

9CFE-1667

Actas del Noveno Congreso Forestal Español Edita: **Sociedad Española de Ciencias Forestales. 2025**. ISBN: **978-84-941695-7-1**



Organiza

Análisis de la severidad del incendio de Sierra de La Culebra en la vegetación a partir de datos satelitales hiperespectrales

<u>CIPRA-RODRIGUEZ, J.A.(1);</u> FERNÁNDEZ-GUISURAGA, J.M.(2); QUINTANO, C. (3,4)

(1) SMART Ecosystems Research Group, Dept. de Producción Vegetal y Recursos Forestales, Instituto Universitario de Investigación en Gestión Forestal Sostenible (iuFOR), Universidad de Valladolid. E.T.S. Ing. Agrarias., Av. de Madrid, s/n, 34004 Palencia, España

(2) DepartamentoDepartmento de Biodiversidad y Gestión Ambiental, Facultad de Biología y Ciencias Ambientales, Universidad de León, 24071 León, España

(3) Departamento de Tecnología Electrónica, Escuela de Ingeniería Industrial, Universidad de Valladolid, 47011 Valladolid, España

(4) Instituto Universitario de Investigación en Gestión Forestal Sostenible (iuFOR), Universidad de Valladolid. E.T.S. Ing. Agrarias., Av. de Madrid, s/n, 34004 Palencia, España

Resumen

El incendio en Sierra de La Culebra causó una pérdida significativa de masa forestal. Este estudio tiene como objetivo estimar la severidad de dicho incendio utilizando datos hiperespectrales post-incendio del satélite PRISMA, frente a la utilización convencional de datos multiespectrales para este fin. Se calcularon varios índices espectrales a partir de la imagen PRISMA: (i) índices espectrales comúnmente utilizados con sensores multiespectrales de banda ancha, pero testeando diversas combinaciones de bandas hiperespectrales adyacentes a la longitud de onda central de la banda ancha; (ii) índices espectrales específicamente diseñados para bandas estrechas hiperespectrales. Estos índices se relacionaron mediante modelos lineales con datos de severidad medidos en parcelas de campo con el Composite Burn Index (CBI). Se encontraron altas correlaciones entre los índices hiperespectrales y los CBI de la vegetación perteneciente al bosque de frondosas y no arbóreas, donde el índice de mejor desempeño fue el índice de absorción de celulosa (CAI; r = -0.899, $R^2 = 0.808$), superando a los índices multiespectrales como la diferencia normalizada de borde rojo (NDRE; r = -0.882, $R^2 = 0.778$). Los resultados permitieron concluir que los índices específicamente diseñados para sensores hiperespectrales fueron más sensibles a los cambios ecológicos inducidos por el fuego. Este estudio mejora por tanto la comprensión de los impactos de los incendios en los ecosistemas, facilitando la evaluación de la recuperación de los ecosistemas.

Palabras claves

Sensores remotos, impacto ecológico post-incendio, PRISMA, índices hiperespectrales, CBI

1. Introducción

Los incendios forestales son la mayor perturbación en los ecosistemas mediterráneos en todo el mundo, y más aún en la cuenca mediterránea donde extensas áreas han sido quemadas en las décadas recientes debido a cambios abruptos de los regímenes de incendios por el cambio climático (OLIVEIRA et al., 2012; BOER et al., 2017; GONÇALVES & SOUSA, 2017). Los incendios desempeñan un rol esencial en la conformación de la composición de especies, estructura y dinámica de las comunidades vegetales del Mediterráneo (TESSLER et al., 2016;





FERNÁNDEZ-GUISURAGA et al., 2019). Asimismo, cambios físicos, químicos y biológicos son provocados en los suelos forestales a causa del fuego (EVANGELIDES & NOBAJAS, 2020).

La determinación de la severidad de incendio es necesaria para cuantificar las pérdidas de biomasa sobre y bajo el suelo (KEELEY, 2009). La severidad de incendio se define como la magnitud del cambio ecológico en un área quemada con respecto al escenario previo al incendio, y medida de manera cualitativa como los efectos del incendio sobre la vegetación y el suelo (KEY & BENSON, 2006; LENTILE et al., 2009). Su evaluación se realiza en campo analizando la vegetación y el suelo e integrando índices como el *Composite Burn Index* (CBI) (QUINTANO et al., 2023). Las imágenes satelitales son insumos que permiten también determinar la severidad de incendio en extensas áreas que son validadas por el CBI (HOLDEN et al., 2009).

La teledetección se ha convertido en una fuente de datos importante para evaluar la severidad de incendios en grandes paisajes quemados por su relación costebeneficio y su naturaleza sinóptica (YIN et al., 2020).

Los datos multiespectrales proporcionados por Sentinel-2 son comúnmente utilizados en evaluaciones cuantitativas de la severidad de los incendios (QUINTANO et al., 2023). Mejora la eficacia, la velocidad y la viabilidad de la identificación y el seguimiento de las regiones en riesgo de incendios forestales (ATUN et al., 2020).

La teledetección hiperespectral proporciona centenares de bandas espectrales contiguas y estrechas con anchos de banda de 5 a 15 nm (GOETZ, 2009; TRANSON et al., 2018). La disponibilidad de estos datos tiene un gran potencial para proporcionar estimaciones de la severidad de los incendios que coincidan con las necesidades de gestión posteriores al incendio. Las ventajas que esto conlleva es la reducción de costos de logística y el descarte de los datos de banda ancha de sensibilidad subóptima (QUINTANO et al., 2023).

Los cálculos de índices de vegetación (IV) a partir de datos obtenidos mediante teledetección son fundamentales para las evaluaciones de recuperación posterior a los incendios, ya que ayudan con el análisis espacio-temporal y el mapeo de la severidad de los incendios (CHRYSAFIS et al., 2019). El IV puede resaltar las sutilezas y características de una clase de características o de una característica específica y puede indicar el desarrollo de los cultivos, la vegetación y la no vegetación, el suelo y otra información relacionada (CHEN et al., 2024). Este puede ser una combinación lineal o no lineal de dos o más bandas espectrales (WANG et al., 2024).

Los IV multiespectrales tradicionales se limitan a las bandas características de rojo, rojo cercano e infrarrojo medio. Estos IV tienen las desventajas de tener un número reducido de bandas, anchos de banda grandes y posiciones de longitud de onda restringidas, que no pueden reflejar con precisión las características de la biomasa (WANG et al., 2024). La teledetección hiperespectral, por otro lado, tiene una alta resolución espectral e información espectral en cientos de bandas (WANG et al., 2024).

En ese sentido, este estudio busca estimar la severidad de los incendios forestales en ecosistemas arbóreos y no arbóreos en la Sierra de La Culebra usando índices hiperespectrales PRISMA. Los CBI fueron evaluados en campo bajo tres clases: vegetación, suelo y sitio, con el fin de identificar el desempeño de los índices



hiperespectrales en predecir la severidad de incendios en dichos niveles. Además, se calcularon índices multiespectrales a partir de una imagen satelital Sentinel-2 para compararla con los índices hiperespectrales.

2. Objetivos

Estimar la severidad de los incendios forestales en la vegetación en la Sierra de La Culebra usando índices hiperespectrales.

3. Metodología

<u>Área de estudio</u>

El incendio forestal de la Sierra de La Culebra, ubicado en Zamora, Castilla y León, España, fue el segundo más grande y destructivo registrados en el país. Este evento tuvo lugar entre el 15 y el 19 de junio de 2022, afectando una superficie total de 28 046 ha (QUINTANO et al., 2023).

La región se distingue por su topografía variada, que incluye laderas escarpadas y valles amplios, con altitudes que oscilan entre los 747 y los 1205 metros sobre el nivel del mar. El clima es mediterráneo, con una temperatura media anual de 11 °C y una precipitación promedio de 750 mm (NINYEROLA et al., 2005).

En función de la vegetación presente antes del incendio, se identificaron tres grupos principales de ecosistemas: los bosques de coníferas, dominados por especies como *Pinus sylvestris* L. (pino silvestre) y *Pinus pinaster* Ait. (pino marítimo); los bosques de frondosas, compuestos por *Quercus ilex* L. (encina) y *Quercus pyrenaica* Willd. (roble melojo); y la vegetación no arbórea compuesta por matorrales dominados por *Cistus ladanifer* L., *Pterospartum tridentatum* (L.) Willk., *Erica australis* L. y *Halimium lasianthum* subsp. *Alyssoides* (Lam.) Greuter, además de pastizales mediterráneos (QUINTANO et al., 2023).

Imágenes hiperespectrales y multiespectrales

Para la evaluación de la severidad del incendio en el área de estudio se empleó los datos de dos tipos de imágenes satelitales: hiperespectral y multiespectral.

La imagen hiperespectral fue descargada de la plataforma de la agencia italiana PRISMA el 13 de julio de 2023. La misión PRecursore IperSpettrale della Missione Applicativa (PRISMA), lanzada en marzo de 2019, proporciona datos satelitales hiperespectrales en un rango espectral de 400 a 2500 nm, con un ancho de franja de 30 km, ofreciendo una herramienta innovadora para el análisis de severidad post-incendio (QUINTANO et al., 2023).

La imagen multiespectral fue obtenida del satélite Sentinel-2 obtenida en nivel 2A el 15 de julio de 2022. Este satélite, perteneciente a la Agencia Espacial Europea (ESA), está equipado con un sensor multiespectral que ofrece 13 bandas resoluciones espaciales de 10 m, 20 m, y 60 m. Estas bandas abarcan las regiones del infrarrojo cercano visible (VNIR; 10 bandas) y del infrarrojo de onda corta (SWIR; 3 bandas), permitiendo una evaluación de los efectos del incendio (QUINTANO et al., 2023).

Composite Burn Index (CBI)

El Composite Burn Index (CBI) es una medida estandarizada de campo de la severidad de incendio en campo, ampliamente utilizadas para validar productos de teledetección basados en imágenes satelitales (HOLDEN et al., 2009). Este índice se calcula mediante la evaluación visual de varias métricas en cuatro estratos de vegetación y suelo, proporcionando una idea general del daño causado por el fuego (FERNÁNDEZ-GARCÍA et al., 2018). En este estudio, no se consideraron atributos posteriores al fuego, como el cambio de la composición de especies o las



nuevas incorporaciones en el suelo.

Se evaluaron 70 parcelas de 30 m x 30 m con homogeneidad de daño, en un mes después del incendio. El diseño de muestreo fue estratificado aleatoriamente, utilizando como estratos las comunidades vegetales dominantes (excluyendo pastizales) (QUINTANO et al., 2023). La distribución de parcelas por categorías de ecosistemas fue: 20 parcelas en bosques de frondosas, 34 en bosques de coníferas, 16 en vegetación no arbórea, y 70 en todos los ecosistemas.

En el sotobosque, se registraron el consumo de combustible fino y los atributos de carbón en el sustrato. Para los estratos de hierbas, arbustos bajos y árboles de menos de 1 m de altura, se evaluó el porcentaje de follaje consumido. En los estratos de arbustos altos y árboles entre 1 y 5 m, también se registró el porcentaje de follaje consumido. En la capa del dosel (intermedios de 5 a 20 m y superiores a 20 m), se registró el porcentaje de follaje verde/negro/marrón y la altura de carbón en los troncos. Para garantizar la consistencia, se requirió el consenso de al menos dos observadores en cada medición (De Santis y Chuvieco, 2007) (QUINTANO et al., 2023).

El CBI del sitio (promedio general de la parcela) se calculó promediando las calificaciones de todos los estratos. El CBI de la vegetación excluye el sustrato, mientras que el CBI del suelo promedia exclusivamente las calificaciones del sustrato. Los datos de severidad de incendio se categorizaron según los umbrales de CBI propuestos por Miller y Thode (2007): bajo (CBI < 1.25), moderado (1.25 <= CBI <= 2.25) y alto (CBI > 2.25) (QUINTANO et al., 2023).

En áreas de baja severidad, el follaje de los arbustos se consumió parcialmente y el dosel arbóreo se mantuvo casi intacto. En contraste, en áreas de alta severidad, el consumo de follaje del sotobosque y del dosel superior fue casi total. En las áreas de severidad moderada, la pérdida de follaje en el dosel fue incompleta, pero el sotobosque presentó un alto grado de consumo (FERNÁNDEZ-GUISURAGA et al., 2023).

Procesamiento de imágenes

El preprocesamiento y procesamiento de las imágenes hiperespectrales y multiespectrales, así como el cálculo de los índices de vegetación, se llevaron a cabo utilizando *Visual Studio Code* (VSC) y el lenguaje *Python*, empleando bibliotecas especializadas como *rasterio*, *numpy*, y *pandas*(GORELICK et al., 2017).

Las bandas con artefactos y baja relación señal-ruido, identificadas en la imagen hiperespectral mediante inspección visual, fueron excluidas del análisis (Tane et al., 2018; Amici y Piscini, 2021). En particular, se descartaron bandas en las regiones de 400-434 nm, 1345–1459 nm, 1774–1975 nm, 2010–2035 nm y 2469–2505 nm (QUINTANO et al., 2023). Asimismo, las bandas hiperespectrales, para utilización en índices multiespectrales, se renombraron de la siguiente manera: azul (BLUE; 400-500 nm), verde (GREEN; 500-600 nm), rojo (RED; 600-700 nm), borde rojo (RED EDGE; 700-750 nm), infrarrojo cercano (NIR; 750-1050 nm), infrarrojo de onda corta 1 (SWIR 1; 1050-1900 nm), e infrarrojo de onda corta 2 (SWIR 2; 1900-2500 nm).

Además, se realizó un co-registro de las imágenes hiperespectrales y multiespectrales para garantizar su alineación espacial precisa. Este proceso se llevó a cabo mediante el uso de puntos de control terrestre (GORELICK et al., 2017). <u>Índices de vegetación</u>

Los índices multiespectrales, como NDVI y NBR, fueron calculados tanto con datos



hiperespectrales como multiespectrales, ya que están diseñados para rangos de banda amplios. Sin embargo, los índices hiperespectrales, como LCI, NDNI y CAI, requieren bandas específicas y estrechas, disponibles únicamente en los datos hiperespectrales. Esto permitió evaluar con mayor sensibilidad las variaciones sutiles en la reflectancia asociadas a la severidad de incendio. En total, se analizaron 140 índices espectrales diferentes. En el presente estudio, con el fin de evitar confusión, los índices hiperespectrales serán aquello que fueron calculados a partir de los datos hiperespectrales, ya sea que el origen del índice se haya creado para hiperespectral y multiespectral. Mientras que se denominarán índices multiespectrales a los calculados a partir de datos multiespectrales.

En general, los índices hiperespectrales son más sensibles que los multiespectrales al capturar detalles finos de la severidad del daño, especialmente en áreas de transición. Esto se debe a la capacidad de las bandas estrechas para detectar cambios específicos en los componentes químicos de la vegetación y el suelo (CLARK et al., 2005).

Análisis estadístico

Para el análisis estadístico se utilizó R (versión 4.4.2; R Development Core Team, 2019). Los índices de vegetación se relacionaron con los valores de CBI mediante modelos lineales simples, evaluando su capacidad predictiva en función de dos métricas clave: el coeficiente de determinación (R²) y la raíz del error cuadrático medio (RMSE).

El coeficiente de determinación (\mathbb{R}^2) se empleó para medir la proporción de la variabilidad de los datos de CBI explicada por cada índice de vegetación. Un valor de \mathbb{R}^2 cercano a 1 indica un modelo con alta precisión predictiva. Por su parte, el RMSE se utilizó para cuantificar la dispersión de los valores observados con respecto a los valores predichos por el modelo. Un RMSE bajo sugiere que el modelo tiene un buen ajuste y una menor discrepancia entre los valores experimentales y los predichos (QIAO et al., 2022).

4. Resultados

Los índices hiperespectrales y multiespectrales calculados mostraron correlaciones variables según la clase de CBI y el tipo de ecosistema analizado (Tablas 1 y 2). Esto pone de manifiesto la importancia de seleccionar índices específicos para cada contexto ecológico y objetivo de análisis. En particular, los índices hiperespectrales, en general, presentaron correlaciones más altas con los CBI en comparación con los índices multiespectrales. Este mejor desempeño se debe a la mayor sensibilidad espectral de las bandas estrechas de las imágenes hiperespectrales, que permiten detectar con mayor precisión los cambios en los componentes químicos de la vegetación y el suelo asociados a la severidad de incendio (QUINTANO et al., 2023).

Respecto al desempeño de los índices con las clases de CBI, se observó que las mejores correlaciones se lograron con el CBI de vegetación. En contraste, el CBI de suelo presentó correlaciones más bajas, probablemente debido a debido a la planimetría de las imágenes que recogen mejor los estratos vegetales superiores en lugar del suelo (PEÑA & MARTÍNEZ, 2021). El CBI de sitio mostró un desempeño intermedio, lo cual es coherente al ser el promedio de las otras dos clases.

Por otro lado, los ecosistemas bosque de frondosas y vegetación no arbórea (matorrales y pastos) obtuvieron, en promedio, las correlaciones más altas con los CBI, seguido por el bosque de conífera. Esto sugiere que las características



adaptativas de las especies vegetales frente al fuego, como la tolerancia o resistencia a la quema, influyen en las respuestas detectadas por las imágenes satelitales (RODRÍGUEZ-TREJO & FULÉ, 2003). La correlación que incluye a todos los ecosistemas juntos fue inferior a la obtenida para los ecosistemas por separado, posiblemente debido a la heterogeneidad en las respuestas de las especies frente a los incendios por caracteres adaptativos al fuego que genera variabilidad en la detección por parte de las imágenes satelitales (ADAM et al., 2010).

Las bandas de las imágenes hiperespectrales y multiespectrales que mejor correlacionaron con los CBI fueron las del NIR y del Red Edge con valores negativos. Por otro lado, el SWIR2 no presentó una correlación significativa, a pesar de que es una banda típicamente usada para el análisis de incendios forestales (CARVAJAL-RAMÍREZ et al., 2019). En consecuencia, se priorizaron en el cálculo los índices que contenían las bandas NIR y Red Edge.

Los índices hiperespectrales que estuvieron mejor correlacionados con los valores de CBI fueron índice de absorción de celulosa (CAI), índice de vegetación de diferencia de rojo (DVIRED), índice de posición de borde rojo (REP) y relación de quema normalizada (NBR). En cuanto a los multiespectrales, los índices de vegetación que mostraron mejor correlación fueron el índice de clorofila de borde rojo (CIREDGE), índice de vegetación de diferencia de rojo (DVIRED), índice de vegetación diferencial (DVI), diferencia normalizada de borde rojo (NDRE), índice de área quemada (BAI) y índice de vegetación estructural (SVI).

El índice hiperespectrales que apareció con mayor frecuencia como el de mejor desempeño fue CAI, destacando en los ecosistemas de bosque de frondosas con las tres clases de CBI, y vegetación baja con CBI de vegetación y sitio. En todo el análisis con los datos hiperespectrales, el índice de vegetación con mejor correlación fue el CAI con el CBI de sitio y el ecosistema vegetación no arbórea, obteniendo un valor de -0.899 (R^2 = 0.808). Respecto a los datos multiespectrales, el índice CIREDGE fue el de mayor número de apariciones como el de mejor desempeño, resaltando en los bosques de frondosas y de coníferas en las clases de CBI suelo y sitio. Sin embargo, el índice NDRE aplicado en bosque de conífera con el CBI de vegetación fue el que presentó la mejor correlación entre los índices multiespectrales, con un valor de -0.882 (R^2 = 0.778).

Índices hiperespectrales							
Ecosistema	CBI vegetación		CBI suelo		CBI sitio		
	Índice	\mathbf{R}^2	Índice	\mathbf{R}^2	Índice	\mathbf{R}^2	
	(bandas)	(r)	(bandas)	(r)	(bandas)	(r)	
Todos	DVIRED	0.495	DVIRED	0.333	DVIRED	0.454	
	(38, 47)	(-0.703)	(37, 48)	(-0.577)	(37, 50)	(-0.674)	
Bosque de frondosas	CAI	0.752	CAI	0.705	CAI	0.766	
	(131, 154, 142)	(-0.867)	(134, 154, 142)	(-0.840)	(134, 154, 142)	(-0.875)	
Bosque de conífera	DVIRED	0.739	REP	0.333	REP	0.598	
	(36, 43)	(-0.860)	(30, 34, 50)	(0.577)	(30, 34, 51)	(0.773)	
Vegetación no arbórea	CAI	0.798	NBR	0.771	CAI	0.808	

Tabla 1. Índices hiperespectrales mejor correlacionados con CBI en diferentes ecosistemas.



(matorrales y	(133, 154, 140)	(-0.894)	(58, 186)	(-0.878)	(133, 154, 140)	(-0.899)
pastos)						

Tabla 2. Índices multiespectrales mejor correlacionados con CBI en diferentes ecosistemas.

Índices multiespectrales							
Ecosistema	CBI vegetación		CBI suelo		CBI sitio		
	Índice	\mathbf{R}^2	Índice	\mathbf{R}^2	Índice	\mathbf{R}^2	
	(bandas)	(r)	(bandas)	(r)	(bandas)	(r)	
Todos	BAI	0.435	DVIRED	0.269	DVIRED	0.383	
	(7, 8)	(0.660)	(6, 8A)	(-0.518)	(6, 8A)	(-0.619)	
Bosque de frondosas	NDRE	0.449	CIREDGE	0.426	CIREDGE	0.487	
	(6, 8A)	(-0.670)	(6, 8A)	(-0.653)	(6, 8A)	(-0.698)	
Bosque de conífera	NDRE	0.778	CIREDGE	0.309	CIREDGE	0.634	
	(5, 8)	(-0.882)	(5, 8)	(-0.556)	(5, 8)	(-0.796)	
Vegetación no arbórea	DVI	0.666	SVI	0.544	DVI	0.626	
	(4, 8A)	(-0.816)	(7, 4)	(-0.737)	(4, 8A)	(-0.791)	
(matorrales y pastos)							

5. Discusión

Los índices hiperespectrales mostraron una correlación más fuerte con los valores de CBI en comparación con los derivados de datos multiespectrales. Por ejemplo, el índice hiperespectral calculado para todos los ecosistemas en relación con el CBI de sitio presentó una correlación de -0.674 ($R^2 = 0.454$), mientras que el índice multiespectral correspondiente alcanzó una correlación de -0.619 ($R^2 = 0.383$). Estos resultados confirman la mayor capacidad de las imágenes hiperespectrales para capturar mayores detalles en la severidad de incendio, en concordancia con estudios previos que también destacan la superioridad de las imágenes PRISMA sobre a las Sentinel-2 (QUINTANO et al., 2023). La mayor sensibilidad de las bandas estrechas de las imágenes hiperespectrales permite una detección más precisa de cambios físicos y químicos en la vegetación, lo que las hace adecuadas para evaluar la severidad de incendio (ADAM et al., 2010).

El CBI de vegetación mostró las mejores correlaciones con los índices espectrales en todos los tipos de ecosistemas (bosque de frondosas, bosque de coníferas y vegetación no arbórea), tanto utilizando datos hiperespectrales como multiespectrales. Esto puede atribuirse a que los índices de vegetación están diseñados específicamente para detectar características relacionadas con la cobertura vegetal, como el contenido de clorofila, la densidad de la vegetación y el vigor de las plantas (MENG & ZHAO, 2017).

Por otro lado, las correlaciones negativas más fuertes entre los índices espectrales y los CBI de suelo y sitio se observaron principalmente en los ecosistemas de bosque de frondosas y vegetación no arbórea, pero no en el bosque de coníferas. Una posible explicación es las distintas respuestas espectrales son emitidas según el tipo de vegetación evaluada (ALDANA et al., 2020; FLORES RODRÍGUEZ et al., 2021; PEÑA & MARTÍNEZ, 2021). Además, factores como la densidad del bosque y la estructura del fuste pueden influir en la detección del estado del suelo por parte de los sensores, ya que estas características afectan la cantidad de biomasa remanente y la exposición del suelo tras un incendio (ROBICHAUD et al., 2007; GARCÍA-LLAMAS et al., 2019).



Los índices hiperespectrales calculados mostraron correlaciones negativas fuertes, superior a -0.850 ($R^2 = 0.722$), con el CBI de vegetación y con los ecosistemas individualmente. Estas correlaciones superaron las obtenidas al incluir todos los ecosistemas juntos (r = -0.703, $R^2 = 0.495$). Los ecosistemas de bosque de frondosas y vegetación no arbórea destacaron por presentar las mejores correlaciones entre los índices hiperespectrales y todas las clases de CBI. Este comportamiento puede atribuirse a las diferentes dinámicas de los ecosistemas y a las adaptaciones específicas de sus especies al fuego, las cuales resultan en composiciones químicas particulares que son detectadas con mayor precisión por las bandas estrechas de los sensores hiperespectrales a través de combinaciones específicas de bandas (ADAM et al., 2010).

La composición del suelo varía entre los ecosistemas debido a las diferencias en el aporte de biomasa que aportan las especies vegetales. Este aporte incluye diferencias en masa, volumen y compuestos químicos, como hojas, acículas y otros residuos orgánicos (CALVO et al., 2003). Estas diferencias explican por qué ciertos índices espectrales mostraron mejor desempeño en función del tipo de ecosistema.

En términos de severidad de incendio, se podría esperar que los ecosistemas forestales como el bosque de frondosas o el bosque de coníferas al poseer mayor biomasa aérea, impulsen el incendio y la severidad resultante sea la más alta (GARCÍA-LLAMAS et al., 2019; FERNÁNDEZ-GUISURAGA et al., 2022). Sin embargo, este patrón no se observó en este estudio, lo que coincide con los resultados de investigaciones previas (FERNÁNDEZ-GUISURAGA et al., 2022).

Los índices de vegetación calculados con datos hiperespectrales contienen las bandas NIR y Red Edge como se esperaba ya que son las bandas que mejor correlación mostraron con los CBI. Sin embargo, el NDVI no resultó relevante en la correlación con los CBI por contener la banda RED que no obtuvo una buena correlación. Los índices hiperespectrales CAI (celulosa y lignina), DVIRED (cambio en la biomasa), REP (cambio en la clorofila y estructura de vegetación), y NBR (severidad de incendios forestales) son particularmente útiles para evaluar la salud de la vegetación debido a su sensibilidad a las variaciones en la reflectancia de las hojas y biomasa (QIAO et al., 2022).

Respecto a los índices multiespectrales, CIREDGE (concentración de clorofila), DVIRED (cambio en la biomasa), NDRE (salud de la vegetación), DVI (cambio en la biomasa) y SVI (salud y densidad de vegetación) se caracterizan también por detectar variaciones en la clorofila, la biomasa y la severidad de los incendios (IMRAN et al., 2020). La identificación de índices de vegetación hiperespectrales específicos permite la evaluación remota de la severidad de incendio de la vegetación y el suelo, superando el análisis de índices a partir de imágenes multiespectrales (HUDAK et al., 2007; CARVAJAL-RAMÍREZ et al., 2019). La identificación de la severidad de incendio de la vegetación y el suelo permitirá la planificación de estrategias de restauración ecológica y monitoreo post-incendio, concentrando esfuerzos en aquellas zonas prioritarias (GARCÍA-LLAMAS et al., 2019).

6. Conclusiones

La severidad de incendio en la Sierra de La Culebra fue mejor estimada por los índices hiperespectrales frente a los índices multiespectrales. Específicamente, se lograron correlaciones más fuertes con los CBI de vegetación por ser el estrato mejor detectado por la planimetría de las imágenes satelitales, comparado con los CBI de suelo y sitio. Dentro de la vegetación evaluada, los ecosistemas de bosque



frondosas y vegetación no arbórea fueron mejor correlacionadas que el bosque de coníferas. La adaptación de las especies vegetales frente al fuego influye en las respuestas detectadas por las imágenes satelitales. Las bandas espectrales que presentaron potencial de correlación con los CBI fueron las del NIR y Red Edge, mientras que el índice hiperespectral con mejor desempeño fue CAI, alcanzando la correlación más alta del estudio (r = -0.899, R^2 = 0.808).

7. Referencias

ADAM, E.; MUTANGA, O.; RUGEGE, D.; 2010. Multispectral and hyperspectral remote sensing for identification and mapping of wetland vegetation: a review. *Wetlands Ecology and Management*, *18*(3), 281-296. https://doi.org/10.1007/s11273-009-9169-z

ALDANA, C.; REVILLA, M.; GONZALES, J.; SAAVEDRA, Y.; MONCADA, W.; MAICELO, J.; 2020. Relación de firmas espectrales para la identificación de bosque seco en imágenes de satélite Sentinel 2, cuenca baja del río Chira, Región Piura. *Revista de Teledetección*, *56*, 147. https://doi.org/10.4995/raet.2020.14110

ATUN, R.; KALKAN, K.; GÜRSOY, Ö.; 2020. Determining The Forest Fire Risk with Sentinel 2 Images. *1*(1), 22-26.

BOER, M. M.; NOLAN, R. H.; RESCO DE DIOS, V.; CLARKE, H.; PRICE, O. F.; BRADSTOCK, R. A.; 2017. Changing Weather Extremes Call for Early Warning of Potential for Catastrophic Fire. *Earth's Future*, *5*(12), 1196-1202. https://doi.org/10.1002/2017EF000657

CALVO, L.; SANTALLA, S.; MARCOS, E.; VALBUENA, L.; TÁRREGA, R.; LUIS, E.; 2003. Regeneration after wildfire in communities dominated by Pinus pinaster, an obligate seeder, and in others dominated by Quercus pyrenaica, a typical resprouter. *Forest Ecology and Management*, *184*(1-3), 209-223. https://doi.org/10.1016/S0378-1127(03)00207-X

CARVAJAL-RAMÍREZ, F.; MARQUES DA SILVA, J. R.; AGÜERA-VEGA, F.; MARTÍNEZ-CARRICONDO, P.; SERRANO, J.; MORAL, F. J.; 2019. Evaluation of Fire Severity Indices Based on Pre- and Post-Fire Multispectral Imagery Sensed from UAV. *Remote Sensing*, *11*(9), 993. https://doi.org/10.3390/rs11090993

CHEN, C.; YUAN, X.; GAN, S.; LUO, W.; BI, R.; LI, R.; GAO, S.; 2024. A new vegetation index based on UAV for extracting plateau vegetation information. *International Journal of Applied Earth Observation and Geoinformation*, *128*, 103668. https://doi.org/10.1016/j.jag.2024.103668

CHRYSAFIS, I.; MALLINIS, G.; TSAKIRI, M.; PATIAS, P.; 2019. Evaluation of singledate and multi-seasonal spatial and spectral information of Sentinel-2 imagery to assess growing stock volume of a Mediterranean forest. *International Journal of Applied Earth Observation and Geoinformation*, 77, 1-14.

https://doi.org/10.1016/j.jag.2018.12.004

CLARK, M. L.; ROBERTS, D. A.; CLARK, D. B.; 2005. Hyperspectral discrimination of tropical rain forest tree species at leaf to crown scales. *Remote Sensing of Environment*, *96*(3-4), 375-398. https://doi.org/10.1016/j.rse.2005.03.009

EVANGELIDES, C.; NOBAJAS, A.; 2020. Red-Edge Normalised Difference Vegetation Index (NDVI705) from Sentinel-2 imagery to assess post-fire regeneration. *Remote Sensing Applications: Society and Environment*, *17*, 100283.

https://doi.org/10.1016/j.rsase.2019.100283

FERNÁNDEZ-GARCÍA, V.; SANTAMARTA, M.; FERNÁNDEZ-MANSO, A.; QUINTANO, C.; MARCOS, E.; CALVO, L.; 2018. Burn severity metrics in fire-prone pine ecosystems along a climatic gradient using Landsat imagery. *Remote Sensing of Environment, 206*, 205-217. https://doi.org/10.1016/j.rse.2017.12.029 FERNÁNDEZ-GUISURAGA, J. M.; CALVO, L.; QUINTANO, C.; FERNÁNDEZ-MANSO,



A.; FERNANDES, P. M.; 2023. Fractional vegetation cover ratio estimated from radiative transfer modeling outperforms spectral indices to assess fire severity in several Mediterranean plant communities. *Remote Sensing of Environment, 290,* 113542. https://doi.org/10.1016/j.rse.2023.113542

FERNÁNDEZ-GUISURAGA, J. M.; FERNÁNDEZ-MANSO, A.; QUINTANO, C.; FERNÁNDEZ-GARCÍA, V.; CERRILLO, A.; MARQUÉS, G.; CASCALLANA, G.; CALVO, L.; 2024. FIREMAP: Cloud-based software to automate the estimation of wildfireinduced ecological impacts and recovery processes using remote sensing techniques. *Ecological Informatics*, *81*, 102591.

https://doi.org/10.1016/j.ecoinf.2024.102591

FERNÁNDEZ-GUISURAGA, J. M.; SUÁREZ-SEOANE, S.; CALVO, L.; 2019. Modeling Pinus pinaster forest structure after a large wildfire using remote sensing data at high spatial resolution. *Forest Ecology and Management*, 446, 257-271. https://doi.org/10.1016/j.foreco.2019.05.028

FERNÁNDEZ-GUISURAGA, J. M.; SUÁREZ-SEOANE, S.; FERNANDES, P. M.; FERNÁNDEZ-GARCÍA, V.; FERNÁNDEZ-MANSO, A.; QUINTANO, C.; CALVO, L.; 2022. Pre-fire aboveground biomass, estimated from LiDAR, spectral and field inventory data, as a major driver of burn severity in maritime pine (Pinus pinaster) ecosystems. *Forest Ecosystems*, *9*, 100022.

https://doi.org/10.1016/j.fecs.2022.100022

FERNÁNDEZ-MANSO, A.; QUINTANO, C.; ROBERTS, D. A.; 2019. Burn severity analysis in Mediterranean forests using maximum entropy model trained with EO-1 Hyperion and LiDAR data. *ISPRS Journal of Photogrammetry and Remote Sensing*, *155*, 102-118. https://doi.org/10.1016/j.isprsjprs.2019.07.003

FLORES RODRÍGUEZ, A. G.; FLORES-GARNICA, J. G.; GONZ'ALEZ-EGUIARTE, D. R.; GALLEGOS-RODRÍGUEZ, A.; ZARAZÚA-VILLASEÑOR, P.; MENA-MUNGUÍA, S.; 2021. Análisis comparativo de índices espectrales para ubicar y dimensionar niveles de severidad de incendios forestales. *Investigaciones Geográficas*, 106. https://doi.org/10.14350/rig.60396

GARCÍA-LLAMAS, P.; SUÁREZ-SEOANE, S.; FERNÁNDEZ-MANSO, A.; QUINTANO, C.; CALVO, L.; 2020. Evaluation of fire severity in fire prone-ecosystems of Spain under two different environmental conditions. *Journal of Environmental Management*, 271, 110706. https://doi.org/10.1016/j.jenvman.2020.110706

GARCÍA-LLAMAS, P.; SUÁREZ-SEOANE, S.; TABOADA, A.; FERNÁNDEZ-MANSO, A.; QUINTANO, C.; FERNÁNDEZ-GARCÍA, V.; FERNÁNDEZ-GUISURAGA, J. M.; MARCOS, E.; CALVO, L.; 2019. Environmental drivers of fire severity in extreme fire events that affect Mediterranean pine forest ecosystems. *Forest Ecology and Management*, 433, 24-32. https://doi.org/10.1016/j.foreco.2018.10.051

GOETZ, A. F. H.; 2009. Three decades of hyperspectral remote sensing of the Earth: A personal view. *Remote Sensing of Environment*, *113*, S5-S16. https://doi.org/10.1016/j.rse.2007.12.014

GONÇALVES, A. C.; SOUSA, A. M. O.; 2017. The Fire in the Mediterranean Region: A Case Study of Forest Fires in Portugal. En B. Fuerst-Bjelis (Ed.), *Mediterranean Identities - Environment, Society, Culture*. InTech.

https://doi.org/10.5772/intechopen.69410

GORELICK, N.; HANCHER, M.; DIXON, M.; ILYUSHCHENKO, S.; THAU, D.; MOORE, R.; 2017. Google Earth Engine: Planetary-scale geospatial analysis for everyone. *Remote Sensing of Environment, 202,* 18-27. https://doi.org/10.1016/j.rse.2017.06.031 HOLDEN, Z. A.; MORGAN, P.; EVANS, J. S.; 2009. A predictive model of burn severity based on 20-year satellite-inferred burn severity data in a large southwestern US wilderness area. *Forest Ecology and Management, 258*(11), 2399-2406.



https://doi.org/10.1016/j.foreco.2009.08.017

HUDAK, A. T.; MORGAN, P.; BOBBITT, M. J.; SMITH, A. M. S.; LEWIS, S. A.; LENTILE, L. B.; ROBICHAUD, P. R.; CLARK, J. T.; MCKINLEY, R. A.; 2007. The Relationship of Multispectral Satellite Imagery to Immediate Fire Effects. *Fire Ecology*, *3*(1), 64-90. https://doi.org/10.4996/fireecology.0301064

IMRAN, H. A.; GIANELLE, D.; ROCCHINI, D.; DALPONTE, M.; MARTÍN, M. P.; SAKOWSKA, K.; WOHLFAHRT, G.; VESCOVO, L.; 2020. VIS-NIR, Red-Edge and NIR-Shoulder Based Normalized Vegetation Indices Response to Co-Varying Leaf and Canopy Structural Traits in Heterogeneous Grasslands. *Remote Sensing*, *12*(14), 2254. https://doi.org/10.3390/rs12142254

KEELEY, J. E.; 2009. Fire intensity, fire severity and burn severity: a brief review and suggested usage. *International Journal of Wildland Fire*, *18*(1), 116. https://doi.org/10.1071/WF07049

KEY, C. H.; BENSON, N. C.; 2006. Landscape assessment (LA): sampling and analysis methods. En *FIREMON: Fire effects monitoring and inventory system*. USDA Forest Service.

LENTILE, L. B.; SMITH, A. M. S.; HUDAK, A. T.; MORGAN, P.; BOBBITT, M. J.; LEWIS, S. A.; ROBICHAUD, P. R.; 2009. Remote sensing for prediction of 1-year post-fire ecosystem condition. *International Journal of Wildland Fire*, *18*(5), 594. https://doi.org/10.1071/WF07091

MENG, R.; ZHAO, F.; 2017. Remote sensing of fire effects: a review for recent advances in burned area and burn severity mapping. En *Remote sensing of hydrometeoroloical hazards* (1st edition, pp. 261-283). CRC Press.

https://www.taylorfrancis.com/chapters/edit/10.1201/9781315154947-12/remote-sensing-fire-effects-ran-meng-feng-zhao

NINYEROLA, M.; PONS, X.; ROURE, J. M.; 2005. Atlas climático digital de la Península Ibérica. Metodología y aplicaciones en bioclimatología y geobotánica. Universitat Autónoma de Barcelona. https://pascal-francis.inist.fr/vibad/index.php? action=getRecordDetail&idt=18200972

NIROUMAND-JADIDI, M.; BOVOLO, F.; BRUZZONE, L.; 2020. Water Quality Retrieval from PRISMA Hyperspectral Images: First Experience in a Turbid Lake and Comparison with Sentinel-2. *Remote Sensing*, *12*(23), 3984.

https://doi.org/10.3390/rs12233984

OLIVEIRA, S.; OEHLER, F.; SAN-MIGUEL-AYANZ, J.; CAMIA, A.; PEREIRA, J. M. C.; 2012. Modeling spatial patterns of fire occurrence in Mediterranean Europe using Multiple Regression and Random Forest. *Forest Ecology and Management*, *275*, 117-129. https://doi.org/10.1016/j.foreco.2012.03.003

PEÑA, M. A.; MARTÍNEZ, G.; 2021. Mapeo del daño en bosques incendiados de Chile central, mediante el modelado de índices espectrales ex-ante y ex-post. *Bosque (Valdivia), 42*(2), 205-215. https://doi.org/10.4067/S0717-92002021000200205

QIAO, L.; TANG, W.; GAO, D.; ZHAO, R.; AN, L.; LI, M.; SUN, H.; SONG, D.; 2022. UAVbased chlorophyll content estimation by evaluating vegetation index responses under different crop coverages. *Computers and Electronics in Agriculture, 196*, 106775. https://doi.org/10.1016/j.compag.2022.106775

QUINTANO, C.; CALVO, L.; FERNÁNDEZ-MANSO, A.; SUÁREZ-SEOANE, S.; FERNANDES, P. M.; FERNÁNDEZ-GUISURAGA, J. M.; 2023. First evaluation of fire severity retrieval from PRISMA hyperspectral data. *Remote Sensing of Environment*, 295, 113670. https://doi.org/10.1016/j.rse.2023.113670

QUINTANO, C.; FERNÁNDEZ-MANSO, A.; ROBERTS, D. A.; 2013. Multiple Endmember Spectral Mixture Analysis (MESMA) to map burn severity levels from Landsat images in Mediterranean countries. *Remote Sensing of Environment*, 136,



76-88. https://doi.org/10.1016/j.rse.2013.04.017

R DEVELOPMENT CORE TEAM.; 2019. R: A Language and Environmenta for Statistical Computing [Software]. R Foundation for Statistical Computing. http://www.r-project.org/

ROBICHAUD, P. R.; LEWIS, S. A.; LAES, D. Y. M.; HUDAK, A. T.; KOKALY, R. F.; ZAMUDIO, J. A.; 2007. Postfire soil burn severity mapping with hyperspectral image unmixing. *Remote Sensing of Environment*, *108*(4), 467-480. https://doi.org/10.1016/j.rse.2006.11.027

RODRÍGUEZ-TREJO, D. A.; FULÉ, P. Z.; 2003. Fire ecology of Mexican pines and a fire management proposal. *International Journal of Wildland Fire*, *12*(1), 23. https://doi.org/10.1071/WF02040

SIVRIKAYA, F.; GÜNLÜ, A.; KÜÇÜK, Ö.; ÜRKER, O.; 2024. Forest fire risk mapping with Landsat 8 OLI images: Evaluation of the potential use of vegetation indices. *Ecological Informatics*, 79, 102461. https://doi.org/10.1016/j.ecoinf.2024.102461 TESSLER, N.; SAPIR, Y.; WITTENBERG, L.; GREENBAUM, N.; 2016. Recovery of Mediterranean Vegetation after Recurrent Forest Fires: Insight from the 2010 Forest Fire on Mount Carmel, Israel. *Land Degradation & Development*, 27(5), 1424-1431. https://doi.org/10.1002/ldr.2419

TRANSON, J.; D'ANDRIMONT, R.; MAUGNARD, A.; DEFOURNY, P.; 2018. Survey of Hyperspectral Earth Observation Applications from Space in the Sentinel-2 Context. *Remote Sensing*, *10*(2), 157. https://doi.org/10.3390/rs10020157 WANG, B.; DAI, D.; YU, D.; GAO, W.; FENG, J.; ZHOU, S.; LIU, Y.; TU, L.; CAO, D.; HUANG, C.; HE, X.; CUI, X.; 2024. The variation in climate conditions and firerelated traits across Pinus (Pinaceae) species. *Global Ecology and Conservation*, *54*, e03152. https://doi.org/10.1016/j.gecco.2024.e03152

YIN, C.; HE, B.; YEBRA, M.; QUAN, X.; EDWARDS, A. C.; LIU, X.; LIAO, Z.; 2020. Improving burn severity retrieval by integrating tree canopy cover into radiative transfer model simulation. *Remote Sensing of Environment, 236*, 111454. https://doi.org/10.1016/j.rse.2019.111454