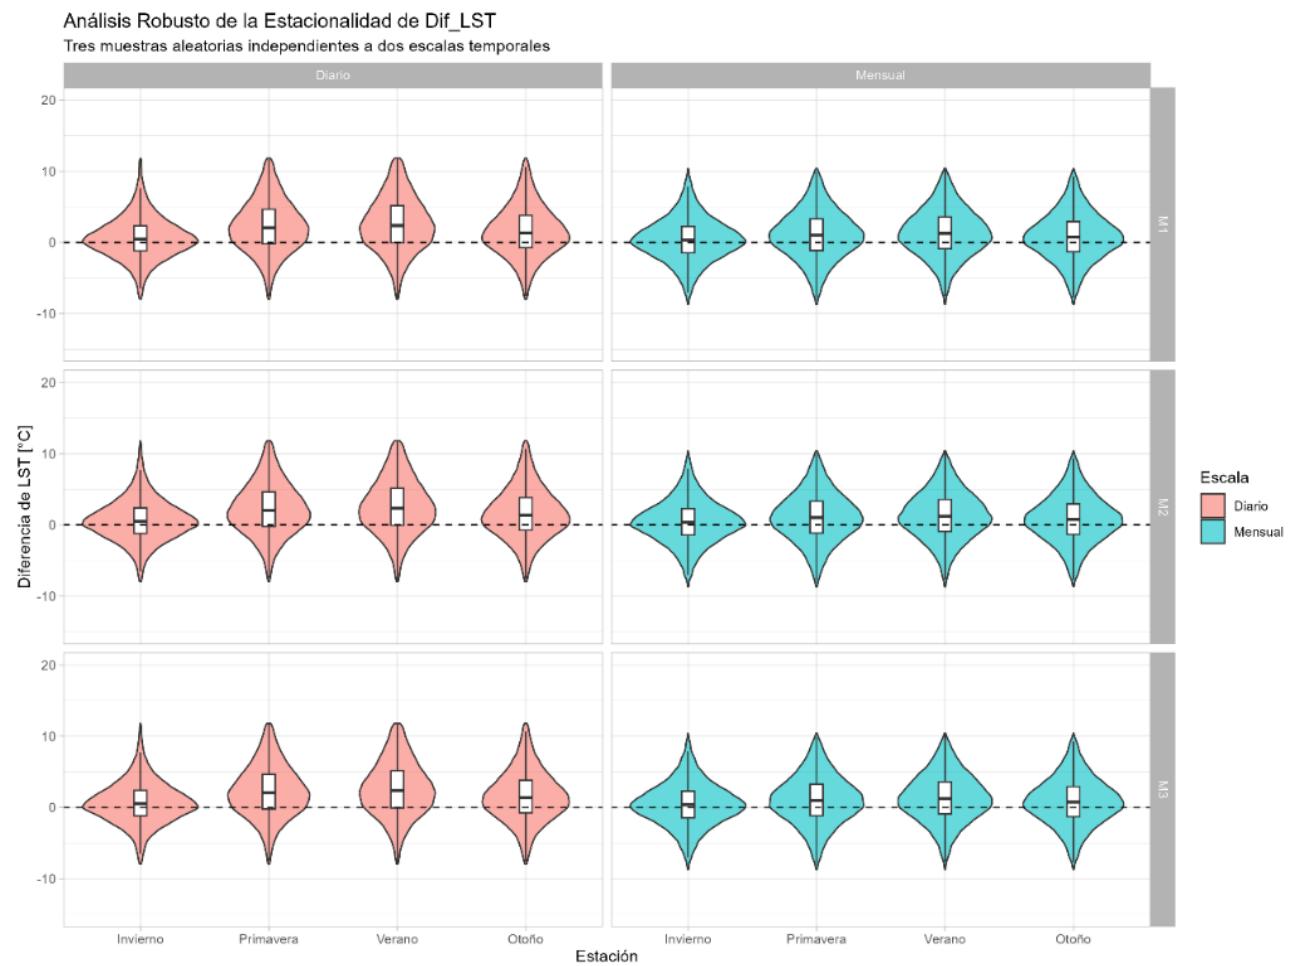
La dinámica a corto plazo, analizada a partir de los datos diarios de los primeros tres años posfuego, se presenta en la Figura 15. Para visualizar el patrón de recuperación promedio del grupo completo de 95 incendios, las series temporales fueron alineadas según su fecha de inicio. El gráfico muestra con gran claridad la trayectoria de la diferencia en el LST media durante los primeros 1095 días. Se observa una pronunciada caída durante el primer año, indicando una rápida normalización inicial. Superpuesta a esta tendencia descendente, se manifiesta un patrón estacional cíclico muy marcado, con picos recurrentes de la anomalía térmica que coinciden con los períodos estivales del primer, segundo y tercer año posfuego.



**Figura 15.** Trayectoria de recuperación térmica promedio durante los tres primeros años posfuego. La línea azul representa la media diaria y la línea naranja suavizada (LOESS) revela una pronunciada tendencia descendente superpuesta a ciclos estacionales.

Este patrón estacional lo podemos apreciar al analizar la distribución de los datos por estación del año (Figura 16). El análisis de tres muestras aleatorias independientes, tanto para la escala diaria como mensual, muestra consistentemente que la Diferencia de LST es máxima durante el verano y mínima

durante el invierno. La Tabla 6 cuantifica esta observación, mostrando que la Diferencia de LST media en verano ( $1.33^{\circ}\text{C}$ ) es aproximadamente tres veces superior a la registrada en invierno ( $0.44^{\circ}\text{C}$ ).



**Figura 16.** Análisis de la estacionalidad de la Diferencia de LST. El gráfico muestra las distribuciones de Dif\_LST ( $^{\circ}\text{C}$ ) para cada estación del año, a partir de tres muestras aleatorias independientes para las escalas diaria y mensual. Se observa de forma consistente un máximo de la anomalía térmica en verano y un mínimo en invierno.

**Tabla 6.** Estadísticos de las observaciones agrupadas por estacionalidad.

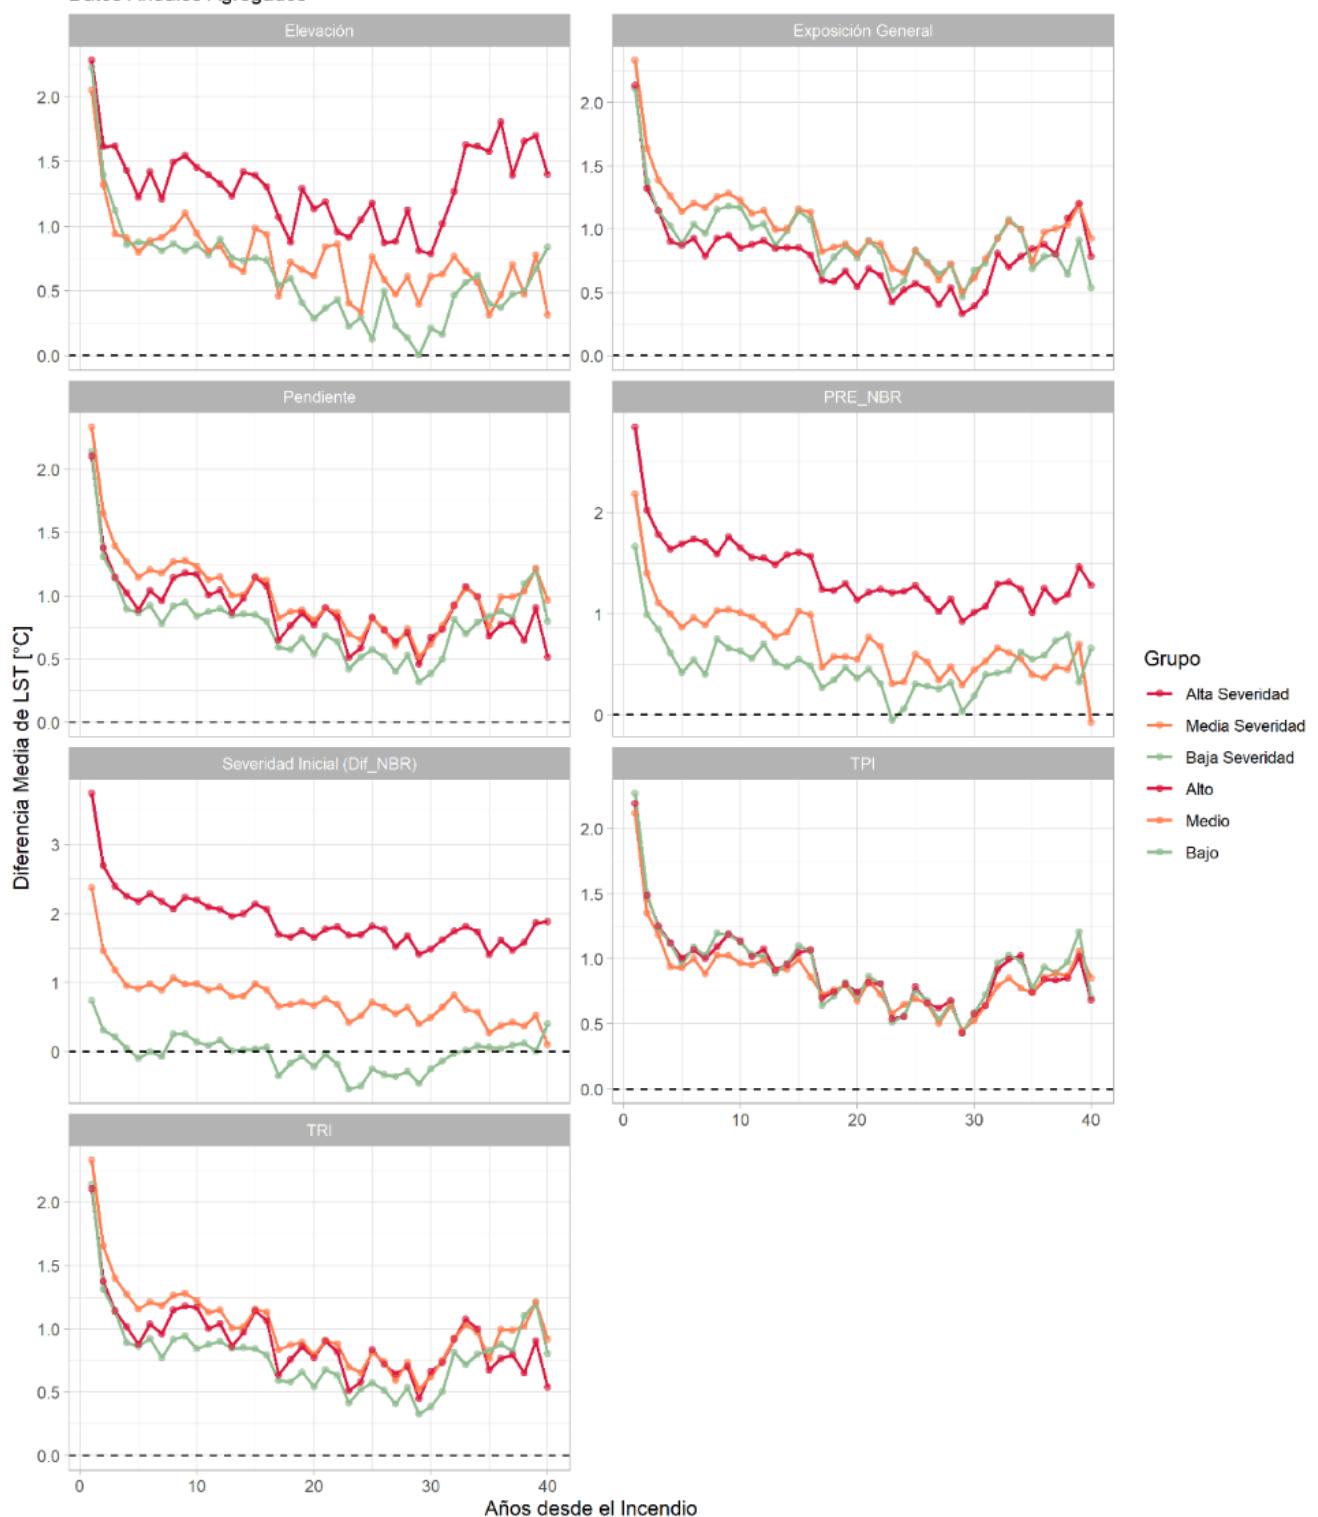
Estación	Media	Mediana	Desv. Estan-dar	P05	P95	# obs.
Primavera	1.06	1.00	3.42	-4.71	6.96	1076234
Verano	1.33	1.27	3.37	-4.31	7.08	1237630
Otoño	0.83	0.76	3.32	-4.76	6.58	1096908
Invierno	0.44	0.37	3.04	-4.63	5.72	1024029

#### 4.3.3. Influencia de los factores de control en la estabilización térmica.

Para explorar cómo diferentes variables modulan la cicatrización térmica, se analizó la evolución de la Diferencia de LST media anual agrupando los datos en tres niveles (Bajo, Medio, Alto) para cada una de las variables de control. Los resultados de este análisis se presentan en la Figura 17.

## Influencia de las Variables de Control en la Tendencia de Recuperación de Dif\_LST

Datos Anuales Agregados



**Figura 17.** Influencia de las variables de control en la trayectoria de recuperación de la Diferencia de LST. Cada panel muestra la tendencia de la Diferencia de LST media anual para subgrupos de datos. Los datos fueron divididos en tres niveles ("Bajo", "Medio", "Alto"). La Severidad Inicial muestra el efecto más marcado en la magnitud y persistencia de la anomalía.

Del análisis visual de los gráficos se desprenden varios patrones. La Severidad Inicial (Severidad\_Inicial\_DifNBR\_grupo) aparece como el factor con la influencia más marcada y clara: las áreas que sufrieron una mayor severidad (grupo "Alto") presentan una Diferencia de LST inicial significativamente más elevada y una recuperación más lenta y prolongada en el tiempo.

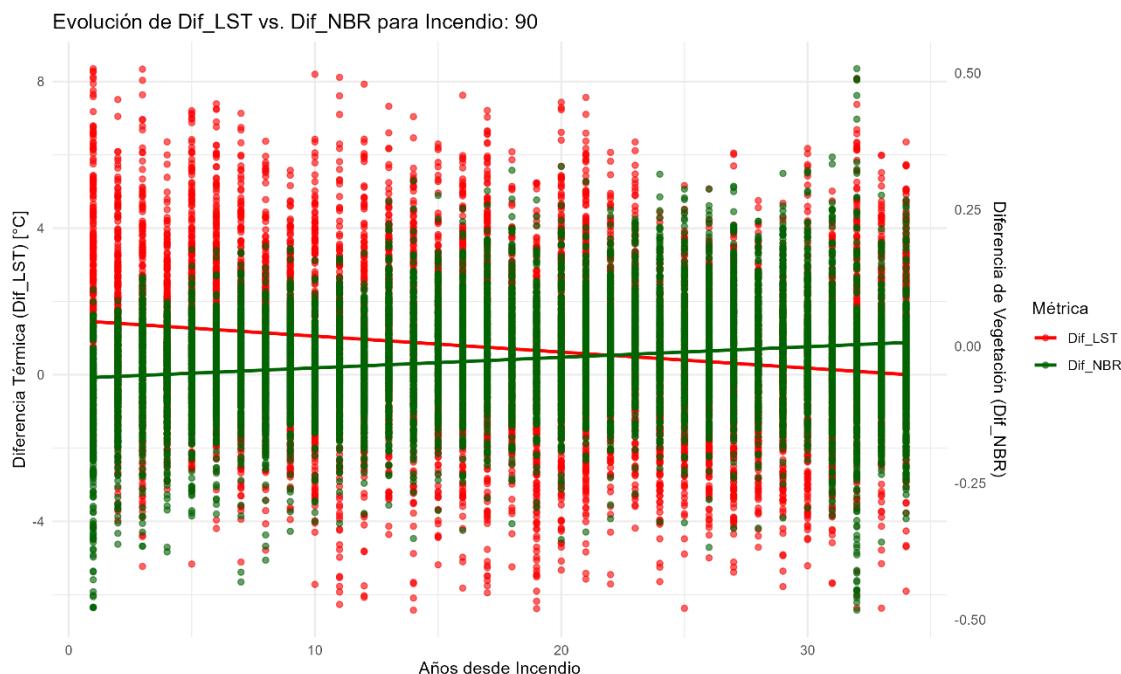
Las variables topográficas también muestran tendencias. Las zonas con mayor elevación y pendiente tienden a registrar una Diferencia de LST inicial más alta y una recuperación aparentemente más

lenta. Para otras variables como la Exposición General, el TPI o el TRI, las tendencias son menos pronunciadas, aunque parecen sugerir que los terrenos más expuestos y rugosos mantienen una diferencia ligeramente superior. De igual manera, las áreas con menor cobertura vegetal antes del incendio (grupo "Bajo" en PRE\_NBR\_grupo) muestran, como era de esperar, una Diferencia de LST más elevada durante todo el periodo.

#### 4.3.4. Heterogeneidad en las trayectorias de recuperación: Casos de estudio.

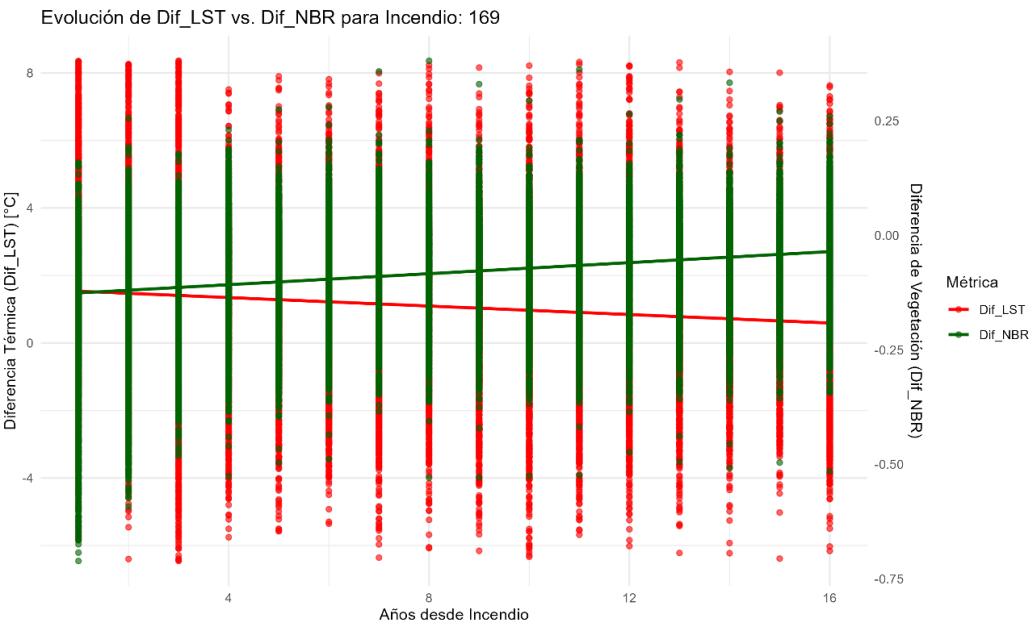
Si bien las tendencias promedio muestran patrones claros, el análisis individual de cada incendio revela una considerable heterogeneidad en las trayectorias de recuperación. Los gráficos de panel que muestran la evolución de la Diferencia de LST y la Diferencia de NBR para los 95 incendios se presentan en el Anexo 8. Para ilustrar esta diversidad, se han seleccionado tres casos de estudio representativos que se detallan a continuación:

- Incendio 90 (1991, Ambel): Este caso presenta una trayectoria que se alinea estrechamente con el comportamiento teórico esperado (Figura 18). Los valores iniciales de la Diferencia de LST son elevados, mientras que los de la Diferencia de NBR son fuertemente negativos. A medida que avanzan los años, se observa una clara tendencia descendente en la anomalía térmica, y una tendencia ascendente de la recuperación de la vegetación. La fuerte relación inversa entre ambas variables y la progresiva vuelta a valores cercanos a cero indican un proceso de recuperación predecible y fuertemente acoplado.



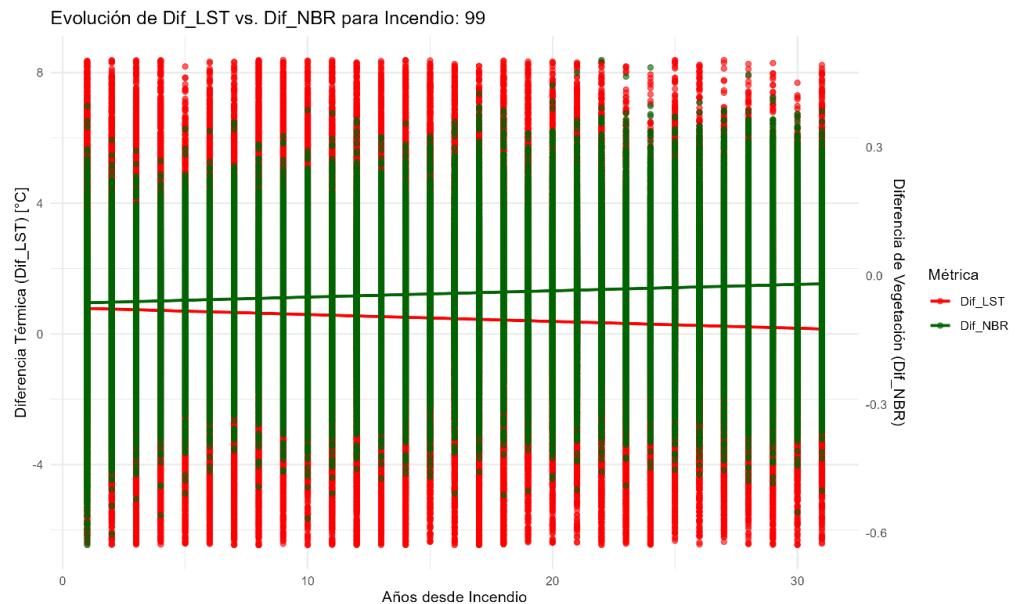
**Figura 18.** Evolución de las diferencias del LST y NBR Incendio 90.

- Incendio 169 (2009, Campo de Tiro y Maniobras de San Gregorio): En contraste, este incendio es un ejemplo de aparente baja resiliencia del ecosistema (Figura 19). A lo largo de todo el periodo de observación, ambas métricas muestran una escasa evolución. Las líneas de tendencia, tanto para la Diferencia de LST como para la Diferencia de NBR, son prácticamente planas y se mantienen lejos de los valores de referencia (cero). Este comportamiento sugiere un estancamiento en el proceso de sucesión ecológica, donde ni la vegetación logra recuperarse de forma significativa ni, en consecuencia, se disipa la anomalía térmica generada por el fuego.



**Figura 19.** Evolución de las diferencias del LST y NBR Incendio 169.

- Incendio 99 (1994, Maestrazgo): Este caso ilustra una dinámica de recuperación más compleja e inestable (Figura 20). Si bien las tendencias generales promedio son las esperadas (la Diferencia de LST desciende y la de NBR asciende), la dispersión de los datos interanuales es extremadamente alta para ambas variables. Para un mismo año transcurrido desde el fuego, se registran anomalías térmicas tanto positivas como negativas, y una gran amplitud en los valores de recuperación de la vegetación. Esto sugiere un ecosistema que, aunque tiende a la recuperación a largo plazo, se ha vuelto termodinámicamente más inestable y altamente sensible a las variaciones climáticas interanuales tras la perturbación.



**Figura 20.** Evolución de las diferencias del LST y NBR Incendio 99.

#### 4.4. Modelado de la normalización térmica.

El proceso de selección de modelos y los resultados finales del ajuste de los Modelos Lineales Mixtos (LMM) se presentan a continuación de forma individual para cada una de las tres escalas temporales analizadas. Además, se realizó un diagnóstico de los residuos para cada uno de los tres modelos con el fin de asegurar la fiabilidad de los resultados. Los gráficos de residuos frente a valores ajustados,

presentados en el Anexo 9, muestran en los tres casos una nube de puntos aleatoria y sin patrones discernibles, centrada horizontalmente en la línea de cero. Esta distribución indica que se cumplen los supuestos de linealidad y homocedasticidad (varianza constante de los errores), validando así la adecuación de los modelos lineales mixtos empleados en este estudio.

#### 4.4.1. Resultados del modelo mensual.

Para la serie temporal mensual, se siguió un procedimiento de selección de modelos por pasos hacia adelante para identificar los predictores más relevantes. Se compararon modelos anidados utilizando el Criterio de Información de Akaike (AIC), que evalúa el ajuste relativo de cada modelo penalizando su complejidad (Burnham & Anderson, 2002). El proceso, detallado en el Anexo 10, mostró que el modelo con el mejor ajuste fue aquel que incluyó la Diferencia de NBR como indicador de vegetación y la elevación como variable topográfica. El análisis posterior de los coeficientes y la significación estadística de este modelo final es lo que determina la importancia y el efecto de cada factor.

La tabla de coeficientes del modelo final se presenta en la Tabla 7. Todos los efectos fijos resultaron estadísticamente significativos ( $p < 0.001$ ). Los resultados cuantitativos del ajuste del modelo (Tabla 8) muestran que los efectos fijos explican aproximadamente un 9.0% de la variabilidad de la Diferencia de LST ( $R^2$  marginal), mientras que los efectos fijos y aleatorios combinados explican un 46.2% ( $R^2$  condicional).

**Tabla 7.** Coeficientes estadísticos para el modelo “mensual”.

Variable	Estimate	Std. Error	df	t value	Pr(> t )
(Intercept)	0.42	0.07	87.77	6.28	<0.001
year_since_fire_z	-0.12	0.00	4419845.38	-89.60	<0.001
Dif_NBR_z	-0.79	0.00	4430125.63	-456.04	<0.001
estacionOtoño	0.38	0.00	4416864.75	115.91	<0.001
estacionPrimavera	0.65	0.00	4416887.29	193.99	<0.001
estacionVerano	0.96	0.00	4416942.15	297.21	<0.001
elevacion2m_z	0.33	0.03	1595.18	10.83	<0.001
year_since_fire_z:Dif_NBR_z	-0.01	0.00	4425920.52	-5.75	<0.001

**Tabla 8.** Coeficientes estadísticos para el ajuste del modelo “mensual”.

Métrica	Valor
AIC	20488904.380
BIC	20489050.734
R2_condicional	0.462
R2_marginal	0.090
RMSE	2.408

#### 4.4.2. Resultados del modelo anual.

De manera análoga a la escala mensual, la selección de variables para el modelo anual confirmó a la Diferencia de NBR y a la elevación como los predictores más significativos. El modelo final (Tabla 9) muestra que todos los efectos fijos son estadísticamente significativos. El análisis de la bondad de ajuste (Tabla 10) indica una capacidad explicativa superior en esta escala: los efectos fijos explican un 17.3% de la variabilidad ( $R^2$  marginal), y el modelo completo alcanza a explicar un 68.2% de la variabilidad total ( $R^2$  condicional).

**Tabla 9.** Coeficientes estadísticos para el modelo “anual”.

Variable	Estimate	Std. Error	df	t value	Pr(> t )
(Intercept)	1.00	0.06	87.06	16.15	<0.001
Year_z	-0.05	0.00	438495.71	-16.64	<0.001
Dif_NBR_z	-1.03	0.00	433683.16	-218.45	<0.001
elevacion2m_z	0.28	0.03	1396.71	9.50	<0.001
Year_z:Dif_NBR_z	-0.04	0.00	440259.03	-15.14	<0.001

**Tabla 10.** Coeficientes estadísticos para el ajuste del modelo “anual”.

Métrica	Valor
AIC	1717392.037
BIC	1717480.149
R2_condicional	0.682
R2_marginal	0.173
RMSE	1.497

#### 4.4.3. Resultados del modelo diario.

El modelo para la escala diaria arrojó resultados consistentes con las otras escalas temporales. El proceso de selección de variables identificó a la Diferencia de NBR y a la elevación como los predictores óptimos. Los coeficientes del modelo final se presentan en la Tabla 11. El análisis de la bondad de ajuste (Tabla 12) indica que los efectos fijos explican un 15.7% de la variabilidad ( $R^2$  marginal), mientras que el modelo completo, incluyendo los efectos aleatorios, explica un 61.0% ( $R^2$  condicional).

**Tabla 11.** Coeficientes estadísticos para el modelo “diario”.

Variable	Estimate	Std. Error	df	t value	Pr(> t )
(Intercept)	0.40	0.09	88.41	4.25	<0.001
year_since_fire_z	-0.27	0.00	987428.86	-100.70	<0.001
Dif_NBR_z	-1.02	0.00	991384.27	-234.34	<0.001
estacionOtoño	0.96	0.01	978479.41	133.74	<0.001
estacionPrimavera	1.83	0.01	978046.70	239.75	<0.001
estacionVerano	2.23	0.01	978832.96	322.26	<0.001
elevacion2m_z	0.49	0.04	2344.52	12.25	<0.001
year_since_fire_z:Dif_NBR_z	0.03	0.00	983268.59	10.29	<0.001

**Tabla 12.** Coeficientes estadísticos para el ajuste del modelo “diario”.

Métrica	Valor
AIC	4574306.393
BIC	4574436.318
R2_condicional	0.610
R2_marginal	0.157
RMSE	2.300

#### 4.4.4. Interpretación de los efectos del modelo.

El análisis de los coeficientes de los modelos finales (efectos fijos) revela patrones consistentes y estadísticamente significativos en las tres escalas temporales. A continuación, se interpretan los principales hallazgos derivados del modelo mensual, que es el más completo al incluir el efecto estacional.

- Efecto de la Recuperación de la Vegetación y el Tiempo: Los resultados confirman la hipótesis principal. El efecto más potente es la normalización de las propiedades ópticas de la superficie analizadas a través de la Diferencia de NBR (Dif\_NBR\_z) ( $\beta \approx -0.79$ ). Dado que este índice es el principal indicador de la recuperación de la biomasa y está inversamente relacionado con la severidad inicial del fuego, el resultado pone de manifiesto que la regeneración de la vegetación es el motor principal de la reducción de la diferencia térmica entre casos y controles. Adicionalmente, el coeficiente asociado al tiempo transcurrido desde el incendio (year\_since\_fire\_z) es consistentemente negativo ( $\beta \approx -0.12$ ), indicando una progresiva normalización térmica a lo largo de los años.
- Efecto de la Estacionalidad: El modelo confirma el patrón observado en el análisis exploratorio. Tomando el invierno como estación de referencia, la Diferencia de LST es significativamente mayor en otoño ( $\beta \approx +0.38$ ), primavera ( $\beta \approx +0.65$ ) y, sobre todo, en verano ( $\beta \approx +0.96$ ), haciendo patente que la anomalía térmica se magnifica durante los meses de mayor insolación.
- Efecto de los Factores de Control: De las variables topográficas analizadas, la elevación (elevation2m\_z) resultó ser el predictor más influyente. Su coeficiente positivo ( $\beta \approx +0.33$ ) indica que, a mayor altitud, la Diferencia de LST tiende a ser mayor. Esto sugiere que los incendios ocurridos en zonas más elevadas presentan una cicatriz térmica más pronunciada o persistente.
- Variabilidad entre Incendios (Efectos Aleatorios): El análisis de las métricas de ajuste del modelo (Tabla #) revela un hallazgo fundamental. El  $R^2$  marginal, que representa la varianza explicada por los efectos fijos, es del 9.0%, mientras que el  $R^2$  condicional, que incluye la variabilidad atribuible a cada incendio y punto de muestreo, asciende al 46.2%. Esta gran diferencia entre ambos valores cuantifica la enorme heterogeneidad que existe entre los distintos eventos de fuego y demuestra que una parte sustancial de la respuesta térmica depende de las características idiosincráticas de cada incendio, justificando la necesidad del enfoque de modelado mixto.

#### 4.5. Análisis multiescala: comparación de la anomalía térmica Dron vs. Satélite.

El análisis comparativo final se efectuó sobre un conjunto de 1,342 pares de puntos de muestreo válidos, donde la diferencia temporal promedio entre la adquisición del dron y la del satélite fue de 6.2 días, garantizando así una alta comparabilidad temporal entre ambos sensores.

##### 4.5.1. Distribución y variabilidad de las diferencias de temperatura.

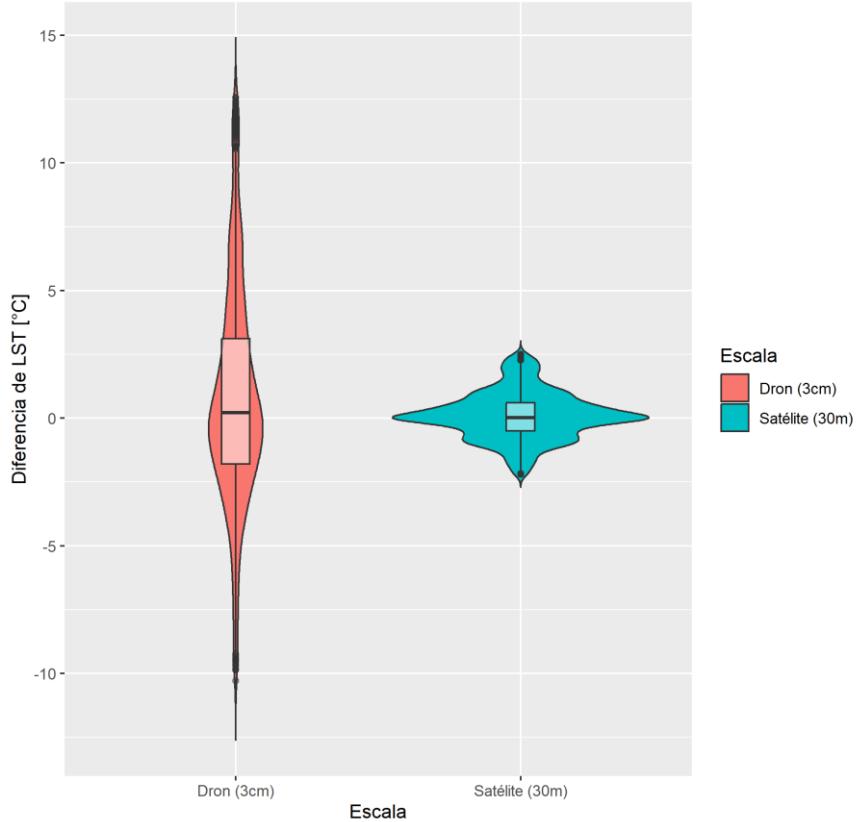
El análisis de las distribuciones de la Diferencia de LST (Dif\_LST) revela diferencias fundamentales entre las dos escalas de observación. Como se detalla en la Tabla 13, la anomalía térmica media registrada por el dron fue de  $0.82^{\circ}\text{C}$ , mientras que la capturada por el satélite fue sustancialmente menor, de  $0.10^{\circ}\text{C}$ . La divergencia más significativa se manifestó en la variabilidad de las mediciones: la desviación estándar para los datos del dron fue de  $4.30^{\circ}\text{C}$ , un valor casi cinco veces superior al de los datos satelitales  $0.93^{\circ}\text{C}$ .

**Tabla 13.** Valores estadísticos de las distribuciones de la Diferencia del LST para Dron (D) y Satélite (S).

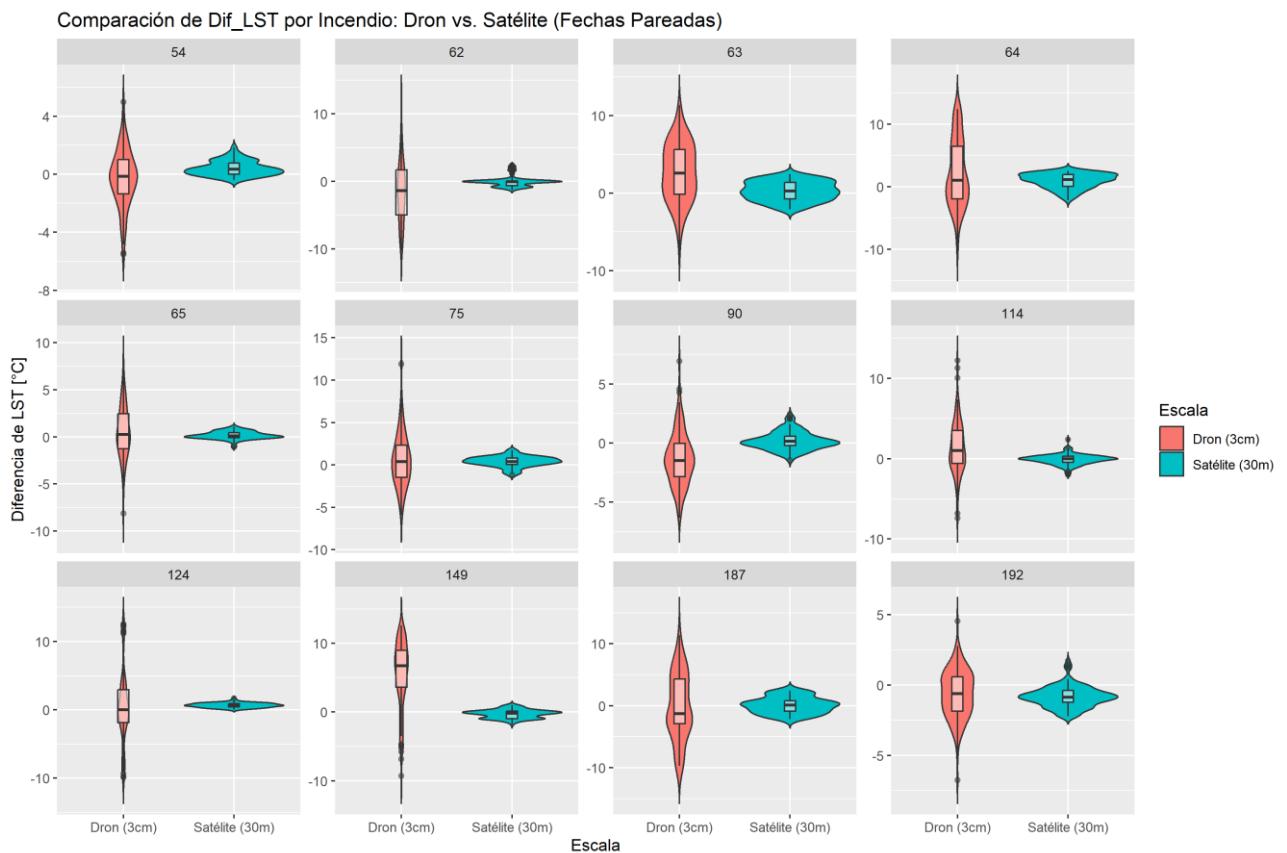
Media D.	Mediana D.	SD D.	Media S.	Mediana S.	SD S.	# Obs.	Media Día
0.82	0.21	4.30	0.10	0.02	0.93	1342.00	6.18

La Figura 21 ilustra visualmente este contraste. La distribución de los datos del dron presenta colas muy extendidas, indicativas de una alta heterogeneidad y la presencia de valores extremos, mientras que la distribución de los datos satelitales se muestra mucho más concentrada en torno a la media. Este patrón, donde el dron registra una variabilidad sistemáticamente mayor, se mantuvo de forma consistente en los 12 incendios analizados individualmente (Figura 22).

Comparación Global de Dif\_LST: Dron vs. Satélite (Fechas Pareadas)



**Figura 21.** Comparación de las distribuciones de la Diferencia de LST entre las escalas de dron (3 cm) y satélite (30 m). Los gráficos de violín muestran la densidad de probabilidad de los datos, mientras que las cajas internas representan la mediana y el rango intercuartílico. Se observa una dispersión significativamente mayor en las mediciones del dron en comparación con las del satélite.



**Figura 21.** Comparación de las distribuciones de la Diferencia de LST por cada incendio.

La Tabla 14 recoge estas diferencias a nivel de cada incendio. Por ejemplo, para el incendio con IDPAF 63, la Dif\_LST media con datos procedentes del dron fue de  $+2.71^{\circ}\text{C}$  con una desviación estándar de  $3.79^{\circ}\text{C}$ , mientras que para el satélite los valores correspondientes fueron de  $+0.28^{\circ}\text{C}$  y  $1.24^{\circ}\text{C}$ , respectivamente. En contraste, para el incendio 90, se registraron anomalías térmicas medias negativas para el dron ( $-1.33^{\circ}\text{C}$ ) y positivas para el satélite ( $+0.18^{\circ}\text{C}$ ), aunque en ambos casos, la variabilidad capturada por el dron ( $\text{SD} = 2.29^{\circ}\text{C}$ ) fue notablemente superior a la del satélite ( $\text{SD} = 0.76^{\circ}\text{C}$ ). Estos resultados confirman que el efecto de atenuación de la variabilidad por parte del sensor satelital es un fenómeno fuerte y generalizable a lo largo de los distintos eventos de fuego estudiados.

**Tabla 14.** Estadísticos de las distribuciones de la Diferencia del LST por escala Dron (D) y Satélite (S).

IDPAF	Media D.	SD D.	Media S.	SD S.	# Obs
54.00	-0.24	1.97	0.42	0.51	107.00
62.00	-1.53	4.52	-0.03	0.77	140.00
63.00	2.71	3.79	0.28	1.24	116.00
64.00	2.19	5.31	0.93	1.17	121.00
65.00	0.53	2.78	0.16	0.41	79.00
75.00	0.61	3.18	0.41	0.61	66.00
90.00	-1.33	2.29	0.18	0.76	130.00
114.00	1.38	3.21	-0.11	0.63	148.00
124.00	0.42	5.21	0.66	0.33	94.00
149.00	5.62	4.77	-0.28	0.61	126.00
187.00	-0.07	5.27	0.09	1.30	65.00
192.00	-0.63	1.72	-0.84	0.75	150.00

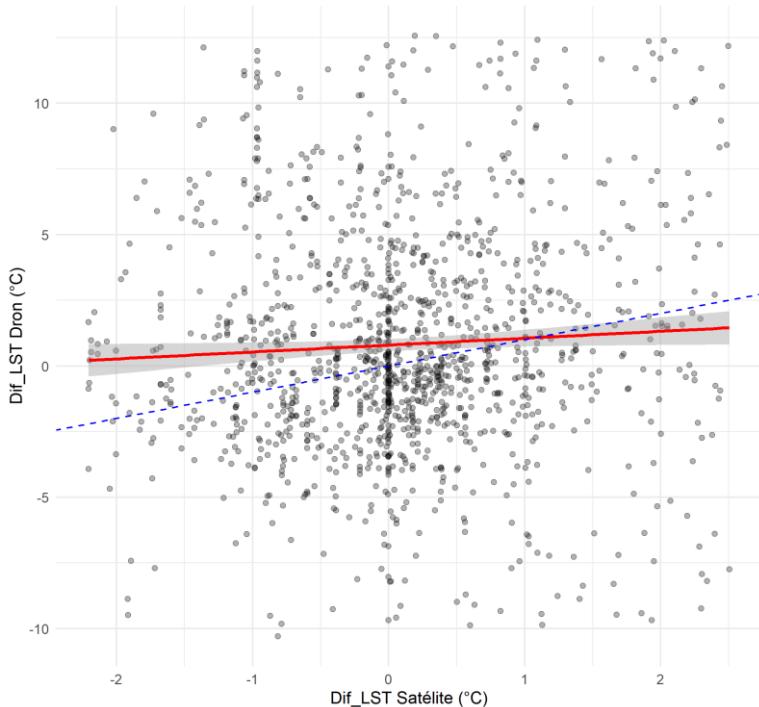
#### 4.5.2. Relación lineal entre las mediciones de ambos sensores.

Para cuantificar el grado de acoplamiento entre las mediciones, se realizó un análisis de correlación Tabla 15. Se obtuvo un coeficiente de Pearson de  $r = 0.057$ , que, a pesar de ser estadísticamente significativo ( $p = 0.037$ ), indica en la práctica la ausencia de una relación lineal relevante entre las mediciones de ambos sensores a nivel de punto. La Figura 22 confirma gráficamente este desacoplamiento, mostrando una nube de puntos dispersa y sin una tendencia lineal definida. Adicionalmente, se cuantificó un sesgo medio de  $-0.72^{\circ}\text{C}$ , confirmando que el satélite tiende a subestimar la magnitud de la anomalía térmica registrada por el dron.

**Tabla 15.** Análisis de correlación entre Satélite y Dron

Pearson	p valor	Sesgo medio	Sesgo mediana	SD sesgo
0.0569	0.0372	-0.7188	-0.1311	4.3479

Correlación entre Medición Satélite y Dron  
Correlación de Pearson = 0.06



**Figura 22.** Relación lineal entre las mediciones de Dif\_LST de satélite y dron. El gráfico de dispersión muestra los 1,342 pares de mediciones temporalmente pareadas. La línea roja representa el ajuste lineal (regresión) y la línea azul discontinua la relación 1:1. El bajo coeficiente de correlación de Pearson ( $r = 0.06$ ) indica un profundo desacoplamiento entre las mediciones de ambas escalas a nivel de punto.

#### 4.5.3. Modelado predictivo de la anomalía térmica a microescala.

Para evaluar la relación entre las mediciones y la influencia de los factores de control a microescala, se ajustó un Modelo Lineal Mixto (LMM). En este modelo, la Dif\_LST\_dron fue la variable respuesta, mientras que la Dif\_LST\_satelite y las variables topográficas derivadas del MDT de 2 metros actuaron como predictores. El objetivo no era crear un modelo predictivo, sino cuantificar el poder explicativo relativo de las variables de diferentes escalas espaciales.

La Tabla 16 resume los resultados de los coeficientes del modelo. El análisis revela que la única variable con un efecto estadísticamente significativo fue el NBR pre-incendio (PRE\_NBR\_z), con un coeficiente negativo ( $\beta = -0.59$ ,  $p = 0.003$ ). Es notable que ni la Dif\_LST\_satelite ( $p = 0.073$ ) ni ninguna de las variables topográficas de alta resolución ( $p > 0.1$  en todos los casos) resultaron ser predictores significativos de la anomalía térmica a microescala.

**Tabla 16.** Coeficientes del modelado predictivo a microescala.

Variable	Esti- mate	Std. Error	df	t value	Pr(> t )
(Intercept)	0.757	0.669	10.390	1.130	0.284
Dif_LST_satelite_z	0.217	0.121	1327.403	1.790	0.073
PRE_NBR_z	-0.587	0.195	867.772	-3.020	0.003
elevacion2m_z	0.226	0.430	74.140	0.530	0.601
pendiente2m_z	0.101	0.923	1326.719	0.110	0.913
expo_general2m_z	-0.960	0.613	1330.574	-1.570	0.117
tpi2m_z	-0.092	0.104	1324.086	-0.880	0.379
tri2m_z	-0.867	1.121	1325.127	-0.770	0.439

El análisis de la bondad de ajuste del modelo (Tabla 17) revela que los efectos fijos explicaron tan solo un 2.4% de la varianza ( $R^2$  marginal), mientras que el modelo completo, al incluir el efecto aleatorio por incendio (IDPAF), explicó un 28.4% de la varianza total ( $R^2$  condicional).

**Tabla 17.** Coeficientes del ajuste para el modelado predictivo a microescala.

Métrica	Valor
AIC	7447.498
BIC	7499.517
$R^2$ conditional	0.284
$R^2$ marginal	0.024
RMSE	3.767

## 5. DISCUSIÓN.

### 5.1. Dinámica temporal de la cicatriz térmica.

Los resultados del análisis de series temporales muestran un patrón de recuperación no lineal, consistente en las tres escalas analizadas. Se identifica una fase inicial de recuperación rápida, con una caída pronunciada de la Diferencia de LST durante los primeros 10-15 años, seguida de una fase de recuperación mucho más lenta y prolongada. Este comportamiento de dos fases es consistente con los procesos ecológicos posfuego. La rápida disminución inicial puede atribuirse a factores de primer orden como la colonización por vegetación pionera y cambios abruptos en las propiedades de la superficie, como la disipación de la capa de cenizas y las consiguientes modificaciones del albedo. La fase posterior, más lenta, reflejaría los procesos a largo plazo de la sucesión ecológica, como el cierre del dosel y el desarrollo de un suelo orgánico.

La magnitud de esta anomalía térmica no es constante a lo largo del año, sino que está fuertemente modulada por un patrón estacional, con máximos en verano y mínimos en invierno, como se ha determinado en el análisis exploratorio. Esta dinámica estacional, observada en otros estudios de LST y vegetación (Ahmed et al., 2024), se explica por la confluencia de dos factores que se exacerbaban durante el estío en el clima Mediterráneo.

En primer lugar, la mayor radiación solar incidente en verano magnifica el impacto térmico de cualquier diferencia biofísica residual entre la zona recuperada y la de control. Diferencias sutiles en el albedo, la estructura del dosel o la proporción de suelo desnudo, que pueden tener un efecto térmico menor en invierno, se traducen en un calentamiento diferencial mucho más pronunciado bajo la máxima insolación estival (Quattrochi & Luval, 1999).

En segundo lugar, y de forma crucial, el estrés hídrico característico del verano limita la capacidad de la vegetación para termorregularse. La capacidad de las plantas para enfriar la superficie mediante la evapotranspiración, un proceso fundamental para el balance energético (Ruelland & Zachowski, 2010), se ve reducida por la escasez de agua. Es plausible que la vegetación de las zonas de control, a menudo más madura y con sistemas radiculares más desarrollados, mantenga una mayor capacidad de transpiración que la vegetación más joven y estructuralmente más simple de las áreas en recuperación. Esta diferencia en la eficiencia del enfriamiento latente se acentúa en verano, contribuyendo de forma significativa al pico observado en la Dif\_LST.

### 5.2. Recuperación de la vegetación como actor principal de la recuperación térmica.

Los resultados del modelado estadístico ponen de manifiesto que la recuperación de la vegetación, medida a través de la Diferencia de NBR, es el factor explicativo más potente de la disminución de la anomalía térmica. El coeficiente fuertemente negativo y significativo de esta variable en todos los modelos explica que la regeneración de la biomasa es el principal agente de la normalización térmica. Este hallazgo se alinea con los principios biofísicos fundamentales: el restablecimiento de la cubierta vegetal

aumenta el sombreadimiento del suelo y, de forma crucial, reintroduce el enfriamiento por evapotranspiración, dos mecanismos clave que regulan el balance energético de la superficie (Veraverbeke et al., 2012). Esta relación inversa entre la temperatura superficial y la vegetación, medida a través de índices como el NDVI, es un principio fundamental en teledetección, ampliamente documentado no solo en contextos posfuego, sino también en estudios sobre cambios de uso del suelo y dinámica de paisajes (Jaiswal et al., 2023; Kumar et al., 2025). La capacidad de la vegetación para modular la LST es tan directa que la dinámica temporal de ambos parámetros a menudo muestra una fuerte correlación, como demuestran análisis recientes con datos de Sentinel-2 y Landsat (Ahmed et al., 2024).

### 5.3. Heterogeneidad entre incendios: la importancia de los factores locales.

Un hallazgo central de este estudio es la considerable heterogeneidad en las trayectorias de recuperación entre los 95 incendios analizados, ilustrada en los casos de estudio (Apartado 4.3.4). Esta variabilidad es cuantificada por los resultados de los modelos mixtos: la gran diferencia entre el  $R^2$  marginal (que explica entre un 9% y un 17% de la varianza) y el  $R^2$  condicional (que explica entre un 46% y un 68%) demuestra que las características idiosincráticas de cada incendio y de cada punto específico son el principal factor que determina la respuesta de la LST. Esto subraya que, si bien existen patrones generales, la trayectoria de recuperación de un incendio concreto está fuertemente condicionada por factores locales (topografía, condiciones climáticas posfuego, severidad local, intervenciones antrópicas, etc.), lo que valida la idoneidad de haber trabajado con un grupo extenso de incendios para separar las tendencias generales de los efectos locales. Este hallazgo es crucial, ya que se alinea con la visión de la ecología del paisaje que considera los procesos térmicos como fenómenos espacialmente heterogéneos, y no como promedios uniformes (Quattrochi & Luval, 1999). La persistencia o atenuación de una cicatriz térmica no depende únicamente de la recuperación de la biomasa, sino de un complejo entramado de factores locales que condicionan el balance energético a escala de ladera o incluso de parcela.

### 5.4. Efecto de la escala de observación: implicaciones del análisis dron vs. satélite.

El análisis entre las mediciones del dron y del satélite pone de manifiesto una profunda disfunción espacial, un concepto clave en la ecología del paisaje y la teledetección. El resultado más notable, la ausencia de una relación predictiva entre la LST satelital y la del dron, no debe interpretarse como una "falla" del sensor Landsat, sino como la cuantificación de la pérdida de información que ocurre al pasar de una escala métrica a una centimétrica. Más revelador aún es que, a pesar de su enorme diferencia de resolución, la medición satelital ( $p = 0.073$ ) se muestra como un predictor marginalmente más potente que cualquiera de las variables topográficas de alta resolución (2 m), las cuales no muestran ninguna capacidad explicativa ( $p > 0.1$ ).

El valor de un píxel de Landsat ( $900 \text{ m}^2$ ) es una abstracción, un promedio radiométrico de un mosaico de componentes (suelo, vegetación, sombras) que no tiene una correspondencia directa con un punto específico de 3 cm en el terreno, además de que se tiene que tener presente la volatilidad que se tiene en la LST a diferentes horas del día o entre días mismos, entre los productos de diferentes escalas espaciales contribuyendo a la falta de correlación. Si bien la heterogeneidad a microescala es demasiado alta para ser explicada por el promedio de  $900\text{m}^2$  del satélite, la información radiométrica de Landsat aún captura una señal térmica más relevante para el proceso que las características estáticas del terreno a 2m. Esto sugiere que la heterogeneidad térmica a una escala de centímetros, en un ecosistema post-recuperación, está gobernada por procesos a una escala aún más fina que la topografía del MDT, como la estructura 3D de la vegetación baja, la rugosidad del suelo o la distribución de la necromasa, factores que no fueron medidos en este estudio.

El único predictor significativo fue la "memoria o el legado del paisaje", representada por el PRE\_NBR. Este hallazgo, aparentemente paradójico (una variable de 30m predice un fenómeno de 3cm), apunta a un fuerte determinismo ecológico. Sugiere que el estado de la vegetación pre-incendio (un fenómeno a escala de paisaje) es un factor clave que condiciona la trayectoria de la sucesión posfuego, y es esta trayectoria la que, a su vez, define la estructura y la firma térmica del nuevo ecosistema a microescala décadas más tarde. En esencia, la historia del paisaje (un fenómeno a escala de paisaje)

demuestra tener más influencia en la micro-temperatura actual que las mediciones térmicas contemporáneas obtenidas a esa misma escala.

### **5.5. Fortalezas y limitaciones del estudio.**

La principal fortaleza de esta investigación reside en su aproximación regional, analizando un grupo de 95 incendios, lo que permite una mayor generalización de los resultados en comparación con los estudios de caso único. La aplicación de una metodología de emparejamiento de puntos y un análisis estadístico mediante modelos mixtos ha permitido separar y cuantificar los patrones generales de la variabilidad local.

Sin embargo, el estudio no está exento de limitaciones. En primer lugar, la *limpieza* de outliers, aunque metodológicamente se optó por un proceso normalizado, se trata de un procedimiento que podría haber atenuado la magnitud real de las anomalías estacionales. En segundo lugar, si bien el análisis comparativo entre dron y satélite se realizó sobre mediciones temporalmente pareadas, la naturaleza de "instantánea" de los datos del dron no permite derivar de ellos una tendencia de recuperación a largo plazo como la obtenida con las series temporales satelitales. Finalmente, aunque el poder explicativo de los modelos es considerable ( $R^2$  condicional > 46%), una parte importante de la variabilidad sigue sin ser explicada, lo que sugiere la influencia de otros factores no incluidos en este estudio, como las variables climáticas posfuego, la aplicación de tratamientos hidrológico-forestales o la dinámica hidro-geo-morfológica.

### **5.6. Futuras líneas de investigación.**

Los resultados de este trabajo abren numerosas líneas de investigación futuras. Sería de gran interés incorporar variables climáticas posfuego (precipitación, temperatura del aire) en los modelos para determinar su papel en la modulación de las trayectorias de recuperación. Asimismo, la aplicación de este flujo de trabajo a otras regiones de ecosistemas mediterráneos permitiría verificar la generalidad de los patrones aquí encontrados. Finalmente, la integración de datos de nuevos sensores satelitales con mayor resolución temporal y espacial, como Sentinel-2, podría refinar aún más la comprensión de la dinámica de la recuperación posfuego. Asimismo, el presente estudio ha puesto de manifiesto el desacoplamiento entre las mediciones a escala de paisaje y de microescala. Una futura línea de investigación de gran interés sería explorar modelos de fusión de datos (data fusion) que intenten predecir la distribución sub-píxel de la temperatura a partir de variables satelitales y topográficas, validando dichos modelos con datos de dron. Habiendo obtenido como resultado en este estudio que los predictores a escala de paisaje pierden poder explicativo a microescala, el siguiente paso lógico sería investigar qué variables medidas a escalas de detalle (ej. estructura de la vegetación derivada de LiDAR o del propio dron) sí pueden modelar eficazmente la heterogeneidad térmica a escala centimétrica. Esto podría abrir la puerta a la generación de mapas de heterogeneidad térmica a alta resolución para áreas extensas, superando las limitaciones logísticas de las campañas de vuelo.

## **6. CONCLUSIONES**

A partir del análisis realizado, se extraen las siguientes conclusiones principales en respuesta a los objetivos planteados:

- La anomalía térmica posfuego en los ecosistemas estudiados sigue una tendencia de recuperación no lineal, caracterizada por una disminución inicial muy rápida, seguida de proceso lento de estabilización a largo plazo.
- La recuperación de la vegetación (NBR) es el principal factor que impulsa esta normalización térmica, cuya magnitud está, a su vez, fuertemente modulada por un patrón estacional con máximos en verano.
- El análisis mediante modelos mixtos muestra que la trayectoria de normalización térmica presenta una alta heterogeneidad entre los distintos eventos de fuego. Además, se identifica la severidad del fuego y la elevación como los factores más determinantes, de tal modo que los incendios más severos y a mayor altitud se corresponden con las cicatrices térmicas más intensas y persistentes.
- La escala de observación es un factor crítico en la caracterización de la anomalía térmica. A escala de paisaje (30 m), el satélite registra una anomalía media atenuada y con baja variabilidad. Por el contrario, a microescala (3 cm), el dron revela una heterogeneidad espacial extrema, un mosaico de condiciones térmicas que es promediado y enmascarado por el sensor satelital.
- Con el análisis comparativo entre las diferentes escalas se ha encontrado un desacoplamiento intenso entre las mediciones, la medición LST Landsat en un día no constituye un predictor significativo de la LST a una escala centimétrica, esto incorporando las dificultades para la comparación entre las diferencias horarias, se puede evidenciar la limitación de usar datos de resolución a escala paisaje para inferir procesos de la superficie a escala centimétrica.
- La "memoria del paisaje", cuantificada a través del NBR pre-incendio, ha resultado ser un predictor más robusto de la cicatriz térmica a escala centimétrica que la propia medición térmica satelital contemporánea. Esto subraya la importancia de las condiciones iniciales en la determinación de la trayectoria eco-fisiológica posfuego.

## 7. GLOSARIO DE TÉRMINOS Y ACRÓNIMOS

- AIC (Criterio de Información de Akaike): Criterio estadístico utilizado para la selección de modelos. Permite comparar un conjunto de modelos candidatos y elegir aquel que ofrece el mejor equilibrio entre la bondad de ajuste y la complejidad (equilibrio).
- Cicatriz Térmica: Fenómeno que describe el incremento significativo y persistente de la Temperatura Superficial Terrestre (LST) en un área después de un incendio forestal, debido principalmente a cambios en el balance energético de la superficie.
- Diferencia de LST (Dif\_LST): Variable principal del estudio, calculada como la resta de la LST del punto de control a la del punto de incendio (LST\_Incendio - LST\_Control). Representa la anomalía térmica neta atribuible al fuego.
- Emparejamiento Ambiental: Metodología utilizada en este estudio para seleccionar, para cada punto de muestreo, un punto de control análogo basándose en la similitud de un conjunto de variables geoespaciales (topográficas y de vegetación).
- GEE (*Google Earth Engine*): Plataforma de computación en la nube de Google para el análisis de datos geoespaciales a escala planetaria. Ha sido la herramienta utilizada para la extracción de las series temporales de datos Landsat.
- IQR (Rango Intercuartílico): Medida estadística de dispersión que equivale a la diferencia entre el tercer cuartil (Q3) y el primer cuartil (Q1). Se ha utilizado para la detección robusta de valores atípicos.
- LMM (Modelo Lineal Mixto): Familia de modelos estadísticos utilizados para analizar datos con una estructura jerárquica o anidada (observaciones repetidas en el tiempo para diferentes puntos agrupados por incendio). Permiten separar los efectos fijos (generales) de los efectos aleatorios (específicos de cada grupo).
- LST (Temperatura Superficial Terrestre): Temperatura radiométrica de la "piel" de la superficie terrestre. Es un indicador clave del balance de energía y agua.
- MDT (Modelo Digital del Terreno): Representación vectorial de la superficie terrestre a partir de la cual se derivan variables topográficas como la elevación, la pendiente o la exposición.
- NBR (Índice Normalizado de Quemadura): Índice espectral calculado a partir de las bandas del Infrarrojo Cercano (NIR) y el Infrarrojo de Onda Corta (SWIR). Es sensible a la humedad de la vegetación y a la biomasa, siendo un indicador estándar de la severidad del fuego y la recuperación vegetal.
- Punto Gemelo / Punto de Control: Punto localizado en una zona no quemada, seleccionado por el algoritmo de emparejamiento por ser ambientalmente análogo a un punto de muestreo situado dentro de un incendio.
- R<sup>2</sup> Condicional: En un LMM, es el coeficiente de determinación que mide el porcentaje de la varianza explicado por los efectos fijos y los efectos aleatorios combinados.
- R<sup>2</sup> Marginal: En un LMM, es el coeficiente de determinación que mide el porcentaje de la varianza explicado únicamente por los efectos fijos del modelo.

## 8. BIBLIOGRAFIA

- Ahmed, A.Y., Ali, A.M., & Ahmed, N. (2024). "Temporal dynamics of leaf area index and land surface temperature correlation using Sentinel-2 and Landsat OLI data". *Environmental Systems Research*, 13, 43.
- Barbet-Massin, M., Jiguet, F., Albert, C. H., & Thuiller, W. (2012). "Selecting pseudo-absences for species distribution models: how, where and how many?". *Methods in Ecology and Evolution*, 3(2), pp. 327-338.
- Burnham, K. P., & Anderson, D. R. (2002). *Model selection and multimodel inference: a practical information-theoretic approach*. Springer-Verlag.
- Cuadrat, J. M., Saz, M. A., & Vicente-Serrano, S. M. (2007). *Atlas Climático de Aragón*. Gobierno de Aragón.
- Ezzaher, F. E., Ben Achhab, N., Raissouni, N., Naciri, H., & Chahboun, A. (2024). "Normalized Burn Ratio and Land Surface Temperature Pre- and Post-Mediterranean Forest Fires". *Environmental Sciences Proceedings*, 29, 3.
- Jaiswal, T., Jhariya, D., & Singh, S. (2023). "Spatio-temporal analysis of changes occurring in land use and its impact on land surface temperature". *Environmental Science and Pollution Research*, 30, 107199–107218.
- Koutsias, N., Panourgia, K., Nakas, G., & Petanidou, T. (2023). "The importance of landscape and fire-history as factors explaining short- and medium-term post-fire vegetation recovery in a Mediterranean island using Sentinel-2 satellite data". Preprint not peer reviewed, disponible en: <https://ssrn.com/abstract=4792001>.
- Kumar, H., Anand, S., Kumar, P., & Singh, S.K. (2025). "Analyzing the Changing Landscape Dynamics and Relation of Land Surface Temperature With Different Vegetation Indices Using Multi-Temporal Remote Sensing and Ai Techniques". *Geoscience Letters*.
- Kurbanov, E., Vorobev, O., Lezhnin, S., Sha, J., Wang, J., Li, X., Cole, J., Dergunov, D. y Wang, Y. (2022). "Remote Sensing of Forest Burnt Area, Burn Severity, and Post-Fire Recovery: A Review". *Remote Sensing*, 14, 4714.
- Li, Z.-L., Tang, B.-H., Wu, H., Ren, H., Yan, G., Wan, Z., Trigo, I.F. y Sobrino, J.A. (2013). "Satellite-derived land surface temperature: Current status and perspectives". *Remote Sensing of Environment*, 131, pp. 14-37.
- Li, Z.-L., Wu, H., Duan, S.-B., Zhao, W., Ren, H., Liu, X., et al. (2023). "Satellite Remote Sensing of Global Land Surface Temperature: Definition, Methods, Products, and Applications". *Reviews of Geophysics*, 61, e2022RG000777.
- Ministerio de Agricultura, Pesca y Alimentación. (2017). Mapa Forestal de España 1:200.000.
- Morante-Carballo, F., Bravo-Montero, L., Carrión-Mero, P., Velastegui-Montoya, A. y Berrezueta, E. (2022). "Forest Fire Assessment Using Remote Sensing to Support the Development of an Action Plan Proposal in Ecuador". *Remote Sensing*, 14, 1783.
- Pinheiro, J. C., & Bates, D. M. (2000). *Mixed-effects models in S and S-PLUS*. Springer.
- Quattrochi, D.A., & Luvall, J.C. (1999). "Thermal infrared remote sensing for analysis of landscape ecological processes: methods and applications". *Landscape Ecology*, 14, 577–598.
- Quintano, C., Fernández-Manso, A., Calvo, L. y Roberts, D.A. (2019). "Vegetation and Soil Fire Damage Analysis Based on Species Distribution Modeling Trained with Multispectral Satellite Data". *Remote Sensing*, 11, 1832.
- Riley, S. J., DeGloria, S. D., & Elliot, R. (1999). "A terrain ruggedness index that quantifies topographic heterogeneity". *Intermountain Journal of Sciences*, 5, pp. 23-27.
- Ruelland, E., & Zachowski, A. (2010). "How plants sense temperature". *Environmental and Experimental Botany*, 69, 225–232.
- Tukey, J. W. (1977). *Exploratory Data Analysis*. Addison-Wesley.

- VanDerWal, J., Shoo, L. P., Graham, C. y Williams, S. E. (2009). "Selecting pseudo-absence data for presence-only distribution modeling: How far should you stray from what you know?". Ecological Modelling, 220(4), pp. 589-594.
- Veraverbeke, S., Gitas, I., Katagis, T., Polychronaki, A., Somers, B. y Goossens, R. (2012). "Assessing post-fire vegetation recovery using red-near infrared vegetation indices: Accounting for background and vegetation variability". ISPRS Journal of Photogrammetry and Remote Sensing, 68, pp. 28-39.
- Vlassova, L., & Pérez-Cabello, F. (2016). "Effects of post-fire wood management strategies on vegetation recovery and land surface temperature (LST) estimated from Landsat images". International Journal of Applied Earth Observation and Geoinformation, 44, 171–183.
- Vlassova, L., Pérez-Cabello, F., Rodrigues Mimbrero, M., Montorio Lloverá, R. y García-Martín, A. (2014). "Analysis of the Relationship between Land Surface Temperature and Wildfire Severity in a Series of Landsat Images". Remote Sensing, 6, pp. 6136-6162.
- Weiss, A. D. (2001). "Topographic position and landforms analysis". Poster presentation, ESRI International User Conference, San Diego, CA.
- Zuur, A. F., Ieno, E. N., & Elphick, C. S. (2010). "A protocol for data exploration to avoid common statistical problems". Methods in Ecology and Evolution, 1(1), pp. 3-14.

## 9. ANEXOS

### ANEXO 1. Script R para la Generación de Puntos de Muestreo Satélite

```
# =====
=====
# SCRIPT UNIFICADO v2.0: GENERACIÓN DE PUNTOS DE MUESTREO EN ÁREAS
DE INCENDIO ÚNICAS
#
# - PARÁMETROS CONFIGURABLES PARA LOS NOMBRES DE LAS COLUMNAS.
# - 1. Identifica las porciones de cada incendio que NO se han
vuelto a quemar.
# - 2. Genera puntos de muestreo aleatorios únicamente dentro de
estas áreas "únicas".
# - 3. Se guardan los atributos de la capa original.
#
=====

# 1. LIBRERÍAS
library(sf)
library(dplyr)

# 2. CONFIGURACIÓN
ruta_gpkg    <-    "C:/MASTER_ERICK/TFM/Erick/SHP_TFM/TFM_ERICK_VIL-
LACIS.gpkg"

# --- A) NOMBRES DE CAPAS ---
# CAPA DE ENTRADA DE LOS INCENDIOS QUE SE VAN A ESTUDIAR.
nombre_capa_incendios <- "Areas_Incendio_Satelite"

# NOMBRE DE LA CAPA RESULTADO DEL PROCESO DE CRUCE DE AREAS EN
INCENDIOS
# RESULTADO "Solapada_posteriormente" y "Unica"
nombre_capa_areas_procesadas <- "Areas_Satelite"

# CAPA DE SALIDA FINAL DE LOS PUNTOS ALEATORIOS.
nombre_capa_puntos_salida <- "P_Muestra_Satelite"

# --- B) NOMBRES DE COLUMNAS (CAMPOS) ---
# COLUMNA DE IDENTIFICACION DEL CODIGO DEL INCENDIO
campo_id_incendio <- "IDPAF"

# COLUMNA QUE IDENTIFICA EL AÑO DEL INCENDIO
campo_fecha_incendio <- "Year"

# NOMBRE DE LA COLUMNA DONDE GUARDAR LOS RESULTADOS DEL PROCESO DE
SOLAPE
campo_tipo_area_salida <- "Tipo_Area"
```

```

# --- C) PARÁMETROS DE MUESTREO ---
#NUMERO DE PUNTOS A GENERAR POR KM2
puntos_por_km2 <- 20

# ¡IMPORTANTE! SEMILLA PARA REPRODUCIBILIDAD (EN CASO DOCUMENTAR).
# MANTÉN ESTE NÚMERO FIJO PARA OBTENER SIEMPRE LOS MISMOS PUNTOS.
# CAMBIA ESTE NÚMERO A CUALQUIER OTRO ENTERO PARA UNA NUEVA TANDADA.
set.seed(456)

# --- INICIO DEL PROCESO (NO MODIFICAR) ---

#
=====
# PASO 1: IDENTIFICAR ÁREAS ÚNICAS VS. SOLAPADAS
#
=====

message("PASO 1: Identificando áreas de incendio únicas...")

# LECTURA Y VALIDACIÓN DE DATOS
incendios_sf <- st_read(ruta_gpkg, layer = nombre_capa_incendios)

# Verificación de CRS
if (st_is_longlat(incendios_sf)) {
  stop("ERROR: El CRS debe ser proyectado.")
}

# Verificación de columnas
if (!campo_id_incendio %in% names(incendios_sf))
stop(paste("ERROR: La columna '", campo_id_incendio, "' no se encuentra."))
if (!campo_fecha_incendio %in% names(incendios_sf))
stop(paste("ERROR: La columna '", campo_fecha_incendio, "' no se encuentra."))

incendios_sf <- st_make_valid(incendios_sf)
# Se ordena por el campo de fecha para asegurar un procesamiento cronológico correcto.
incendios_sf <- incendios_sf %>% arrange (!!sym(campo_fecha_incendio))

# PROCESAMIENTO
lista_resultados <- list()
for (i in 1:nrow(incendios_sf)) {
  incendio_actual <- incendios_sf[i, ]

  message(paste0("      Procesando ID: ", incendio_actual[[campo_id_incendio]],
                " (Año: ", incendio_actual[[campo_fecha_incendio]], "... [",
                i, "/", nrow(incendios_sf), "]"))

  geom_actual <- st_geometry(incendio_actual)

  # Encuentra todos los incendios que ocurrieron después
}

```

```

incendios_posteriores <- incendios_sf %>%
  filter(!!sym(campo_fecha_incendio))           >      incendio_ac-
tual[[campo_fecha_incendio]])

if (nrow(incendios_posteriores) == 0) {
  incendio_actual[[campo_tipo_area_salida]] <- "Unica"
  lista_resultados[[length(lista_resultados) + 1]] <- incen-
dio_actual
  next
}

geom_posteriores_unidas <- st_union(st_geometry(incendios_poste-
riores))

area_unica <- st_difference(geom_actual, geom_posteriores_uni-
das)
area_solapada <- st_intersection(geom_actual, geom_posteri-
ores_unidas)

if (length(area_unica) > 0 && !st_is_empty(area_unica)) {
  poligono_unico <- incendio_actual
  st_geometry(poligono_unico) <- area_unica
  poligono_unico[[campo_tipo_area_salida]] <- "Unica"
  lista_resultados[[length(lista_resultados) + 1]] <- poli-
gono_unico
}

if (length(area_solapada) > 0 && !st_is_empty(area_solapada)) {
  poligono_solapado <- incendio_actual
  st_geometry(poligono_solapado) <- area_solapada
  poligono_solapado[[campo_tipo_area_salida]] <- "Solapada_Pos-
teriormente"
  lista_resultados[[length(lista_resultados) + 1]] <- poli-
gono_solapado
}

if (length(lista_resultados) == 0) {
  stop("ERROR: No se generó ningún polígono válido en el Paso 1.")
}
incendios_procesados_sf <- do.call(rbind, lista_resultados)
incendios_procesados_sf <- st_collection_extract(incendios_proce-
sados_sf, "POLYGON")

st_write(incendios_procesados_sf,
         dsn = ruta_gpkg,
         layer = nombre_capa_areas_procesadas,
         delete_layer = TRUE)
message(paste("\nCapa intermedia '", nombre_capa_areas_procesadas,
"' guardada."))

#
=====
```

```

# PASO 2: GENERAR PUNTOS SOLO EN ÁREAS ÚNICAS
#
=====
message("\nPASO 2: Generando puntos de muestreo solo en áreas 'Unica'...")

poligonos_unicos <- incendios_procesados_sf %>%
  filter(!sym(campo_tipo_area_salida) == "Unica")

if (nrow(poligonos_unicos) == 0) {
  stop("No se encontraron áreas de tipo 'Unica' para generar puntos.")
}

message(paste("Se encontraron", nrow(poligonos_unicos), "polígonos de área única."))

poligonos_con_puntos <- poligonos_unicos %>%
  mutate(
    area_km2 = as.numeric(st_area(.)) / 1e6,
    n_puntos = ceiling(area_km2 * puntos_por_km2)
  ) %>%
  mutate(n_puntos = if_else(n_puntos == 0, 1, n_puntos))

puntos_generados_sfc <- st_sample(
  poligonos_con_puntos,
  size = poligonos_con_puntos$n_puntos,
  type = "random"
)

puntos_finales_sf <- st_as_sf(puntos_generados_sfc) %>%
  st_join(poligonos_con_puntos, join = st_intersects)

message(paste("\nTotal de", nrow(puntos_finales_sf), "puntos de muestreo generados en áreas únicas."))

st_write(puntos_finales_sf,
         dsn = ruta_gpkg,
         layer = nombre_capa_puntos_salida,
         delete_layer = TRUE)

message(paste("\n;ÉXITO!"))
message(paste("La capa final '", nombre_capa_puntos_salida, "' ha sido guardada en:", sep=""))
message(ruta_gpkg)

```

## ANEXO 2. Script en R para la Generación de Puntos de Muestreo Dron.

```
# =====
# SCRIPT UNIFICADO: ÁREAS Y PUNTOS DE MUESTREO PARA MODO DRON
#
# 1. Crea huellas precisas para cada imagen de dron (solo píxeles con datos).
# 2. Particiona cada huella en zonas de "Incendio" y "Control".
# 3. Disuelve las geometrías resultantes por ID de incendio y tipo de zona.
# 4. Genera puntos de muestreo aleatorios dentro de estas áreas finales.
#
# =====
```

```
# 1. LIBRERÍAS
library(sf)
library(terra)
library(dplyr)
library(fs)

# 2. CONFIGURACIÓN
# DIRECCION A GPKG DEL PROYECTO
ruta_gpkg    <-  "C:/MASTER_ERICK/TFM/Erick/SHP_TFM/TFM_ERICK_VIL-LACIS.gpkg"

# --- A) NOMBRES DE CAPAS ---
# CAPA DE ENTRADA DEL AREA DE INCENDIOS
nombre_capa_incendios <- "Incendios_Completos"

# DIRECCION DE LA CARPETA CON LAS IMAGENES DE DRON
carpeta_dron_tifs <- "C:/MASTER_ERICK/TFM/Erick/termicas_dron"

# NOMBRE DE LA CAPA DE SALIDA PARA LAS AREAS DE CONTROL E INCENDIOS
nombre_capa_areas_salida <- "Areas_Dron"

# NOMBRE DE LA CAPA DE PUNTOS DE MUESTRA ALEATORIOS
nombre_capa_puntos_salida <- "P_Muestra_Dron"

# --- B) NOMBRES DE COLUMNAS ---
# NOMBRE DEL CAMPO DEL IDENTIFICADOR UNICO DEL INCENDIO
campo_id_incendio <- "IDPAF"

#NOMBRE DE LA COLUMNA DONDE SE VA A GUARDAR LA DIFERENCIA DE ZONAS
#PARA MANTENER CONCORDANCIA CON EL SCRIPT DE ENRIQUECIMIENTO Y CONTROL
#LOS RESULTADOS EN ESTE CAMPO SON 'Incendio' y 'Control'.
campo_zona_salida <- "zona_dron"
```

```

# --- C) PARÁMETROS DE MUESTREO ---
#NUMERO DE PUNTOS ALEATORIOS A GENERAR POR AREA DEL INCENDIO
#SE CONSIDERA DIFERENTE AL DE SATELITE QUE NUESTRO ESPACIO ES MAS
REDUCIDO
puntos_por_poligono_incendio <- 150

# ¡IMPORTANTE! SEMILLA PARA REPRODUCIBILIDAD (EN CASO DOCUMENTAR).
# MANTÉN ESTE NÚMERO FIJO PARA OBTENER SIEMPRE LOS MISMOS PUNTOS.
# CAMBIA ESTE NÚMERO A CUALQUIER OTRO ENTERO PARA UN NUEVO GRUPO.
set.seed(123)

# --- INICIO DEL PROCESO (NO MODIFICAR) ---

#
=====
# PASO 1 Y 2: CREAR, PARTICIONAR Y DISOLVER ÁREAS DE DRON
#
=====

message("PASO 1 & 2: Procesando y disolviendo áreas de Dron...")
incendios_sf <- st_read(ruta_gpkg, layer = nombre_capa_incendios)
incendios_sf <- st_make_valid(incendios_sf)
crs_original <- st_crs(incendios_sf)
incendios_unidos_sf <- st_union(incendios_sf)

lista_tifs <- dir_ls(carpeta_dron_tifs, regexp = "\\.tif$", ignore.case = TRUE)
if (length(lista_tifs) == 0) stop("No se encontraron ficheros.tif.")

lista_resultados_brutos <- list()

for (ruta_tif in lista_tifs) {
  nombre_fichero <- path_file(ruta_tif)
  message(paste(" Procesando:", nombre_fichero))

  raster_dron <- rast(ruta_tif)
  # Crea una huella precisa a partir de píxeles con datos
  huella_poligono_sf <- st_as_sf(as.polygons(raster_dron > -Inf,
dissolve = TRUE))
  huella_poligono_sf <- st_transform(huella_poligono_sf, crs =
crs_original)

  indice_cercano <- st_nearest_feature(huella_poligono_sf, incendios_sf)
  atributos_incendio_cercano <- st_drop_geometry(incendios_sf[indice_cercano, ])

  huella_conAttrs_sf <- st_sf(
    atributos_incendio_cercano,
    geometry = st_geometry(huella_poligono_sf)
  )
  huella_conAttrs_sf$origen_tif <- nombre_fichero
}

```

```

# Particionar en Incendio y Control
area_incendio <- st_intersection(huella_con_attrs_sf, incendios_unidos_sf)
if (nrow(area_incendio) > 0 && !st_is_empty(area_incendio)) {
  area_incendio[[campo_zona_salida]] <- "Incendio"
  lista_resultados_brutos[[length(lista_resultados_brutos) + 1]] <- area_incendio
}

area_control <- st_difference(huella_con_attrs_sf, incendios_unidos_sf)
if (nrow(area_control) > 0 && !st_is_empty(area_control)) {
  area_control[[campo_zona_salida]] <- "Control"
  lista_resultados_brutos[[length(lista_resultados_brutos) + 1]] <- area_control
}

if (length(lista_resultados_brutos) == 0) stop("No se generaron polígonos válidos.")
resultado_bruto_sf <- bind_rows(lista_resultados_brutos)
resultado_bruto_sf <- st_collection_extract(st_make_valid(resultado_bruto_sf), "POLYGON")

areas_finales_sf <- resultado_bruto_sf %>%
  group_by (!!sym(campo_id_incendio), !!sym(campo_zona_salida)) %>%
  summarise(geometry = st_union(geometry), origenes_tif =
  paste(unique(origen_tif), collapse = ", "), .groups = 'drop')

areas_a_guardar <- st_cast(areas_finales_sf, "MULTIPOLYGON")

print(st_geometry_type(areas_a_guardar, by_geometry = FALSE))

st_write(
  areas_a_guardar,
  dsn = ruta_gpkg,
  layer = nombre_capa_areas_salida,
  delete_layer = TRUE
)

message(paste("\nCapa de áreas '", nombre_capa_areas_salida, "' (Incendio y Control) guardada."))

#
=====
# PASO 3: GENERAR PUNTOS DE MUESTREO SOLO EN ZONAS DE INCENDIO
#
=====
message("\nPASO 3: Generando puntos de muestreo solo en polígonos de 'Incendio'...")

# Se filtra para quedarse solo con las zonas de incendio ---

```

```

poligonos_incendio_dron <- areas_finales_sf %>%
  filter(!sym(campo_zona_salida) == "Incendio")

if (nrow(poligonos_incendio_dron) == 0) {
  stop("No se encontraron áreas de tipo 'Incendio' para generar puntos.")
}

message(paste("Se encontraron", nrow(poligonos_incendio_dron),
"polígonos de incendio para el muestreo."))

# Se asigna el número fijo de puntos a cada polígono de incendio.
poligonos_con_n_puntos <- poligonos_incendio_dron %>%
  mutate(n_puntos = puntos_por_poligono_incendio)

message(paste("Generando", puntos_por_poligono_incendio, "puntos en cada uno de los",
nrow(poligonos_con_n_puntos), "polígonos de incendio..."))

message(paste("Total a generar:", sum(poligonos_con_n_puntos$n_puntos),
"puntos."))

# Genera los puntos aleatorios.
puntos_generados_sfc <- st_sample(
  poligonos_con_n_puntos,
  size = poligonos_con_n_puntos$n_puntos,
  type = "random"
)

# Asigna los atributos de los polígonos de incendio a los puntos
puntos_finales_sf <- st_as_sf(puntos_generados_sfc) %>%
  st_join(poligonos_con_n_puntos, join = st_intersects)

message(paste("\nTotal de", nrow(puntos_finales_sf), "puntos de incendio generados."))

# Guarda la capa final de puntos
st_write(puntos_finales_sf,
  dsn = ruta_gpkg,
  layer = nombre_capa_puntos_salida,
  delete_layer = TRUE)

message(paste("\n;ÉXITO!"))
message(paste("La capa final de puntos '", nombre_capa_puntos_salida,
"' ha sido guardada en:", sep=""))
message(ruta_gpkg)

```

**ANEXO 3.** Script en R para la Generación de Puntos de Control gemelos para el análisis de escala “Dron” y “Satélite”

```
#=====
===== # SCRIPT UNIFICADO v12.5: ENRIQUECIMIENTO Y GENERACIÓN DE PUNTOS
DE CONTROL
#
# - SELECCIÓN DE BANDAS ESPECÍFICAS EN RÁSTERS (ÚNICOS O EN CAR-
PETA) .
# - OBTENCION DE DATOS ESPECIFICOS RASTER POR INCENDIO
# - SIMPLIFICACION POR CONVENCIONES.
# - SEPARACIÓN LÓGICA COMPLETA DE PARÁMETROS PARA MODO "SATELITE"
Y "DRON".
# - MODO SATELITE GENERA UN BUFFER CON SEPARACIÓN DEL AREA.
# - FILTRADO AVANZADO POR TOLERANCIAS ABSOLUTAS.
# - INTERRUPTOR DE RIGOR PARA VARIABLES DISCRETAS.
# - LIMPIEZA AUTOMÁTICA DE ARCHIVOS TEMPORALES.
# - OBTENCION DE PUNTOS DE CONTROL COMPARADOS POR PUNTOS DE MUESTRA
# - OPCION DE VERIFICAR PRIMERO EN EL DISCO POR PRODUCTOS TERRA
#
===== # 1. CARGAR LAS LIBRERÍAS NECESARIAS
library(sf)
library(raster) #MANEJO DE LOS RASTER ESPECIFICOS DE INCENDIO
library(terra)
library(dplyr)
library(tidyr) # NECESARIA PARA NA OMIT(), ELIMINANDO LA PROBLEMÁ-
TICA QUE SE GENERABA
library(fs)      # MANEJAR LAS RUTAS DE ARCHIVOS

# --- PASO 1: CONFIGURACIÓN CENTRAL (EL ÚNICO LUGAR PARA MODIFICA-
CIONES) ---

# --- A) CONFIGURACIÓN DEL ENTORNO ---
Sys.setenv(PROJ_LIB = "") # ARREGLA EL ERROR DE NO RECONOCER LOS
SCR

#PARA LOS PROCESAMIENTOS DE TERRA SE REQUIERE UN ESPACIO CONSI-
DERABLE SI ES BASTANTE INFORMACION SE PUEDE UTILIZAR UN DISCO EXTERNO
ruta_temporal <- "E:/Temporal/terra_temp"

#SE CREA LA CARPETA EN CASO DE NO TENERLA, ESTIPULAMOS QUE SEA
LA CARPETA TEMPORAL PARA TERRA
if (!dir.exists(ruta_temporal)) dir.create(ruta_temporal, recursive = TRUE)
terraOptions(tempdir = ruta_temporal)

# (OPCIONAL) RUTA A UNA CARPETA RÁPIDA CON DERIVADOS YA CALCULADOS
('materialized_...').
```

```

# SI EL SCRIPT ENCUENTRA LOS ARCHIVOS AQUÍ, LOS LEERÁ DESDE ESTA
UBICACIÓN DE ALTA VELOCIDAD (EJ. UN SSD).
# SI SE DEJA COMO NULL O NO EXISTE, EL SCRIPT BUSCARÁ/ESCRIBIRÁ
SOLO EN LA 'RUTA_TEMPORAL'
ruta_productos_terra <- "C:/MASTER_ERICK/TFM/Erick/Temporal/te-
rra_temp"

# --- B) GESTIÓN DEL GEOPACKAGE Y CAPAS---
# RUTA A LA GPKG DEL TRABAJO
ruta_gpkg_central <- "C:/MASTER_ERICK/TFM/Erick/SHP_TFM/TFM_ER-
ICK_VILLACIS.gpkg"

# RUTA A LA CARPETA VIRTUAL PARA EL PROCESAMIENTO DEL MDT Y SUS
DERIVADOS VIRTUALES
ruta_trabajo_virtual <- "C:/MASTER_ERICK/TFM/Erick/Temporal/VRT"

#SE CREA LA CARPETA EN CASO DE NO TENERLA
if (!dir.exists(ruta_trabajo_virtual)) dir.create(ruta_tr-
abajo_virtual, recursive = TRUE)

# CAPA DE PUNTOS DE INCENDIO A ENRIQUECER
capa_puntos_entrada <- "P_Muestra_Dron"

# PARÁMETRO PARA MODO "DRON": CAPA CON POLÍGONOS DE INCENDIO Y
CONTROL DEBE CONTENER EL CAMPO "zona_dron"
capa_zonas_dron <- "Areas_Dron"

# PARÁMETRO PARA MODO "SATELITE": CAPA CON PERÍMETROS DE INCEN-
DIOS PARA EXCLUIRLOS
capa_exclusion_satelite <- "Incendios_Completos"

# --- C) LISTA ÚNICA DE RECETAS DE EXTRACCIÓN---
# EL NOMBRE DE LA COLUMNA DE SALIDA SERÁ EL MISMO QUE EL NOMBRE
DE LA RECETA (EJ. 'ELEVACION2M').
# ADVERTENCIA: AL EXPORTAR A SHAPEFILE, NOMBRES > 10 CARACTERES
SERÁN TRUNCADOS.
# SE RECOMIENDA USAR GPKG.
# tolerancia_abs DEFINE EL RANGO ACEPTABLE DE LA VARIABLE A ANA-
LISAR.

# --- TIPOS DE RECETA DISPONIBLES ---
# "raster": PARA RÁSTERS ESTÁTICOS Y GLOBALES (EJ. MDT)
O BANDAS ESPECÍFICAS DE UN ARCHIVO.
# "derivado_raster": PARA DERIVADOS TOPOGRÁFICOS ESTÁNDAR DE 'TE-
RRA' (SLOPE, TPI, TRI, ASPECT).
# "derivado_multishade": TIPO ESPECIALIZADO. GENERA UN ÍNDICE DE
EXPOSICIÓN GENERAL PROMEDIANDO
# CUATRO ILUMINACIONES NORMALIZADAS (NO, NE,
SE, SO) PARA UN ANÁLISIS
# TOPOGRÁFICO MÁS ROBUSTO Y SIN SESGO
DIRECCIONAL.
# "vector_dis": PARA CAPAS VECTORIALES CON DATOS DISCRE-
TOS/CATEGÓRICOS (EJ. USOS DEL SUELO).

```

```

# "vector_con": PARA CAPAS VECTORIALES CON DATOS CONTINUOS
(NO IMPLEMENTADO EN EL EJEMPLO).
# "raster_dinamico_por_id": PARA RÁSTERS QUE SON ESPECÍFICOS PARA
CADA PUNTO DE MUESTRA
# (EJ. UNA IMAGEN PRE_NBR PARA CADA INCENDIO).
REQUIERE CONFIGURACIÓN ADICIONAL.

# --- PARÁMETROS ADICIONALES PARA RECETAS DE TIPO "RASTER" (ES-
TÁTICO) ---
# banda_numero: SELECCIONA UNA BANDA POR SU POSICIÓN NUMÉRICA
EXACTA (EJ. BANDA_NUMERO = 8).
# banda_patron_nombre: BUSCA Y SELECCIONA UNA BANDA POR SU NOM-
BRE.
# - PUEDE BUSCAR UNA PARTE DEL NOMBRE (EJ. "TEMP" ENCONTRARÁ
"TEMPERATURA_MEDIA").
# - SI ENCUENTRA VARIAS BANDAS QUE COINCIDEN, SIEMPRE SELE-
CIONARÁ LA PRIMERA.

# PARÁMETROS ADICIONALES PARA RECETAS "raster_dinamico_por_id" --
-

# ESTE TIPO DE RECETA CARGA UN RÁSTER ESPECÍFICO PARA CADA PUNTO
USANDO
# EL PARÁMETRO 'patron_nombre_archivo'. ESTE PARÁMETRO CONSTRUYE
EL
# NOMBRE DEL ARCHIVO A PARTIR DE DOS TIPOS DE INSTRUCCIONES:
# 1. tipo_parte = "columna_valor": Usa el valor de una columna
del punto
# (ej. list(tipo_parte="columna_valor", nombre_co-
lumna="IDPAF")).

# 2. tipo_parte = "texto_fijo": Añade un texto estático
# (ej. list(tipo_parte="texto_fijo", va-
lor_texto="_preNBR_season.tif")).

# EL SCRIPT UNIRÁ ESTAS PARTES EN ORDEN PARA ENCONTRAR EL ARCHIVO
CORRESPONDIENTE.

lista_recetas <- list(
  elevacion2m = list(
    tipo = "raster",
    grupo = "topografia_2m",
    ruta = "C:/MASTER_ERICK/TFM/Erick/MDE/MDT02m/MDT02_Vir-
tual_HU30.vrt",
    tolerancia_abs = 20 #VALOR +/- QUE CONSIDERA TOLERABLE
  ),
  pendiente2m = list(
    tipo = "derivado_raster",
    grupo = "topografia_2m",
    nombre_receta_mdt_fuente = "elevacion2m",
    opciones_terrain = list(v = "slope", unit = "degrees"),
    tolerancia_abs = 10
  ),
  expo_general2m = list(
    tipo = "derivado_multishade",
    grupo = "topografia_2m",
    nombre_receta_mdt_fuente = "elevacion2m",

```

```

#ELIMINAMOS LAS OPCIONES YA QUE IDENTIFICAMOS POR DEFECTO CUA-
TRO DIRECCIONES
tolerancia_abs = 0.05 # La tolerancia será sobre un valor de 0
a 1.
),
tpi2m = list(
    tipo = "derivado_raster",
    grupo = "topografia_2m",
    nombre_receta_mdt_fuente = "elevacion2m",
    opciones_terrain = list(v = "TPI"),
    tolerancia_abs = 1 # El TPI suele tener valores pequeños, ej -
5 a 5
),
tri2m = list(
    tipo = "derivado_raster",
    grupo = "topografia_2m",
    nombre_receta_mdt_fuente = "elevacion2m",
    opciones_terrain = list(v = "TRI"),
    tolerancia_abs = 0.5
),
PRE_NBR = list(
    tipo = "raster_dinamico_por_id",
    grupo = "NBR",
    ruta = "C:/MASTER_ERICK/TFM/Erick/NBR CRS CORREGIDO",
    tolerancia_abs = 0.1, # VALOR +/- QUE CONSIDERA TOLERABLE
    patron_nombre_archivo = list(
        list(tipo_parte = "columna_valor", nombre_columna =
"IDPAF"),
        list(tipo_parte = "texto_fijo", valor_texto =
"_preNBR_season.tif")
    )
)
),
# --- EJEMPLO: CÓMO AÑADIR LA 'ORIENTACIÓN' (ASPECT) ---
# orientacion2m = list(
#     tipo = "derivado_raster",
#     grupo = "topografia_2m",
#     nombre_receta_mdt_fuente = "elevacion2m",
#     opciones_terrain = list(v = "aspect", unit = "degrees"),
#     tolerancia_abs = 22.5 # Opcional: filtro estricto de +/- 22.5
grados de diferencia
# ),
#COD_CLC = list(
#tipo = "vector_dis",
#grupo = "coberturas",
#ruta = ruta_gpkg_central,
#layer_en_fuente = "clc_18_aragon",
#columna_origen = "CODE_18N"
# ),
# --- EJEMPLO: CÓMO AÑADIR OTRA CAPA VECTORIAL DISCRETA (ej.
Geología) ---
# cod_geologia = list(
#     tipo = "vector_dis",
#     grupo = "geologia", # Grupo nuevo si tiene extensión diferente

```

```

#     ruta = "C:/Ruta/A/Tu/Geopackage_Geologia.gpkg",
#     layer_en_fuente = "mapa_geologico_10k",
#     columna_origen = "LITO_COD"
# ),

# --- NUEVO EJEMPLO: SELECCIONAR BANDA POR NÚMERO DE UN ÚNICO
ARCHIVO .TIF ---
# nir_s2 = list(
#   tipo = "raster",
#   grupo = "reflectancia", # SE CREA UN NUEVO GRUPO PARA ESTOS
DATOS
#   ruta = "C:/DATOS/SATELITE/S2_escena_completa.tif", # RUTA A
UN ÚNICO TIF MULTIBANDA
#   banda_numero = 8 # SELECCIONA LA BANDA 8 (POR EJEMPLO, EL
INFRARROJO CERCANO)
# ),

# --- NUEVO EJEMPLO: SELECCIONAR BANDA POR PATRÓN DE NOMBRE EN
UNA CARPETA DE TIFS ---
# # ESTE ES EL CASO MÁS POTENTE: BUSCARÁ EN CADA TIF DE LA CARPETA
LA BANDA QUE CUMPLA EL PATRÓN.
# precipitacion_anual = list(
#   tipo = "raster",
#   grupo = "clima",
#   ruta = "C:/DATOS/CLIMA/PRECIPITACIONES/", # RUTA A UNA CARPETA
CON VARIOS TIFS
#   banda_patron_nombre = "pre" # BUSCARÁ DENTRO DE CADA TIF UNA
BANDA CUYO NOMBRE CONTENGA "pre" Y LAS UNIRÁ EN UN MOSAICO VIRTUAL
# ), # RECORDAR QUITAR LA COMA EN CASO DE QUE ESTA SEA LA ÚLTIMA
RECETA DE LA LISTA.

# --- D) PARÁMETROS DEL ALGORITMO Y MODO---

# 1. SELECCIÓN DEL MÉTODO DE BÚSQUEDA DE PUNTOS DE CONTROL "DRON",
"SATELITE"
MODO_CONTROL <- "DRON"

# 2. PARÁMETROS GENERALES Y DE CONTROL

# ¡IMPORTANTE! SEMILLA PARA REPRODUCIBILIDAD (EN CASO DOCUMENTAR).
# MANTÉN ESTE NÚMERO FIJO PARA OBTENER SIEMPRE LOS MISMOS PUNTOS.
# CAMBIA ESTE NÚMERO A CUALQUIER OTRO ENTERO PARA UNA NUEVA
TANDADA.
set.seed(123)

# TAMAÑO DEL LOTE PARA EL ENRIQUECIMIENTO INICIAL (PROCESO 1).
AJUSTA SEGÚN LA MEMORIA RAM DISPONIBLE.
tamano_lote_inicial <- 20000

# NÚMERO DE PUNTOS CANDIDATOS A GENERAR POR CADA ZONA DE CONTROL
(DRON O SATELITE).
puntos_candidatos_a_generar <- 20000

```

```

# TAMAÑO DEL LOTE PARA PROCESAR LA NUBE DE PUNTOS CANDIDATOS.
tamano_lote_candidatos <- 2000000

# 3. PARÁMETROS DE IDENTIFICACIÓN Y RIGOR
# NOMBRE EXACTO DE LA COLUMNA DEL CÓDIGO ÚNICO DEL INCENDIO.
ID_POLIGONO_INCENDIO <- "IDPAF"

# SI ES TRUE, SÓLO ACEPTA GEMELOS CON VARIABLES DISCRETAS IDÉNTICAS.
EXIGIR_IGUALDAD_DISCRETA <- TRUE

# 4. PARÁMETROS ESPECÍFICOS PARA EL MODO "SATELITE"
# RADIO INICIAL (EN METROS) DEL ANILLO DE SEPARACION CON EL AREA DE INVESTIGACION.
buffer_inicial_m <- 50

# RADIO MÁXIMO (EN METROS) QUE ALCANZARÁ LA BÚSQUEDA ANTES DE RENDIRSE.
buffer_maximo_m <- 3000

# 5. COSAS A CONSIDERAR
# - ID DE PUNTO ÚNICO GENERADO SE NOMBRARA LA COLUMNA 'ID_Punto'.
# - PARA MODO DRON, LA COLUMNA EN LA CAPA DE POLIGONOS DEBE LLAMARSE 'zona_dron'
#     Y CONTENER LOS VALORES DE 'Incendio' y 'Control'.

# --- E) SELECCION DE PROCESOS A CUMPLIR (TRUE, FALSE) ---
EJECUTAR_ENRIQUECIMIENTO <- TRUE
EJECUTAR_GENERACION_CONTROL <- TRUE

#
=====

# --- PASO 2: GENERACIÓN DE NOMBRES Y FUNCIONES (NO MODIFICAR) --
-
#
=====

capa_puntos_salida_enriquecidos <- paste0(capa_puntos_entrada,
"_enriquecidos")
capa_salida_control <- paste0(capa_puntos_entrada, "_control")
.cache_fuentes <- new.env()

preparar_fuentes_datos <- function(recetas, ruta_vrt) {
  if (!is.null(.cache_fuentes$datos)) {return(.cache_fuentes$datos)}
  pilas_raster_por_grupo <- list(); fuentes_vector_por_grupo <-
  list()
  grupos_de_capas <- unique(sapply(recetas, `[[`, "grupo"))

  for (grupo_actual in grupos_de_capas) {
    
```

```

recetas_del_grupo <- Filter(function(x) x$grupo == grupo_actual, recetas)
nombres_recetas_grupo <- names(recetas_del_grupo)
tipo_grupo <- recetas_del_grupo[[1]]$tipo

if (tipo_grupo %in% c("raster", "derivado_raster", "derivado_multishade")) {
  fuentes_raster_en_memoria <- list()

  for (nombre_receta in nombres_recetas_grupo) {
    receta_actual <- recetas_del_grupo[nombre_receta];
    capa_raster_final <- NULL

    if (receta_actual$tipo == "raster") {

      seleccionar_banda_de_raster <- function(raster_obj, receta) {
        if (!is.null(receta$banda_numero)) {
          n_banda <- receta$banda_numero
          if (n_banda > 0 && n_banda <= nlyr(raster_obj)) {
            return(raster_obj[[n_banda]])
          } else {
            warning(paste("En", sources(raster_obj), "el nº de banda",
              n_banda, "está fuera de rango. Se omite el archivo."))
            return(NULL)
          }
        }
        else if (!is.null(receta$banda_patron_nombre)) {
          patron <- receta$banda_patron_nombre
          nombres_bandas <- names(raster_obj)
          indices_coincidentes <- grep(patron, nombres_bandas)

          if (length(indices_coincidentes) >= 1) {
            if (length(indices_coincidentes) > 1) {
              warning(paste("En", sources(raster_obj), "se encontraron múltiples bandas con patrón '", patron, "'. Usando la primera: '", nombres_bandas[indices_coincidentes[1]], "'"))
            }
            return(raster_obj[[indices_coincidentes[1]]])
          } else {
            warning(paste("En", sources(raster_obj), "no se encontró banda con patrón '", patron, "'. Se omite el archivo."))
            return(NULL)
          }
        }
      }
      if (nlyr(raster_obj) > 1) {
        warning(paste("Receta '", nombre_receta, "' apunta a un raster multibanda ('", sources(raster_obj), "') pero no especifica banda a seleccionar. Se usará la primera por defecto."))
      }
      return(raster_obj[[1]])
    }

    ruta_fuente <- receta_actual$ruta
  }
}

```

```

        ruta_vrt_final <- file.path(ruta_vrt, paste0(nombre_receta, ".vrt"))

        if (file.exists(ruta_vrt_final)) {
            capa_raster_final <- rast(ruta_vrt_final)
        } else {
            if (dir.exists(ruta_fuente)) {
                lista_tifs <- list.files(ruta_fuente, pattern =
"\\.tif$", full.names = TRUE, ignore.case = TRUE)
                if (length(lista_tifs) > 0) {
                    print(paste("-> Procesando", length(lista_tifs),
"TIFs en la carpeta para la receta:", nombre_receta))
                    lista_bandas_seleccionadas <- list()
                    for (tif_path in lista_tifs) {
                        raster_individual <- rast(tif_path)
                        banda_seleccionada <- seleccionar_banda_de_raster(raster_individual, receta_actual)
                        if (!is.null(banda_seleccionada)) {
                            lista_bandas_seleccionadas <- append(
                                lista_bandas_seleccionadas, banda_seleccionada)
                        }
                    }
                    if (length(lista_bandas_seleccionadas) > 0) {
                        capa_raster_final <- vrt(lista_bandas_seleccionadas,
                            ruta_vrt_final, overwrite = TRUE)
                    } else {
                        warning(paste("No se pudo extraer ninguna banda
válida de la carpeta para la receta:", nombre_receta))
                    }
                }
            } else if (file.exists(ruta_fuente)) {
                print(paste("-> Procesando archivo único para la re-
ceta:", nombre_receta))
                raster_completo <- rast(ruta_fuente)
                capa_raster_final <- seleccionar_banda_de_raster(raster_completo, receta_actual)
            }
        }

    } else if (receta_actual$tipo %in% c("derivado_raster",
"derivado_multishade")) {
        fuente_mdt <- fuentes_raster_en_memoria[[receta_ac-
tual$nombre_receta_mdt_fuente]]
        if (is.null(fuente_mdt)) {warning(paste("Fuente MDT no
encontrada para", nombre_receta)); next}

        nombre_archivo_materializado <- paste0("materialized_",
nombre_receta, ".tif")

        ruta_leitura_rapida <- if (!is.null(ruta_productos_te-
rra) && dir.exists(ruta_productos_terra)) {
            file.path(ruta_productos_terra, nombre_archivo_mat-
erializado)
        } else { NULL }

```

```

        ruta_lectura_escritura_temporal <- file.path(terraOpti-
ons()$tempdir, nombre_archivo_materializado)

        if (!is.null(ruta_lectura_rapida)) &&
file.exists(ruta_lectura_rapida)) {
            print(paste("    -> Leyendo derivado desde la RUTA RÁ-
PIDA:", nombre_receta))
            capa_raster_final <- rast(ruta_lectura_rapida)
        } else if (file.exists(ruta_lectura_escritura_temporal)) {
            print(paste("    -> Leyendo derivado desde la RUTA TEM-
PORAL:", nombre_receta))
            capa_raster_final <- rast(ruta_lectura_escritura_tem-
poral)
        } else {
            print(paste("    -> Derivado no encontrado. GENERANDO y
guardando en la RUTA TEMPORAL:", nombre_receta))
            capa_derivada <- NULL

            if (receta_actual$tipo == "derivado_raster") {
                if (!is.null(receta_actual$opciones_terrain)) {
                    args <- c(list(x = fuente_mdt), receta_actual$op-
ciones_terrain); capa_derivada <- do.call(terra::terrain, args)
                }
            } else if (receta_actual$tipo == "derivado_multi-
shade") {
                slope_rad <- terra::terrain(fuente_mdt, v="slope",
unit="radians")
                aspect_rad <- terra::terrain(fuente_mdt, v="aspect",
unit="radians")
                # GENERACIOND 4 HILLSHADES EN DIFERENTES DIRECCIONES
PARA SU EXPOSICION.
                h1 <- terra::shade(slope_rad, aspect_rad, angle=45,
direction=315)
                h2 <- terra::shade(slope_rad, aspect_rad, angle=45,
direction=45)
                h3 <- terra::shade(slope_rad, aspect_rad, angle=45,
direction=135)
                h4 <- terra::shade(slope_rad, aspect_rad, angle=45,
direction=225)
                promedio_hillshade <- (h1 + h2 + h3 + h4) / 4
                capa_derivada <- promedio_hillshade / 255.0
            }

            if(!is.null(capa_derivada)) {
                writeRaster(capa_derivada, ruta_lectura_escri-
tura_temporal, gdal=c("COMPRESS=LZW"), overwrite=TRUE)
                capa_raster_final <- rast(ruta_lectura_escri-
tura_temporal)
            }
        }
    }
}

```

```

        if (!is.null(capa_raster_final)) {fuentes_raster_en_memoria[[nombre_receta]] <- capa_raster_final}
    }

    if (length(fuentes_raster_en_memoria) > 0) {
        pila_raster_objetos <- rast(fuentes_raster_en_memoria);
names(pila_raster_objetos) <- names(fuentes_raster_en_memoria)
        pilas_raster_por_grupo[[grupo_actual]] <- pila_raster_objetos
    }

} else if (tipo_grupo %in% c("vector_dis", "vector_con")) {
    fuentes_vector_grupo <- list()
    for(nombre_receta in nombres_recetas_grupo){
        receta_actual <- recetas_del_grupo[[nombre_receta]]
        capa_vec <- st_read(receta_actual$ruta, layer = receta_actual$layer_en_fuente, quiet = TRUE)
        fuentes_vector_grupo[[nombre_receta]] <- capa_vec %>%
            select (!!sym(receta_actual$columna_origen), "geom") %>%
            rename (!!sym(nombre_receta) := !!sym(receta_actual$columna_origen))
    }
    fuentes_vector_por_grupo[[grupo_actual]] <- fuentes_vector_grupo
}
}

.cache_fuentes$datos <- list(pilas_raster = pilas_raster_por_grupo, fuentes_vector = fuentes_vector_por_grupo)
return(.cache_fuentes$datos)
}

#
=====
=====

# FUNCIÓN enriquecer_puntos
#
=====

enriquecer_puntos <- function(puntos_sf, fuentes_preparadas, todas_las_recetas) {
    if(nrow(puntos_sf) == 0) return(puntos_sf)

    # Creamos una lista para almacenar los data.frames de nuevos atributos
    lista_nuevos_atributos <- list()

    # --- PASO A: ENRIQUECIMIENTO CON RÁSTERS ESTÁTICOS (terra) ---
    message("... enriqueciendo con variables estáticas (terra).")
    for (grupo in names(fuentes_preparadas$pilas_raster)) {
        receta_ejemplo <- todas_las_recetas[[names(fuentes_preparadas$pilas_raster)[[grupo]]][1]]]
        if (receta_ejemplo$tipo %in% c("raster", "derivado_raster",
"derivado_multishade")) {

```

```

pila_raster <- fuentes_preparadas$pilas_raster[[grupo]]
puntos_para_extract <- puntos_sf
if (st_crs(puntos_para_extract) != st_crs(pila_raster)) {
  puntos_para_extract <- st_transform(puntos_para_extract,
st_crs(pila_raster))
}
valores_extraidos_df <- terra::extract(pila_raster,
vect(puntos_para_extract), ID = FALSE, na.rm = TRUE)
lista_nuevos_atributos[[length(lista_nuevos_atributos) + 1]] <- valores_extraidos_df
}

# --- PASO B: ENRIQUECIMIENTO CON RÁSTERS DINÁMICOS (raster) --
recetas_dinamicas <- Filter(function(x) x$tipo == "raster_dinamico_por_id", todas_las_recetas)

if(length(recetas_dinamicas) > 0) {
  message("    ... enriqueciendo con variables dinámicas (raster).")

  for(nombre_receta in names(recetas_dinamicas)) {
    receta_actual <- recetas_dinamicas[[nombre_receta]]
    valores_resultados_dinamicos <- rep(NA_real_, nrow(puntos_sf))

    for(i in 1:nrow(puntos_sf)) {
      punto_actual_sf <- puntos_sf[i, ]

      nombre_archivo_a_buscar <- ""
      for(parte in receta_actual$patron_nombre_archivo) {
        if(parte$tipo_parte == "texto_fijo"){
          nombre_archivo_a_buscar <- paste0(nombre_archivo_a_buscar, parte$valor_texto)
        } else if(parte$tipo_parte == "columna_valor"){
          df_sin_geom <- st_drop_geometry(punto_actual_sf)
          if (!parte$nombre_columna %in% names(df_sin_geom)) {
            nombre_archivo_a_buscar <- ""
            break
          }
          valor_columna <- df_sin_geom[, parte$nombre_columna,
drop = TRUE]
          if(is.na(valor_columna)) { nombre_archivo_a_buscar <-
""; break }
          nombre_archivo_a_buscar <- paste0(nombre_archivo_a_buscar, as.character(valor_columna))
        }
      }
      if(nombre_archivo_a_buscar == "") next

      ruta_completa <- file.path(receta_actual$ruta, nombre_archivo_a_buscar)
    }
  }
}

```

```

        if (file.exists(ruta_completa)) {
            raster_especifico <- raster::raster(ruta_completa)
            valor_extraido <- raster::extract(raster_especifico,
punto_actual_sf)
                if (!is.null(valor_extraido) && !is.na(valor_extraido))
{
                    valores_resultados_dinamicos[i] <- valor_extraido
                }
            }
        df_dinamico_temp <- data.frame(valores_resultados_dinamicos)
names(df_dinamico_temp) <- nombre_receta
lista_nuevos_atributos[[length(lista_nuevos_atributos) + 1]]
<- df_dinamico_temp
    }
}

# --- ENSAMBLAJE FINAL Y SEGURO ---
df_todos_atributos_nuevos <- do.call(cbind, lista_nuevos_atributos)

if (ncol(st_drop_geometry(puntos_sf)) > 0) {
    puntos_enriquecidos_final <- st_sf(
        cbind(st_drop_geometry(puntos_sf), df_todos_atributos_nuevos),
        geometry = st_geometry(puntos_sf)
    )
} else {
    # Esto ocurre con los puntos candidatos que nacen sin atributos
    puntos_enriquecidos_final <- st_sf(df_todos_atributos_nuevos,
geometry = st_geometry(puntos_sf))
}

# --- PASO C: ENRIQUECIMIENTO CON VECTORES (CÓDIGO COMPLETO) ---

if (length(fuentes_preparadas$fuentes_vector) > 0) {
    for (grupo in names(fuentes_preparadas$fuentes_vector)) {
        for (nombre_receta in names(fuentes_preparadas$fuentes_vector[[grupo]])) {
            message(paste("    ... enriqueciendo con capa vectorial:", nombre_receta))
            capa_vectorial_fuente <- fuentes_preparadas$fuentes_vector[[grupo]][[nombre_receta]]

            # Asegurarse de que los CRS coincidan antes del join
            if (st_crs(puntos_enriquecidos_final) != st_crs(capa_vectorial_fuente)) {
                capa_vectorial_fuente <- st_transform(capa_vectorial_fuente, st_crs(puntos_enriquecidos_final))
            }

            # Realizar la unión espacial (spatial join) para añadir los
atributos del vector

```

```

        puntos_enriquecidos_final <- st_join(puntos_enriquecidos_final, capa_vectorial_fuente, join = st_intersects, left = TRUE)
    }
}

return(puntos_enriquecidos_final)
}

# --- PASO 3: EJECUCIÓN DE PROCESOS ---
if (EJECUTAR_ENRIQUECIMIENTO) {
  print("====")
  print("INICIANDO PROCESO 1: ENRIQUECIMIENTO DE PUNTOS")
  print("====")
  puntos_originales <- st_read(ruta_gpkg_central, layer = capa_puntos_entrada)
  fuentes_de_datos <- preparar_fuentes_datos(lista_recetas, ruta_trabajo_virtual)
  print("--- ENRIQUECIENDO LOS PUNTOS DE INCENDIO ORIGINALES POR LOTES... ---")

  lista_lotes_enriquecidos <- list()
  total_puntos <- nrow(puntos_originales)

  for (lote_inicio in seq(1, total_puntos, by = tamano_lote_inicial)) {
    lote_fin <- min(lote_inicio + tamano_lote_inicial - 1, total_puntos)
    print(paste("    -> Procesando lote de puntos:", lote_inicio, "a", lote_fin, "de", total_puntos))
    puntos_del_lote <- puntos_originales[lote_inicio:lote_fin, ]
    lote_enriquecido <- enriquecer_puntos(puntos_del_lote, fuentes_de_datos, lista_recetas)
    lista_lotes_enriquecidos[[length(lista_lotes_enriquecidos) + 1]] <- lote_enriquecido
  }
  puntos_finales_enriquecidos <- do.call(rbind, lista_lotes_enriquecidos)
  puntos_finales_enriquecidos <- puntos_finales_enriquecidos %>%
  mutate(ID_Punto = row_number())
  print("--- VERIFICACIÓN DE LA TABLA DE ATRIBUTOS FINAL ---")
  print(head(as.data.frame(puntos_finales_enriquecidos)))
  st_write(puntos_finales_enriquecidos, dsn = ruta_gpkg_central, layer = capa_puntos_salida_enriquecidos, delete_layer = TRUE)
  print(paste("¡PROCESO 1 COMPLETADO! CAPA GUARDADA COMO:", capa_puntos_salida_enriquecidos))
}

if (EJECUTAR_GENERACION_CONTROL) {
  print("====")
  print("INICIANDO PROCESO 2: GENERACIÓN DE PUNTOS DE CONTROL")
  print("====")

# --- PREPARACIÓN INICIAL ---

```

```

    puntos_incendio_enriquecidos <- st_read(ruta_gpkg_central, layer
= capa_puntos_salida_enriquecidos)
    if (!exists("fuentes_de_datos")) {fuentes_de_datos <- preparar_fuentes_datos(lista_recetas, ruta_trabajo_virtual)}

    # --- PASO 2A: GENERAR PUNTOS CANDIDATOS DENTRO DE CADA ZONA DE CONTROL INDIVIDUAL ---
    print("--- Generando puntos candidatos por cada zona de control individual ---")
    lista_candidatos_por_zona <- list()
    if (MODO_CONTROL == "DRON") {
        zonas_de_control <- st_read(ruta_gpkg_central, layer =
capa_zonas_dron) %>% filter(zona_dron == "Control")
        if (nrow(zonas_de_control) == 0) stop("No se encontraron zonas con 'zona_dron' = 'Control'.")
        for (i in 1:nrow(zonas_de_control)) {
            zona_actual <- zonas_de_control[i, ]
            id_incendio_asociado <- zona_actual[[ID_POLIGONO_INCENDIO]]
            print(paste(" -> Generando candidatos para la zona de control del incendio:", id_incendio_asociado))
            candidatos_zona <- st_sample(zona_actual, size = puntos_candidatos_a_generar, type = "random", exact = FALSE)
            if (length(candidatos_zona) > 0) {
                candidatos_sf <- st_as_sf(candidatos_zona)
                candidatos_sf[[ID_POLIGONO_INCENDIO]] <- id_incendio_asociado
                lista_candidatos_por_zona[[length(lista_candidatos_por_zona) + 1]] <- candidatos_sf
            }
        }
    } else if (MODO_CONTROL == "SATELITE") {
        poligonos_incendios_originales <- st_read(ruta_gpkg_central,
layer = capa_exclusion_satelite)
        area_total_exclusion <- st_union(poligonos_incendios_originales)
        for (i in 1:nrow(poligonos_incendios_originales)) {
            poligono_actual <- poligonos_incendios_originales[i, ]
            id_incendio_asociado <- poligono_actual[[ID_POLIGONO_INCENDIO]]
            print(paste(" -> Generando candidatos en el anillo de búsqueda para el incendio:", id_incendio_asociado))
            buffer_exterior <- st_buffer(poligono_actual, dist =
buffer_maximo_m)
            buffer_interior_colchon <- st_buffer(poligono_actual, dist =
buffer_inicial_m)
            anillo_de_busqueda <- st_difference(buffer_exterior,
buffer_interior_colchon)
            area_de_busqueda_final <- st_difference(anillo_de_busqueda,
area_total_exclusion)
            if (!st_is_empty(area_de_busqueda_final) &&
all(st_is_valid(area_de_busqueda_final, na.rm=TRUE))) {
                candidatos_zona <- st_sample(area_de_busqueda_final, size =
puntos_candidatos_a_generar, type = "random", exact = FALSE)
                if (length(candidatos_zona) > 0) {

```

```

        candidatos_sf <- st_as_sf(candidatos_zona)
        candidatos_sf[[ID_POLIGONO_INCENDIO]] <- id_incen-
dio_asociado
        lista_candidatos_por_zona[[length(lista_candida-
tos_por_zona) + 1]] <- candidatos_sf
    }
}
}
candidatos_globales_sf <- do.call(rbind, lista_candida-
tos_por_zona)
if(is.null(candidatos_globales_sf) || nrow(candidatos_globa-
les_sf) == 0) {
    stop("No se pudo generar ningún punto candidato en ninguna
zona. El proceso no puede continuar.")
}

# --- PASO 2B: ENRIQUECER LA MEGA-TABLA DE CANDIDATOS ---
print(paste("--- Enriqueciendo la nube global de", nrow(candida-
tos_globales_sf), "candidatos por lotes ---"))
lista_lotes_enriquecidos <- list()
for (lote_inicio in seq(1, nrow(candidatos_globales_sf), by =
tamano_lote_candidatos)) {
    lote_fin <- min(lote_inicio + tamano_lote_candidatos - 1,
nrow(candidatos_globales_sf))
    print(paste("          ... procesando lote de candidatos:",
lote_inicio, "a", lote_fin))
    candidatos_lote <- candidatos_globa-
les_sf[lote_inicio:lote_fin, ]
    lista_lotes_enriquecidos[[length(lista_lotes_enriquecidos) + 1]] <- enriquecer_puntos(candidatos_lote, fuentes_de_datos, lista_re-
cetas)
}
candidatos_enriquecidos <- do.call(rbind, lista_lotes_enriqueci-
dos)
candidatos_enriquecidos <- candidatos_enriquecidos %>% na.omit()
print(paste("--- Nube global enriquecida con", nrow(candida-
tos_enriquecidos), "puntos válidos ---"))

# --- PASO 2C: PREPARACIÓN PARA LA COMPARACIÓN---
print("--- Preparando datos para la comparación inteligente
(cálculo de rangos globales) ---")
nombres_variables_comparacion <- names(lista_recetas)
datos_completos_para_rangos <- rbind(
    st_drop_geometry(puntos_incendio_enriquecidos)[, nombres_va-
riables_comparacion],
    st_drop_geometry(candidatos_enriquecidos)[, nombres_varia-
bles_comparacion]
)

rangos_globales <- lapply(datos_completos_para_rangos, fun-
ction(columna) {
    list(min = min(columna, na.rm = TRUE), max = max(columna, na.rm =
TRUE))
})

```

```

    }

normalize_global <- function(x, var_name) {
  rango <- rangos_globales[[var_name]]
  if (rango$max - rango$min == 0) return(0)
  return((x - rango$min) / (rango$max - rango$min))
}

# --- PASO 2D: BUCLE DE BÚSQUEDA DE GEMELOS---
lista_puntos_control_final <- list()
ids_unicos_incendios_muestra <- unique(puntos_incendio_enriquecidos[[ID_POLIGONO_INCENDIO]])

for (id_actual in ids_unicos_incendios_muestra) {
  print(paste("--- Buscando gemelos para el incendio:", id_actual, "---"))
  candidatos_del_incendio <- candidatos_enriquecidos %>% filter(!sym(ID_POLIGONO_INCENDIO) == id_actual)
  if (nrow(candidatos_del_incendio) == 0) {
    warning(paste("    -> No hay candidatos válidos para el incendio", id_actual, ". Saltando."))
    next
  }

  puntos_del_incendio_actual <- puntos_incendio_enriquecidos %>% filter(!sym(ID_POLIGONO_INCENDIO) == id_actual)
  for (j in 1:nrow(puntos_del_incendio_actual)) {
    punto_actual <- puntos_del_incendio_actual[j, ]

    # FASE 1: FILTRO DURO POR TOLERANCIA
    candidatos_filtrados <- candidatos_del_incendio
    nombres_col_con_tolerancia <- names(Filter(function(r) !is.null(r$tolerancia_abs), lista_recetas))
    for (col_nombre in nombres_col_con_tolerancia) {
      valor_actual <- punto_actual[[col_nombre]]
      tolerancia <- lista_recetas[[col_nombre]]$tolerancia_abs
      candidatos_filtrados <- candidatos_filtrados %>% filter(abs(.data[[col_nombre]]) - valor_actual) <= tolerancia
    }

    if (nrow(candidatos_filtrados) == 0) {
      next
    }

    # FASE 2: RANKING POR DISTANCIA EUCLIDIANA (SOBRE LOS MISMOS DATOS, NORMALIZADOS GLOBALMENTE)
    distancias <- rep(0, nrow(candidatos_filtrados))
    for(var_name in nombres_variables_comparacion) {
      norm_punto <- normalize_global(punto_actual[[var_name]], var_name)
      norm_candidatos <- normalize_global(candidatos_filtrados[[var_name]], var_name)
      distancias <- distancias + (norm_punto - norm_candidatos)^2
    }
  }
}

```

```

distancias <- sqrt(distancias)

mejor_candidato_idx <- which.min(distancias)
mejor_candidato_final <- candidatos_filtrados[mejor_candidato_idx, ]

    mejor_candidato_final[["ID_Punto"]]           <- punto_actual[["ID_Punto"]]
    lista_puntos_control_final[[length(lista_puntos_control_final) + 1]] <- mejor_candidato_final
}
}

# --- PASO 2E: ENSAMBLAJE FINAL ---
if(length(lista_puntos_control_final) > 0) {
    puntos_control_a_guardar <- do.call(rbind, lista_puntos_control_final)
    puntos_control_a_guardar$Tipo <- "Control"
    print("---- COMPILANDO Y GUARDANDO RESULTADOS FINALES... ----")
    st_write(puntos_control_a_guardar, dsn = ruta_gpkg_central,
layer = capa_salida_control, delete_layer = TRUE)

print("=====")
=====)
    print(paste("; PROCESO 2 COMPLETADO! SE GENERARON", nrow(puntos_control_a_guardar), "PUNTOS DE CONTROL VÁLIDOS."))
    print(paste("LA CAPA '", capa_salida_control, "' SE HA GUARDADO EN:", ruta_gpkg_central))

print("=====")
=====)
} else {
    print("ADVERTENCIA: NO SE PUDO GENERAR NINGÚN PUNTO DE CONTROL CON EL MODO Y PARÁMETROS SELECCIONADOS.")
}
}

# --- PASO FINAL: LIMPIEZA EXPLÍCITA DE ARCHIVOS TEMPORALES ---
# DESCOMENTAR SI SE REQUIERE ELIMINAR LOS TIF GENERADOS
##print("=====")
##print("INICIANDO LIMPIEZA DE ARCHIVOS TEMPORALES...")
##archivos_temporales <- list.files(path = terraOptions()$tempdir,
pattern = "\\.tif$", full.names = TRUE, ignore.case = TRUE)
##if (length(archivos_temporales) > 0) {
##    print(paste("Se encontraron", length(archivos_temporales),
"archivos temporales para eliminar:"))
##    print(basename(archivos_temporales))
##    eliminados <- file.remove(archivos_temporales)
##    if (all(eliminados)) {
##        print("; TODOS LOS ARCHIVOS TEMPORALES HAN SIDO ELIMINADOS CORRECTAMENTE!")
##    } else {
##        warning("NO SE PUDIERON ELIMINAR TODOS LOS ARCHIVOS TEMPORALES. REVISA LA CARPETA MANUALMENTE.")

```

```
##  }
##} else {
##  print("No se encontraron archivos temporales .tif para eliminar.")
##}
print("===== ")
print("¡FLUJO DE TRABAJO COMPLETADO!")
```

**ANEXO 4.** Tabla de éxito de emparejamiento por incendio.

IDPAF	P. Muestra	P. Control	% Éxito
53	133.00	133.00	100.00
56	29.00	29.00	100.00
54	193.00	179.00	92.75
55	73.00	70.00	95.89
66	214.00	210.00	98.13
61	75.00	72.00	96.00
65	20.00	9.00	45.00
64	87.00	87.00	100.00
62	340.00	340.00	100.00
58	75.00	75.00	100.00
63	103.00	102.00	99.03
59	85.00	85.00	100.00
60	356.00	354.00	99.44
67	72.00	72.00	100.00
68	54.00	54.00	100.00
69	130.00	128.00	98.46
70	44.00	44.00	100.00
72	27.00	27.00	100.00
73	113.00	111.00	98.23
74	96.00	96.00	100.00
75	60.00	59.00	98.33
80	143.00	142.00	99.30
82	58.00	58.00	100.00
83	23.00	23.00	100.00
86	36.00	36.00	100.00
79	62.00	62.00	100.00
84	24.00	20.00	83.33
89	48.00	47.00	97.92
90	255.00	253.00	99.22
87	28.00	28.00	100.00
88	332.00	331.00	99.70
91	18.00	18.00	100.00
92	143.00	143.00	100.00
94	213.00	211.00	99.06
93	330.00	328.00	99.39
98	42.00	42.00	100.00
101	970.00	969.00	99.90
104	43.00	41.00	95.35
110	374.00	374.00	100.00
97	13.00	13.00	100.00
105	37.00	37.00	100.00
106	90.00	90.00	100.00
107	85.00	72.00	84.71
96	276.00	274.00	99.28
99	2953.00	2905.00	98.37
113	133.00	133.00	100.00
103	244.00	244.00	100.00
108	1.00	1.00	100.00

100	98.00	92.00	93.88
102	16.00	16.00	100.00
114	585.00	585.00	100.00
115	36.00	36.00	100.00
118	56.00	56.00	100.00
119	112.00	112.00	100.00
117	40.00	40.00	100.00
120	24.00	24.00	100.00
121	31.00	31.00	100.00
123	55.00	55.00	100.00
124	497.00	488.00	98.19
122	13.00	13.00	100.00
125	42.00	42.00	100.00
126	54.00	53.00	98.15
128	51.00	51.00	100.00
129	106.00	106.00	100.00
131	20.00	20.00	100.00
133	121.00	118.00	97.52
132	13.00	13.00	100.00
136	79.00	79.00	100.00
134	55.00	55.00	100.00
138	21.00	21.00	100.00
143	273.00	272.00	99.63
147	298.00	298.00	100.00
149	334.00	334.00	100.00
165	231.00	231.00	100.00
167	110.00	110.00	100.00
157	30.00	29.00	96.67
151	144.00	144.00	100.00
169	1188.00	1183.00	99.58
158	1286.00	1273.00	98.99
159	186.00	185.00	99.46
163	110.00	110.00	100.00
160	37.00	37.00	100.00
161	239.00	238.00	99.58
177	38.00	38.00	100.00
184	56.00	56.00	100.00
182	11.00	11.00	100.00
187	663.00	662.00	99.85
190	22.00	22.00	100.00
193	21.00	20.00	95.24
192	1234.00	1232.00	99.84
195	20.00	20.00	100.00
196	25.00	25.00	100.00
194	25.00	25.00	100.00
197	26.00	26.00	100.00
201	23.00	23.00	100.00
TOTAL:	18108.00	17941.00	99.08

**ANEXO 5.** Tabla de retención de observaciones por incendio.

IDPAF	DIARIO			Mensual			Anual		
	Inicio	Pares finales	% éxito	Inicio	Pares finales	% éxito	Inicio	Pares finales	% éxito
53	27340	7587	55.50	116053	53451	92.11	10906	5155	94.54
54	38178	10372	54.33	156190	69650	89.19	14678	6953	94.74
55	5869	2250	76.67	56578	26643	94.18	5740	2773	96.62
56	5533	1692	61.16	25284	11809	93.41	2378	1127	94.79
58	12808	5148	80.39	65298	31035	95.06	6000	2919	97.30
59	7588	3048	80.34	66695	31473	94.38	6800	3304	97.18
60	46223	15019	64.98	289022	133006	92.04	28320	13657	96.45
61	15157	4603	60.74	62096	28970	93.31	5760	2783	96.63
62	25006	9235	73.86	239867	109268	91.11	27200	13094	96.28
63	10173	3185	62.62	73195	31200	85.25	8160	3743	91.74
64	18772	5635	60.04	76181	36095	94.76	6960	3388	97.36
65	2220	579	52.16	7875	3738	94.93	720	350	97.22
66	50911	13302	52.26	180157	83330	92.51	16800	8115	96.61
67	13842	5176	74.79	61305	29023	94.68	5616	2723	96.97
68	4780	1802	75.40	37908	16597	87.56	4212	1885	89.51
69	27328	8038	58.83	102777	46912	91.29	9984	4773	95.61
70	7390	1704	46.12	32623	15388	94.34	3344	1624	97.13
72	5852	1778	60.77	19403	8737	90.06	1998	966	96.70
73	11005	4415	80.24	75391	34927	92.66	8214	3955	96.30
74	19264	7568	78.57	75007	35804	95.47	6912	3357	97.14
75	15339	4207	54.85	45051	20981	93.14	4248	2058	96.89
79	5496	2238	81.44	40812	18969	92.96	4340	2072	95.48
80	21922	5481	50.00	95451	44398	93.03	9940	4763	95.84
82	11154	4245	76.12	44164	21060	95.37	4060	1966	96.85
83	5539	1604	57.92	17303	8170	94.43	1610	776	96.40
84	1791	758	84.65	12532	5853	93.41	1400	677	96.71
86	5394	2070	76.75	25293	11726	92.72	2520	1213	96.27
87	3207	1343	83.75	19781	9464	95.69	1960	951	97.04
88	66429	20488	61.68	242688	106586	87.84	23170	10847	93.63
89	9824	3308	67.35	34430	15917	92.46	3290	1575	95.74
90	23827	9090	76.30	159390	73264	91.93	17710	8522	96.24
91	1759	708	80.50	11456	5438	94.94	1188	573	96.46
92	24978	9513	76.17	103254	48605	94.15	9438	4557	96.57
93	29141	10044	68.93	212085	95704	90.25	21648	10291	95.08
94	17643	5200	58.95	127168	54792	86.17	13926	6409	92.04
96	47044	18183	77.30	190201	88315	92.86	17536	8273	94.35
97	879	386	87.83	7500	3502	93.39	832	400	96.15
98	3189	1200	75.26	24663	11601	94.08	2688	1300	96.73
99	305029	97341	63.82	1856213	823820	88.76	185919	87252	93.86
100	21401	6742	63.01	64204	30353	94.55	5888	2835	96.30
101	192233	40443	42.08	631485	282134	89.36	62016	29451	94.98
102	1188	456	76.77	8938	4138	92.59	1024	494	96.48
103	53786	12027	44.72	165885	77221	93.10	15616	7505	96.12
104	10334	2611	50.53	28694	13360	93.12	2624	1243	94.74
105	2963	1160	78.30	22386	10301	92.03	2368	1107	93.50
106	7653	2816	73.59	53945	24985	92.63	5760	2734	94.93

107	8316	3062	73.64	47440	22255	93.82	4608	2200	95.49
108	168	66	78.57	699	330	94.42	64	31	96.88
110	81569	22371	54.85	257590	119500	92.78	23936	11399	95.25
113	35883	9615	53.59	95101	44653	93.91	8512	4082	95.91
114	111541	42401	76.03	395843	186142	94.05	36270	17226	94.99
115	5514	2301	83.46	19701	9313	94.54	2016	971	96.33
117	16108	3812	47.33	22176	10309	92.97	2080	986	94.81
118	22451	5622	50.08	31174	14405	92.42	2912	1382	94.92
119	15201	5070	66.71	54712	24860	90.88	5824	2766	94.99
120	2909	991	68.13	11911	5575	93.61	1248	599	95.99
121	4237	1441	68.02	15580	7305	93.77	1612	775	96.15
122	1610	672	83.48	6169	2953	95.74	650	310	95.38
123	11454	4413	77.06	28851	13289	92.12	2750	1300	94.55
124	178680	40871	45.75	266057	119121	89.55	24400	11362	93.13
125	13490	3865	57.30	22961	10704	93.24	2100	997	94.95
126	16147	3672	45.48	27453	12712	92.61	2544	1210	95.13
128	10737	3270	60.91	25089	11366	90.61	2346	1099	93.69
129	20608	7388	71.70	53451	24747	92.60	4876	2320	95.16
131	2002	790	78.92	8278	3825	92.41	880	418	95.00
132	2263	796	70.35	6139	2828	92.13	572	272	95.10
133	22060	7655	69.40	56244	26296	93.51	5192	2465	94.95
134	4954	1854	74.85	21494	9727	90.51	2310	1074	92.99
136	14371	4739	65.95	36056	16696	92.61	3318	1562	94.15
138	4330	1232	56.91	8560	3970	92.76	840	398	94.76
143	54288	18944	69.79	118943	55536	93.38	10880	5157	94.80
147	36497	14171	77.66	111184	50819	91.41	11324	5301	93.62
149	69654	24563	70.53	131687	59868	90.92	12024	5515	91.73
151	33202	11517	69.38	55114	25657	93.11	4896	2287	93.42
157	4848	1603	66.13	10399	4658	89.59	986	455	92.29
158	141809	49190	69.38	431458	188758	87.50	43282	19820	91.59
159	18362	6304	68.66	58807	25583	87.01	6290	2738	87.06
160	11170	2869	51.37	14168	6586	92.97	1258	588	93.48
161	31946	10731	67.18	84518	38547	91.22	8092	3802	93.97
163	13627	5208	76.44	39446	18191	92.23	3740	1758	94.01
165	42667	12170	57.05	85813	38785	90.39	7854	3584	91.27
167	11563	4159	71.94	36858	16283	88.36	3740	1696	90.70
169	227319	65000	57.19	444659	201249	90.52	40222	18675	92.86
177	9616	3564	74.13	12685	5962	94.00	1140	528	92.63
182	3294	1309	79.48	3411	1612	94.52	308	143	92.86
184	16060	6286	78.28	17581	8224	93.56	1568	727	92.73
187	94425	35426	75.04	182291	80765	88.61	18536	8446	91.13
190	7677	2754	71.75	6546	3061	93.52	572	264	92.31
192	540045	150920	55.89	308242	140895	91.42	27104	12296	90.73
193	9543	2755	57.74	4956	2268	91.53	440	200	90.91
194	12860	3145	48.91	5602	2494	89.04	500	222	88.80
195	7626	2625	68.84	4598	2062	89.69	400	180	90.00
196	4656	1842	79.12	5240	2290	87.40	500	222	88.80
197	5108	1990	77.92	5458	2456	90.00	520	234	90.00
201	8651	3114	71.99	3519	1598	90.82	322	138	85.71

**ANEXO 6.** Tabla de las Diferencias del LST por escala y año transcurrido por el evento (year\_since\_fire)

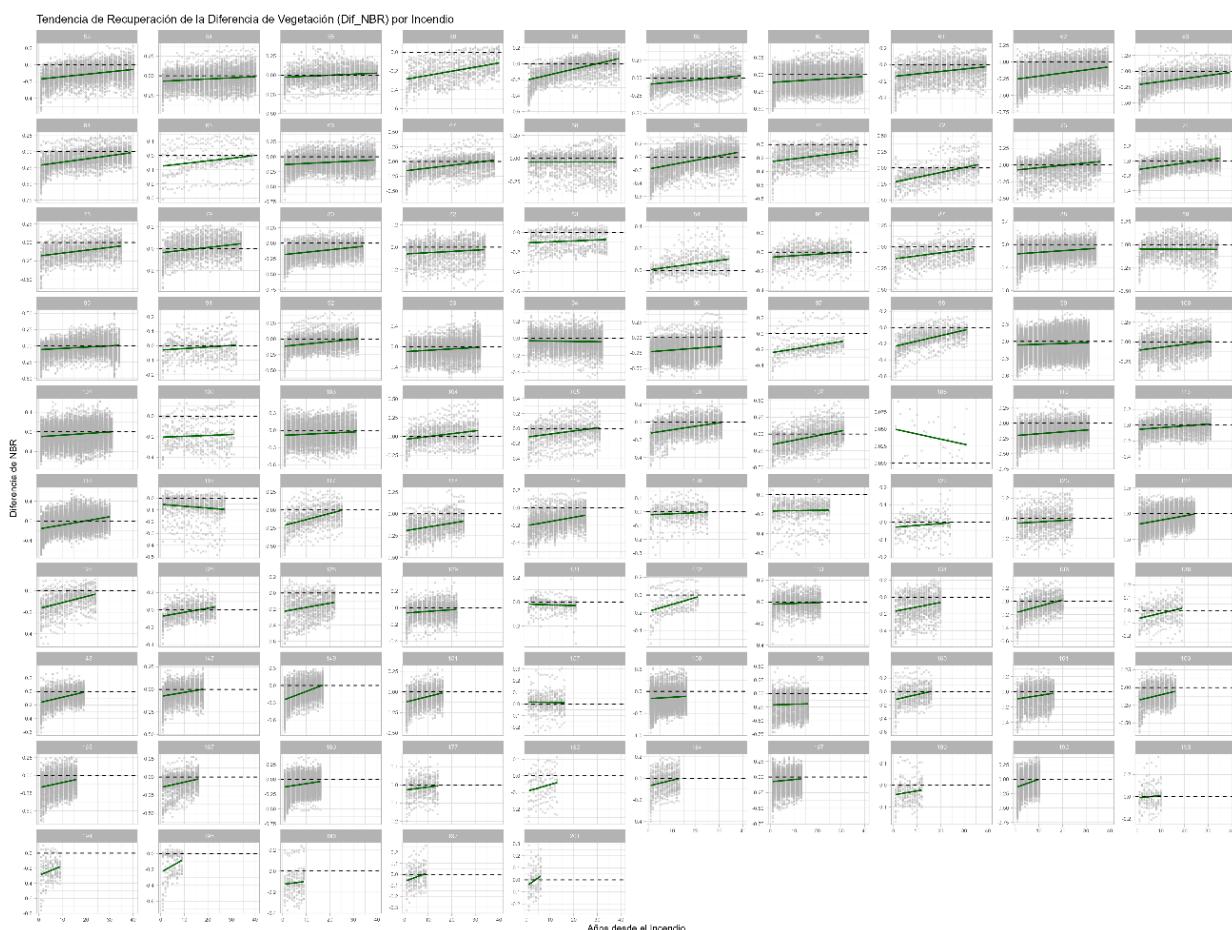
Media Dif_LST	SE	Escala	year_since_fire
2.812	0.012	Diario	0
2.350	0.007	Diario	1
1.591	0.006	Diario	2
1.348	0.006	Diario	3
1.993	0.016	Mensual	0
1.901	0.010	Mensual	1
1.412	0.009	Mensual	2
1.195	0.009	Mensual	3
1.037	0.008	Mensual	4
1.015	0.008	Mensual	5
1.071	0.008	Mensual	6
1.025	0.008	Mensual	7
1.107	0.008	Mensual	8
1.055	0.008	Mensual	9
0.968	0.008	Mensual	10
1.004	0.008	Mensual	11
0.950	0.008	Mensual	12
0.913	0.008	Mensual	13
0.958	0.008	Mensual	14
0.916	0.008	Mensual	15
0.884	0.009	Mensual	16
0.853	0.010	Mensual	17
0.742	0.011	Mensual	18
0.841	0.010	Mensual	19
0.631	0.009	Mensual	20
0.728	0.010	Mensual	21
0.776	0.010	Mensual	22
0.665	0.010	Mensual	23
0.697	0.010	Mensual	24
0.639	0.010	Mensual	25
0.634	0.010	Mensual	26
0.551	0.010	Mensual	27
0.532	0.010	Mensual	28
0.483	0.010	Mensual	29
0.546	0.011	Mensual	30
0.648	0.011	Mensual	31
0.772	0.016	Mensual	32
0.981	0.016	Mensual	33
0.844	0.017	Mensual	34
0.710	0.020	Mensual	35
0.814	0.021	Mensual	36
0.708	0.022	Mensual	37
0.812	0.022	Mensual	38
0.979	0.026	Mensual	39
0.769	0.053	Mensual	40
2.192	0.023	Anual	1

1.444	0.022	Anual	2
1.225	0.022	Anual	3
1.058	0.021	Anual	4
0.965	0.021	Anual	5
1.054	0.020	Anual	6
0.970	0.020	Anual	7
1.105	0.022	Anual	8
1.132	0.020	Anual	9
1.076	0.020	Anual	10
1.003	0.022	Anual	11
1.031	0.022	Anual	12
0.905	0.021	Anual	13
0.947	0.022	Anual	14
1.048	0.021	Anual	15
0.997	0.023	Anual	16
0.689	0.026	Anual	17
0.740	0.029	Anual	18
0.808	0.025	Anual	19
0.708	0.025	Anual	20
0.835	0.025	Anual	21
0.782	0.026	Anual	22
0.544	0.026	Anual	23
0.588	0.026	Anual	24
0.747	0.027	Anual	25
0.664	0.027	Anual	26
0.553	0.025	Anual	27
0.663	0.025	Anual	28
0.436	0.025	Anual	29
0.565	0.024	Anual	30
0.670	0.025	Anual	31
0.893	0.040	Anual	32
0.961	0.041	Anual	33
0.935	0.041	Anual	34
0.752	0.049	Anual	35
0.877	0.053	Anual	36
0.870	0.051	Anual	37
0.899	0.051	Anual	38
1.091	0.055	Anual	39
0.736	0.119	Anual	40

**ANEXO 7.** Tabla de perdida de eventos según el año transcurrido del grupo.

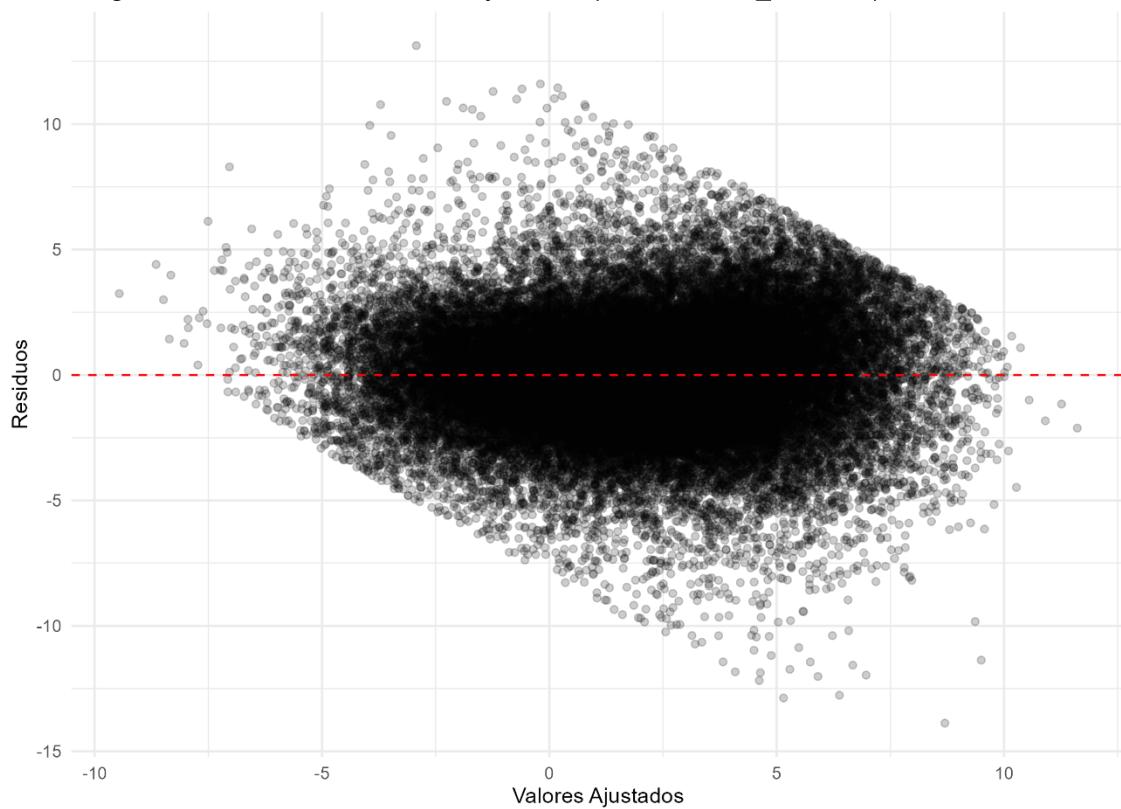
year_since_fire	N_Incendios_Activos
1	95
2	95
3	95
4	95
5	95
6	95
7	94
8	94
9	94
10	90
11	88
12	88
13	87
14	84
15	83
16	83
17	73
18	72
19	71
20	69
21	67
22	64
23	62
24	61
25	57
26	52
27	52
28	51
29	51
30	51
31	50
32	35
33	31
34	31
35	21
36	19
37	17
38	16
39	13
40	4

## ANEXO 8. Tendencias por incendio de la diferencia del LST y el NBR.

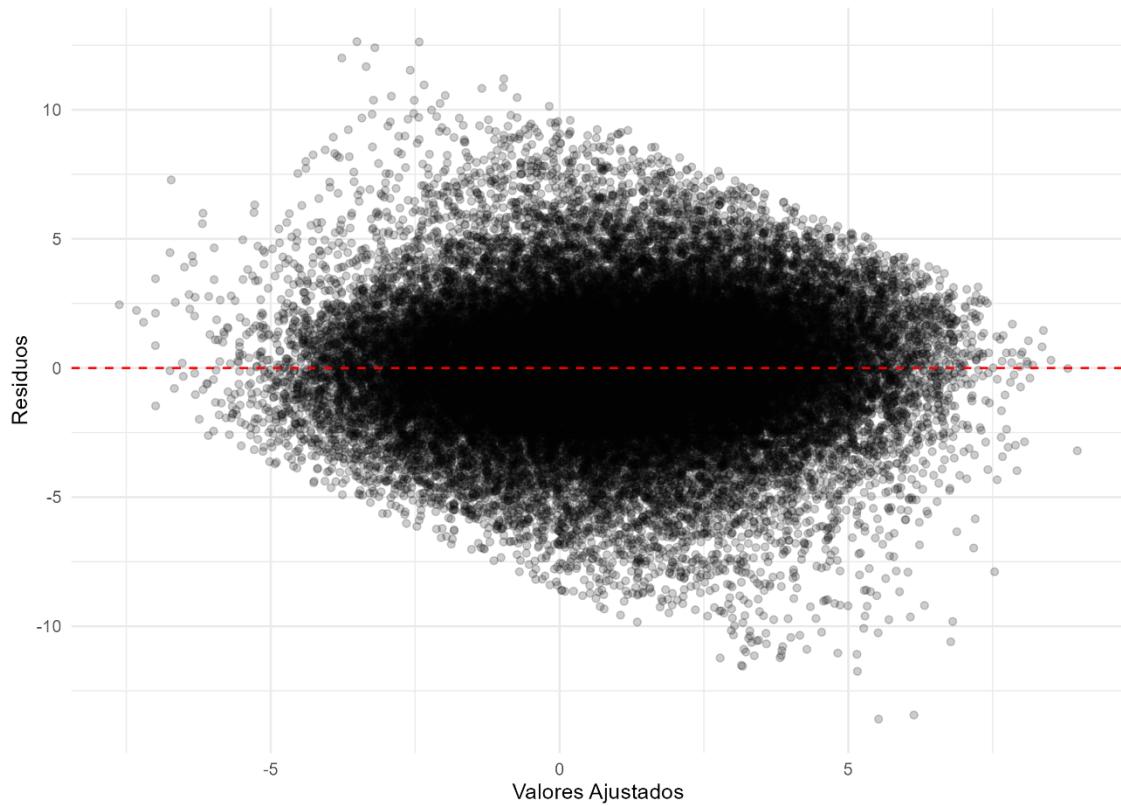


**ANEXO 9.** Gráficos de residuos de los modelos mensual, anual y diario.

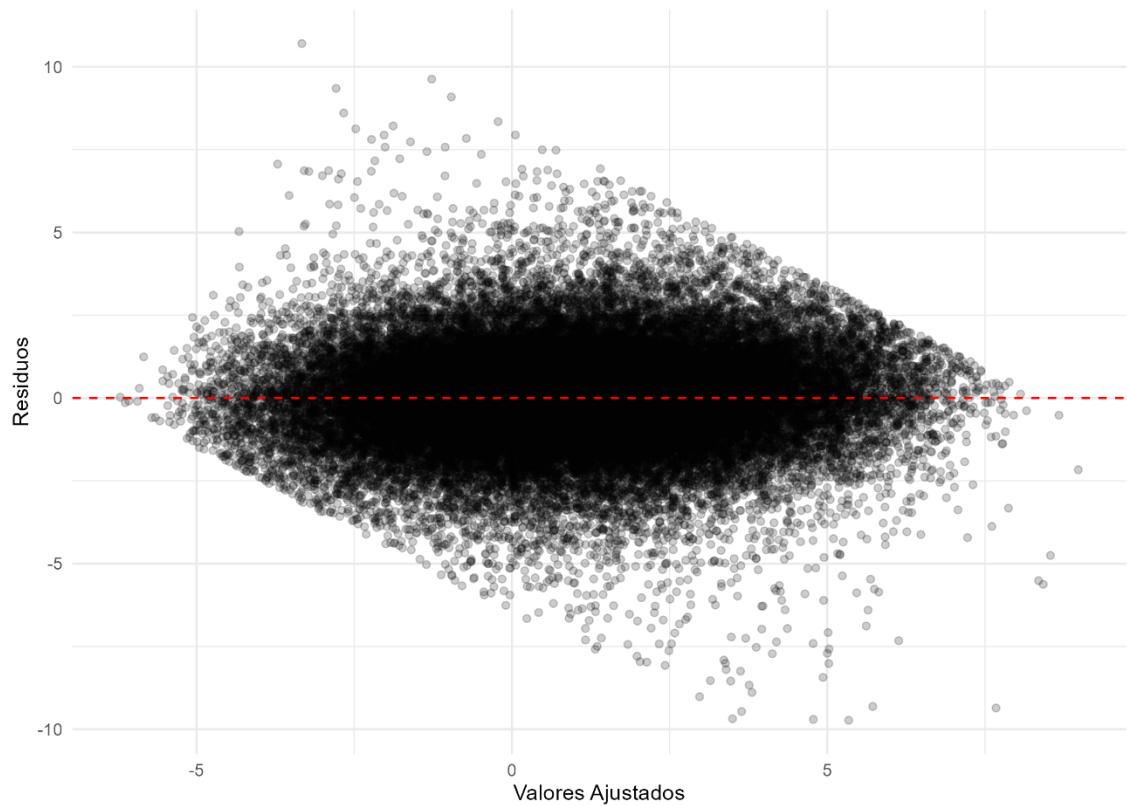
Diagnóstico: Residuos vs. Valores Ajustados (Modelo diario\_muestra )



Diagnóstico: Residuos vs. Valores Ajustados (Modelo mensual )



Diagnóstico: Residuos vs. Valores Ajustados (Modelo anual )



**ANEXO 10.** Proceso de comparación con el método de AIC, escala diaria, mensual y anual.

Mensual

Nombre	Modelo R	AIC	AIC_wt
Dif_NBR	lmerModLmerTest	20488947.07	1
Dif_NDVI	lmerModLmerTest	20696798.90	0
Dif_BAI	lmerModLmerTest	20671305.16	0
Dif_NDWI	lmerModLmerTest	20678021.99	0

Nombre	Modelo R	AIC	AIC_wt
elevacion2m	lmerModLmerTest	20488832.11	1.00E+00
pendiente2m	lmerModLmerTest	20488949.05	4.04E-26
expo_general2m	lmerModLmerTest	20488946.22	1.66E-25
tpi2m	lmerModLmerTest	20488948.83	4.52E-26
tri2m	lmerModLmerTest	20488947.59	8.40E-26

Anual

Nombre	Modelo R	AIC	AIC_wt
Dif_NBR	lmerModLmerTest	1717441.81	1
Dif_NDVI	lmerModLmerTest	1748894.70	0
Dif_NDWI	lmerModLmerTest	1758132.15	0

Nombre	Modelo R	AIC	AIC_wt
elevacion2m	lmerModLmerTest	1717353.94	1.00E+00
pendiente2m	lmerModLmerTest	1717443.81	3.05E-20
expo_general2m	lmerModLmerTest	1717442.09	7.21E-20
tpi2m	lmerModLmerTest	1717443.68	3.26E-20
tri2m	lmerModLmerTest	1717442.80	5.06E-20

Diario

Nombre	Modelo R	AIC	AIC_wt
Dif_NBR	lmerModLmerTest	4574390.40	1
Dif_NDVI	lmerModLmerTest	4632634.85	0
Dif_BAI	lmerModLmerTest	4631917.51	0
Dif_NDWI	lmerModLmerTest	4633684.32	0

Nombre	Modelo R	AIC	AIC_wt
elevacion2m	lmerModLmerTest	4574244.09	1.00E+00
pendiente2m	lmerModLmerTest	4574387.09	8.88E-32
expo_general2m	lmerModLmerTest	4574378.95	5.21E-30
tpi2m	lmerModLmerTest	4574392.40	6.25E-33
tri2m	lmerModLmerTest	4574381.90	1.19E-30