



9CFE-1403

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

Organiza





Detección de cambios en terrenos certificados por PEFC mediante series temporales de imágenes satelitales y el algoritmo CCDC.

GONZÁLEZ GONZÁLEZ, I. (1), ESTEBAN CAVA, J. (1), SALVADOR DEL POZO, M. (2), MARÍN MEGÍA, M. (2), TEJIDO MURIAS, I. (3), TOME MORÁN, J.L. (1)

(1) Agresta Sociedad Cooperativa

(2) PEFC España

(3) Departamento de Biología de Organismos y Sistemas de la Universidad de Oviedo

Resumen

El proyecto “Bosques 3.0: Digitalización y Teledetección del Uso Sostenible, Biodiversidad y Resiliencia de los Bosques Españoles” busca mejorar la gestión forestal sostenible mediante herramientas digitales avanzadas. La certificación PEFC es esencial para garantizar prácticas sostenibles, pero los costos del seguimiento y auditoría pueden ser una barrera para los propietarios privados, especialmente en el caso de superficies pequeñas.

El artículo aborda la implementación de un sistema de computación en la nube para detectar periódicamente cambios en la cobertura vegetal con precisión de manera económicamente sostenible. Explica la metodología utilizada para monitorear distintos tipos de cambio, como cortas a hecho, desbroces, claras e incendios forestales en terrenos certificados, empleando series temporales de imágenes de satélite, índices espectrales clave y el algoritmo CCDC (Continuous Change Detection and Classification). Además, presenta una comparación de los resultados obtenidos en las zonas piloto del proyecto.

Estos avances automatizan el proceso de seguimiento de la superficie certificada y mejoran la eficiencia de los controles, tanto en las auditorías externas como internas, facilitando el cumplimiento de los estándares PEFC. El enfoque basado en datos aumenta la transparencia en la certificación y ofrece información valiosa sobre la dinámica de los bosques. Esta investigación resalta la importancia de integrar tecnología avanzada para mejorar la gestión y conservación de los bosques certificados.

Palabras clave

Gestión forestal, teledetección, digitalización, cambios.

1. Introducción

La gestión sostenible de los recursos forestales en España se articula, en parte, a través de la certificación forestal promovida por PEFC España, una organización sin ánimo de lucro que vela por la sostenibilidad forestal y la puesta en valor de los productos obtenidos. El proceso de certificación de la gestión forestal exige auditorías internas y externas periódicas basadas en muestreo de las unidades de gestión adscritas al certificado, donde las primeras son responsabilidad de la entidad coordinadora del certificado y las segundas son ejecutadas por auditores acreditados. No obstante, la complejidad territorial y la fragmentación de la propiedad forestal en España imponen retos significativos para la cobertura eficiente de estas inspecciones, lo que genera una necesidad urgente de innovación tecnológica que optimice los recursos invertidos y facilite el control



En este contexto, la teledetección se ha identificado como una solución prometedora para mejorar la eficacia del monitoreo forestal, permitiendo una identificación temprana de cambios en la cobertura vegetal y facilitando la priorización de áreas críticas para auditorías de campo. En una colaboración inicial, PEFC España y Agresta llevaron a cabo un proyecto piloto en Galicia que evidenció el alto potencial de esta tecnología para detectar cambios a gran escala con gran precisión; sin embargo, los costos del procesamiento de series de imágenes satelitales Landsat en local limitaron su aplicabilidad a largo plazo. Actualmente el programa Landsat ofrece la posibilidad de acceder a datos ya procesados y disponibles en plataformas en la nube. Esta transición ha transformado la manera de trabajar, pasando de un enfoque más tradicional de procesamiento individual a uno más automatizado (Wulder et al., 2022). Este cambio contribuye a reducir significativamente el tiempo necesario para obtener resultados y, por tanto, los costos asociados a esta tarea.

El Grupo Operativo BOSQUES 3.0 se crea con el objetivo general de crear nuevas herramientas IT para los gestores forestales y las entidades de certificación e impulsar la puesta en valor de los bosques españoles. En concreto, los resultados orientados a teledetección pretenden superar las barreras económicas detectadas en experiencias previas y aprovechar los nuevos avances tecnológicos para desarrollar una plataforma nacional de detección de cambios basada en inteligencia artificial y computación en la nube, que permitan la monitorización continua semestralmente de los bosques, generando mapas de cambios a nivel nacional y adaptándose a diferentes realidades forestales.

Durante su fase piloto, el sistema se probó en Asturias, Huesca y Sevilla, seleccionadas por sus características diversas en términos de estructura y gestión forestal. En una etapa posterior, el sistema se amplió para cubrir toda la España peninsular y las Islas Baleares; esta segunda fase queda fuera del alcance de este artículo.

2. Objetivos

El objetivo del presente artículo es evaluar el sistema de identificación de cambios en la cobertura vegetal mediante técnicas de teledetección en las zonas piloto de Asturias, Huesca y Sevilla.

Desde una perspectiva técnica, enfrentamos dos desafíos clave para desarrollar un sistema de detección de cambios en la cobertura forestal utilizando teledetección: (i) implementar algoritmos de detección de cambios basados en tecnologías de computación en la nube que posibiliten la escalabilidad a nivel nacional, y (ii) hacerlo a un costo accesible para su integración como parte del sistema PEFC.

3. Metodología



3.1 Zona de estudio

El área de estudio engloba tanto los terrenos certificados por PEFC como el resto de masas forestales en las tres provincias piloto. La máscara de masas forestales se obtuvo a partir de información de la Foto Fija de 2018, seleccionando las teselas identificadas como arbolado y/o matorral.

Las provincias de Asturias, Huesca y Sevilla abarcan aproximadamente 10.600 km², 15.600 km² y 14.000 km², respectivamente. De acuerdo con el tercer inventario nacional, el área forestal representa respectivamente el 72,1 %, 59,7 % y 29,3 % de estas superficies.

Las zonas forestales con cobertura arbórea representan aproximadamente el 59% de la superficie forestal en Asturias, destacando los bosques de caducifolias como los más abundantes. Entre las especies predominantes se encuentra una combinación de castaño (*Castanea sativa*) con otras frondosas, como el roble (*Quercus robur*), el abedul (*Betula spp.*), el eucalipto (*Eucalyptus globulus*) y el haya (*Fagus sylvatica*). En el Principado de Asturias, las frondosas dominan ampliamente, ocupando el 86% de la superficie arbolada total. Por su parte, las coníferas representan el 8%, siendo el *Pinus pinaster* y el *Pinus radiata* las especies más frecuentes, mientras que el 6% restante corresponde a mezclas de frondosas y coníferas (Ortega et al., 2011). La región se caracteriza por una alta productividad forestal y una gestión activa, donde principalmente los tratamientos más comunes incluyen las cortas a hecho, mientras que las claras y claros son menos frecuentes, si bien sí se llevan a cabo en los pinares.

En Huesca, la superficie forestal arbolada representa el 66% de la superficie forestal, según datos del Observatorio Forestal Pirenaico. De esta superficie, el 41% corresponde a formaciones de coníferas, el 7% a frondosas y el 52% a masas mixtas. La superficie forestal certificada está compuesta principalmente por pinares de *Pinus sylvestris* y choperas (*Populus spp.*). En cuanto a las prácticas silvícolas predominantes, en las choperas se realizan habitualmente cortas a hecho, mientras que en los pinares se aplican cortas de regeneración y de mejora.

En la provincia de Sevilla, la superficie forestal certificada está compuesta principalmente por formaciones de *Quercus ilex* (encina) y *Quercus suber* (alcornoque) que ocupan un 24 % de la superficie provincial. La gestión forestal se concentra en montes adhesados situados en terrenos con pendiente inferior al 20%, así como en masas mediterráneas ubicadas en áreas de mayor pendiente, donde predominan encinares y matorrales, que además tienen una destacada vocación cinegética. Aunque también se gestionan eucaliptales y pinares destinados a la producción maderera, estas superficies representan una extensión limitada, ligeramente superior a las 100 hectáreas. En cuanto a los tratamientos forestales, las principales intervenciones incluyen desbroces y resalvos en los encinares, con el objetivo de mejorar la estructura y productividad del bosque. Adicionalmente, se realizan densificaciones para incrementar la cobertura vegetal y podas orientadas a fomentar el crecimiento.



La Tabla 1 muestra una caracterización de la superficie certificada en las tres provincias piloto. Destaca especialmente el caso de Asturias, donde se observa un número alto de unidades de gestión forestal (UGF) en relación con la superficie certificada. En esta provincia, 1.328 UGF tienen una extensión inferior a 0,5 ha, mientras que 3.221 UGF no superan 1 ha.

Tabla 1. Caracterización de la superficie forestal certificada en las provincias piloto.

Provincia	Superficie Certificada PEFC (ha)	Número de UGF	UGF, Superficies mínima y máxima (ha)
Asturias	55.585	7.624	0,01 – 2.852
Huesca	76.413	27	3,64 – 23.753,1
Sevilla	43.147	61	60,9 - 4150,1

3.2 Selección de la plataforma

La metodología del proyecto se basa en el uso de la plataforma Google Earth Engine (GEE) (Gorelick et al., 2017), seleccionada tras evaluar diversas soluciones de procesamiento en la nube. GEE es una herramienta que permite el análisis y visualización de datos geoespaciales a escala global, aprovechando la infraestructura de computación de Google. Ofrece acceso a un amplio repositorio de datos geoespaciales, incluyendo imágenes satelitales de Landsat y Sentinel, y dispone de una API compatible con JavaScript y Python para desarrollo interactivo.

Las razones principales para seleccionar GEE como herramienta de análisis fueron su capacidad para gestionar grandes volúmenes de datos de manera eficiente, su acceso gratuito para organizaciones sin ánimo de lucro como PEFC España y la ausencia de requisitos de procesamiento en tiempo real. Sin embargo, la plataforma presenta limitaciones en su capacidad de procesamiento, lo que nos ha obligado a optimizar tanto el código como la parametrización del algoritmo empleado.

3.3 Algoritmo Continuous Change Detection and Classification (CCDC)

En los últimos años, se han desarrollado diversos algoritmos para la detección de cambios a partir de series temporales de imágenes satelitales, como BFAST (Breaks For Additive Seasonal and Trend), LandTrendR (Landsat-based detection of Trends in Disturbance and Recovery), y CCDC (Continuous Change Detection and Classification) (Cai et al., 2022). Entre ellos, optamos por el algoritmo CCDC debido a su capacidad para detectar cambios de manera continua, lo que se ajusta al objetivo de nuestro proyecto de identificar cambios semestrales.

Otra de las características principales del CCDC es su capacidad para procesar datos casi en tiempo real, facilitando la detección y clasificación de cambios



recientes. Además, permite generar mapas de cambio que no solo identifican la ocurrencia del cambio, sino que también lo clasifican en distintas categorías. Esto lo hace ideal para aplicaciones como la monitorización de bosques proporcionando información precisa y actualizada basada en series temporales de datos satelitales. Asimismo, su implementación en GEE (Arévalo et al., 2020) proporcionó una plataforma sólida que permitió un desarrollo con bajos costos y tiempos de procesamiento eficientes, adecuados a las necesidades del proyecto.

El algoritmo CCDC (Zhu & Woodcock, 2014) es un método diseñado para el análisis de series temporales de imágenes satelitales con el propósito de detectar cambios en la cobertura terrestre de manera continua y precisa. Este método utiliza modelos armónicos multitemporales que ajustan una función periódica a cada píxel de las imágenes. El modelo utilizado combina términos lineales y armónicos para capturar patrones estacionales y tendencias a largo plazo en las observaciones. Se destaca la capacidad del modelo para adaptarse a variaciones naturales en la señal, como estacionalidad o ruido, permitiendo así identificar únicamente cambios significativos que rompen con el patrón esperado (Zhu & Woodcock, 2014).

El ajuste inicial del modelo utiliza las primeras doce observaciones libres de nubes, sombras y nieve, enmascaradas mediante el método Fmask (Zhu & Woodcock, 2012), y analiza las tres siguientes para identificar cambios en el comportamiento del píxel. Este análisis grupal en el dominio temporal atenúa efectos efímeros, como ruido o anomalías temporales, por ejemplo, aerosoles densos, humo o inundaciones que pueden confundirse con alteraciones en la cobertura terrestre, y considera un cambio real si las tres observaciones consecutivas están fuera del rango predicho. El umbral de cambio varía según el tipo de perturbación y se adapta a cada píxel usando todas las bandas. El método de mínimos cuadrados calcula el Error Medio Cuadrático (EMC) en cada banda, y las observaciones se comparan con el modelo usando un rango de $\pm 3 \times \text{EMC}$. Si las tres observaciones libres de nubes quedan fuera de este rango, se detecta un cambio en la cobertura (Zhu & Woodcock, 2014). Este método permite generar cartografías de cambio y asociar la detección del cambio a una fecha específica (Pasquarella et al., 2022).




Figura 1. Esquema de funcionamiento de la detección de cambios del algoritmo CCDC

Estudios previos han recomendado el uso de tres observaciones consecutivas para clasificar un píxel como “Cambio” (Zhu & Woodcock, 2014). Sin embargo, al aplicar este criterio en nuestra área de estudio, se observó un aumento en la tasa de falsos positivos, lo que pone de manifiesto la necesidad de realizar ajustes específicos para mejorar la precisión del algoritmo en contextos particulares.

3.4 Desarrollo de productos cartográficos

La metodología se desarrolla en dos fases principales. En primer lugar, se realiza la **detección de cambios**, generando como resultado intermedio una cartografía de “Cambio” – “No Cambio” dentro del rango temporal analizado. En la segunda fase, se **clasifica el tipo de cambio** mediante la combinación de las variables predictoras obtenidas en el paso anterior y el uso del algoritmo Random Forest (Breiman, 2001).




Figura 2. Esquema del flujo metodológico

La **detección de cambios** se inicia con la selección de imágenes Landsat de la colección 2, previamente sometidas a calibración radiométrica, corrección atmosférica y geométrica, para obtener valores precisos de reflectividad. Antes de aplicar el algoritmo CCDC, que incluye su propio método para eliminar nubes, sombras y nieve, realizamos un filtrado inicial para eliminar píxeles afectados por nubes, neblina, sombras, saturación o aerosoles. Este proceso utiliza tres bandas específicas proporcionadas por las imágenes Landsat: *QA_PIXEL*, *QA_RADSAT* y *SR_QA_AEROSOL*. A continuación, se calcularon diversos índices espectrales para cada imagen de la serie temporal. A la hora de seleccionar las bandas espectrales con las que trabajar tuvimos en cuenta dos aspectos, por un lado, debíamos seleccionar el mínimo número de bandas para optimizar y agilizar los procesos en GEE, y, por otro lado, seleccionar bandas que habían demostrado en estudios anteriores su capacidad para detectar cambios en el entorno forestal. Tras este análisis se optó por tres índices principales, el Normalized Burn Ratio (NBR), el Tasseled Cap Wetness (Wetness) y el Normalized Difference Vegetation Index (NDVI), (Kennedy et al., 2010, Grogan et al., 2015)

Una vez generada la serie temporal de índices de vegetación, se aplicó el CCDC para la detección de cambios. Uno de los resultados directos del algoritmo es la magnitud del cambio, donde los valores negativos de los índices empleados indican pérdida de vegetación. Para identificar exclusivamente los tipos de cambio relevantes para el proyecto, se definió un umbral óptimo de magnitud de cambio mediante el uso de una curva ROC (Receiver Operating Characteristic, Bradley A.P., 1997). Los píxeles con valores superiores a este umbral fueron clasificados como “No Cambio”.

En el caso específico de la provincia de Asturias, se emplearon los tres índices de vegetación para generar el mapa de cambios. La magnitud del cambio se definió como la suma de las magnitudes de cambio de cada uno de los índices utilizados, por lo que el umbral se determinó en función de esta suma combinada de



magnitudes. Para las otras dos provincias, se utilizó exclusivamente un índice espectral, ya que la combinación de múltiples índices incrementaba de manera significativa la tasa de falsos positivos. La aparición de falsos positivos es más frecuente en masas forestales abiertas, donde las variaciones en la humedad del suelo pueden generar detecciones de cambios que no forman parte del objeto de estudio. Este fenómeno ha sido especialmente común en la provincia de Sevilla, donde, durante periodos de sequía severa, se han identificado cambios que introducen ruido en la cartografía generada.

Debido a que las características de las masas forestales de las tres provincias piloto son diversas, fue necesario establecer distintos parámetros de configuración del algoritmo para cada una de las provincias piloto. La Tabla 2 muestra los valores de los parámetros de configuración del algoritmo para cada una de ellas. El número de observaciones (**#Obs**) representa el número de observaciones consecutivas necesarias para identificar un cambio. El valor “Chi Square Probability” controla la sensibilidad del algoritmo para detectar cambios. El valor “Min Num Of Years” determina el intervalo mínimo de tiempo, en años, que debe transcurrir antes de que el modelo sea reevaluado. Lambda es el parámetro que regula cuánto simplifica el modelo al ajustar los datos temporales, equilibrando entre capturar cambios reales y evitar sobreajustes a fluctuaciones menores o ruido.

Tabla 2. Parámetros de configuración del algoritmo en las provincias piloto

Provincia	IV	Umbral Mag. Cambio	#Obs	Chi Square Probability	Min Num Of Years	lambda	Detección nubes
Asturias	NDVI Wetness NBR	-2673	6	0,99	1.33	0,002	Banda Verde y SWIR-2
Huesca	Wetness	-141	9				
Sevilla	NBR	-131	12				

Para el testeo del algoritmo, se identificaron los cambios ocurridos entre los años 2017 y 2021. La selección de este período se basó en la disponibilidad de imágenes de muy alta resolución, indispensables para realizar la validación mediante fotointerpretación de los cambios. Como resultado se obtuvieron las cartografías de “Cambio” – “No Cambio” para las tres provincias piloto.

La unidad mínima de mapeo definida para el proyecto fue de 0,5 hectáreas. No obstante, durante las pruebas, se buscó identificar cambios más pequeños, lo que llevó a filtrar en la cartografía de cambios los grupos de píxeles menores a cinco (0,45 ha) en Sevilla. En la Cornisa Cantábrica, debido a las particularidades de la propiedad forestal, este criterio se ajustó eliminando los grupos de píxeles menores a tres (0,27 ha). Del mismo modo, en la provincia de Huesca se aplicó el filtro de 0,27 ha; sin embargo, los análisis realizados hasta la fecha sugieren que, para Huesca, sería más adecuado conservar la unidad mínima original de 0,5 ha a fin de



minimizar los errores de comisión.

En la segunda fase del análisis, se realizó la **clasificación del tipo de cambio** en cuatro clases: “corta a hecho”, “clara”, “desbroce” e “incendio forestal”. Es importante precisar que, en este contexto, se define una clara como una reducción en la densidad de la cobertura arbórea, aunque resulta difícil precisar un porcentaje exacto. Para cada píxel identificado como “Cambio”, se generaron una serie de variables predictoras. Estas incluyeron la magnitud del cambio en los índices espectrales utilizados para la detección, así como los valores de reflectividad de las bandas del verde y SWIR-2 antes y después del cambio. Estos valores se obtuvieron generando imágenes sintéticas al inicio y al final del período analizado. Dichas imágenes se crearon estimando los valores del píxel a partir del modelo armónico ajustado (Arévalo et al., 2020). Por último, se consideraron también los coeficientes asociados a los modelos de regresión armónica. En el caso particular de la provincia de Asturias, además de las magnitudes de cambio de los tres índices espectrales, se incluyó como variable adicional la suma de dichas magnitudes.

Una vez seleccionada la pila de variables predictoras, se utilizó un modelo de clasificación Random Forest para identificar el tipo de cambio. Dado que las condiciones forestales varían significativamente entre las tres provincias piloto, se desarrollaron modelos independientes para cada una de ellas. Esta estrategia permitió ajustar los modelos de manera específica a las distintas realidades forestales y mejorar la precisión de las clasificaciones.

La generación de las áreas de entrenamiento para la clasificación se basó en la cartografía inicial de “Cambio” – “No Cambio” obtenida para el periodo 2017 - 2021. De cara a poder ampliar la muestra de entrenamiento de tipos de cambio, las áreas de entrenamiento se definieron tanto en las provincias pilotopolito como en otras provincias asociadas, seleccionadas por compartir características forestales similares o para tratar de equilibrar la presencia de todas las clases en la muestra de entrenamiento. La delimitación y asignación del tipo de cambio a cada área de entrenamiento se realizaron mediante la fotointerpretación de imágenes de muy alta resolución, obtenidas del Plan Nacional de Ortofotografía Aérea (PNOA) y Google Earth. La Tabla 3 presenta las provincias para las que se definieron áreas de entrenamiento y su relación con las provincias piloto.

A partir de estas áreas de entrenamiento, se ajustó un modelo preliminar utilizando el algoritmo Random Forest para identificar las variables predictoras más relevantes. Con las variables seleccionadas, se construyó el modelo definitivo empleando nuevamente Random Forest, optimizando así su capacidad predictiva.

Finalmente se probaron los modelos entrenados en el periodo 2017-2021 para el año 2022, obteniéndose una cartografía de cambios clasificados para las tres provincias piloto en dicho año.

Tabla 3. Áreas de entrenamiento y variables predictoras más importantes

Provincia	Áreas de entrenamiento	Variables predictoras (*)
Asturias	Pontevedra Asturias	WETNESS_MAG, NBR_MAG, GREEN_start, WETNESS_COS, SWIR2_end, GREEN_end, SWIR2_start, NDVI_SIN, NDVI_MAG, NDVI_COS, MAG_sum, NBR_COS, NBR_SIN
Huesca	Huesca Navarra, Barcelona	SWIR2_end, WETNESS_COS, GREEN_start, SWIR2_start, GREEN_end, WETNESS_INTP, WETNESS_RMSE, WETNESS_SIN, WETNESS_MAG
Sevilla	Sevilla, Badajoz Alicante Castellón	NBR_MAG, NBR_SIN, NBR_COS, NBR_COS2, SWIR2_start, NBR_SIN2, GREEN_start, NBR_RMSE, SWIR2_end, NBR_INTP, GREEN_end

(*) _MAG: hace referencia a la magnitud de cada índice, _sum: a la suma de magnitud de los distintos índices, _start: al valor de la banda al principio del periodo, _end: al valor de la banda al final del periodo, _COS*, _SIN*, _INTP: a los coeficientes del modelo armónico ajustado antes del cambio, _RMSE: error medio cuadrático del modelo ajustado.

3.5 Validación de la cartografía

Se llevaron a cabo dos procesos de validación: el primero evaluó la precisión de la cartografía de “Cambio” - “No Cambio” correspondiente al período 2017–2021, mientras que el segundo validó la cartografía clasificada por tipo de cambio generada para el año 2022.

Validación de la cartografía de “Cambio” – “No Cambio”

La validación de la cartografía se llevó a cabo mediante una muestra aleatoria estratificada basada en las dos clases. Se seleccionaron puntos de validación en cada estrato y se procedió a su fotointerpretación, asignando cada punto a una de las dos categorías. Este proceso permitió evaluar la correspondencia entre los puntos observados y la predicción del modelo. A partir de esta comparación, se generaron las matrices de confusión, que permitieron calcular métricas estándar de precisión como la exactitud global y las tasas de error de omisión y comisión para ambas clases.

Validación de la cartografía según el tipo de cambio

El proceso de validación de la cartografía por tipo de cambio empleó una metodología distinta. Para cada provincia analizada, se utilizaron los cambios registrados en 2022 por el producto Global Forest Change (GFC) (Hansen et al., 2013). De estos cambios, se seleccionaron aleatoriamente entre 150 y 300 polígonos por provincia, considerando únicamente aquellos con una superficie igual o superior a 0,4 hectáreas. La cantidad final de polígonos fotointerpretados dependió de la disponibilidad de imágenes adecuadas para evaluar los cambios ocurridos específicamente en 2022.



Una vez fotointerpretados, los polígonos seleccionados se compararon con la cartografía por tipo de cambio. A cada polígono del producto GFC se le asignó la clase predominante del mapa generado, basada en el valor mayoritario dentro de su área. Finalmente, se construyeron matrices de confusión para evaluar la precisión de la clasificación por tipo de cambio, calculando métricas como la exactitud global y las tasas de error específicas para cada clase de cambio.

4. Resultados 4.1 Cartografía “Cambio” – “No Cambio” para el periodo 2017 – 2021

La Figura 3 presenta las matrices de confusión obtenidas para las tres provincias piloto. En general, los modelos demostraron una alta precisión global, superior al 93%. No obstante, los errores de comisión, que representan la proporción de píxeles clasificados incorrectamente como “Cambio”, fueron elevados en los tres casos, con valores entre 19% y 27%, siendo particularmente altos en la provincia de Huesca. Este valor se espera reducir incrementando el tamaño mínimo de los grupos de píxeles a filtrar, lo que ayudará a eliminar el ruido.

Por otro lado, los errores de omisión, que corresponden a píxeles de cambio no detectados, fueron relativamente bajos en Asturias con un 12% y Huesca con un 9%, mientras que en Sevilla esta clase presentó un error más alto, alcanzando el 19%. En Sevilla, el uso de 12 observaciones consecutivas para identificar un evento como “Cambio” redujo la detección de cambios reales. Sin embargo, al disminuir este número a 6 o 9 observaciones, los errores de comisión se incrementaron significativamente. Lograr un equilibrio en Sevilla resultó complejo, lo que se atribuye principalmente a la presencia de masas forestales de menor densidad, donde el efecto del suelo genera un impacto considerable en la detección de cambios.

Asturias						Huesca						Sevilla					
Observados						Observados						Observados					
		Cambio	No Cambio	Total	Error de comisión			Cambio	No Cambio	Total	Error de comisión			Cambio	No Cambio	Total	Error de comisión
Σ	Cambio	44	10	54	0.19	Σ	Cambio	32	12	44	0.27	Σ	Cambio	39	12	51	0.24
	No Cambio	6	156	162	0.04		No Cambio	3	250	253	0.01		No Cambio	9	496	505	0.02
	Total	50	166	216			Total	35	262	297			Total	48	508	556	
	Error de omisión	0.12	0.06				Error de omisión	0.09	0.05				Error de omisión	0.19	0.02		
	Precisión			0.93			Precisión			0.95			Precisión			0.96	
	Global						Global						Global				

Figura 3. Matrices de confusión para la validación de 'Cambio' y 'No Cambio'

Otro factor que considerar en relación con los errores de comisión es que, al analizar detenidamente la serie temporal de observaciones, a menudo se detectan cambios significativos en la respuesta espectral que no son evidentes durante la fotointerpretación de las imágenes de alta resolución. Estos cambios no visibles podrían atribuirse a claras leves o a masas forestales que están experimentando algún tipo de decaimiento temprano, aún imperceptible en las imágenes de mayor resolución. La Figura 4 ilustra un ejemplo de este fenómeno.




Figura 4. Ejemplo de un cambio identificado por el algoritmo CCDC en 2017 fotointerpretado como “No Cambio“. A) Área clasificada como cambio; B) Imagen de 2015; C) Imagen de 2017; D) Imagen de 2020. Abajo: Serie temporal de observaciones y cambio detectado por el algoritmo en 2017.

4.2 Cartografía por tipo de cambio

El análisis de las matrices de confusión refleja los resultados obtenidos por los tres modelos desarrollados para clasificar los tipos de cambio en Asturias, Huesca y Sevilla. Cada modelo mostró un rendimiento diferente dependiendo de las características locales y la distribución de las clases en cada región.

Asturias								Huesca								Sevilla							
Observados								Observados								Observados							
Map	Class	Cortas	Claras	Desbroces	IIFF	Total	Error de comisión	Map	Class	Cortas	Claras	Desbroces	IIFF	Total	Error de comisión	Map	Class	Cortas	Claras	Desbroces	IIFF	Total	Error de comisión
	Cortas	139	2	5	2	148	0.06		Cortas	15	2	0	2	19	0.21		Cortas	3	1	0	0	4	0.25
	Claras	0	0	0	0	0			Claras	11	59	0	2	72	0.18		Claras	13	45	22	1	81	0.44
	Desbroces	0	0	0	0	0			Desbroces	0	0	0	0	0			Desbroces	14	25	118	0	157	0.25
	IIFF	2	1	18	11	32	0.66		IIFF	2	0	7	5	14	0.64		IIFF	10	2	15	1	28	0.96
	Total	141	3	23	13	180			Total	28	61	7	9	105			Total	40	73	155	2	270	
	Error de omisión	0.01	1.00	1.00	0.15				Error de omisión	0.46	0.03	1.00	0.44				Error de omisión	0.93	0.38	0.24	0.50		
	Precisión Global					0.83			Precisión Global					0.75			Precisión Global						0.62

Figura 5. Matrices de confusión para la validación por tipo de cambio.

El desequilibrio de la muestra de validación entre los distintos tipos de cambio se debió a las diferencias en las realidades forestales de las provincias piloto, donde predominan ciertos tipos de tratamientos. Por ello, la muestra de entrenamiento (Tabla 3) se amplió a provincias aledañas o con características similares, con el objetivo de aumentar la variabilidad de los tipos de cambio representados en las áreas de entrenamiento.

En **Asturias** el modelo aplicado alcanzó una **precisión global del 83%**, mostrando precisiones moderadas con variaciones significativas entre las clases.

La clase “corta” es la mejor clasificada con errores de comisión y de omisión muy bajos. Las clases “claras” y “desbroces” no fueron detectadas, siendo la mayoría de los desbroces clasificados como incendios forestales, lo que dio lugar a un error de comisión elevado para la clase incendios forestales.

El modelo desarrollado para **Huesca** obtuvo una **precisión global del 75%**, con precisiones también desiguales entre las clases. El modelo clasificó la clase “corta” con un error de comisión de 0,21 y un alto error de omisión de 0,46, lo que indica las dificultades del modelo para identificar esta clase de forma consistente. La clase “clara” fue la mejor detectada con errores de comisión y omisión bajos. De la misma manera que en Asturias, la clase de “desbroce” no fue detectada, lo que evidencia limitaciones en la capacidad del modelo para detectar esta clase. La clase “Incendio” también mostró errores de comisión y omisión altos. El modelo para Huesca es bueno para la detección de claras, pero su desempeño en cortas, desbroces e incendios requiere de ajustes para mejorar la precisión.

El modelo aplicado en **Sevilla** presentó la **precisión global más baja (62%)**, con resultados variables entre las distintas clases. Aunque mostró mayor efectividad en la clase “desbroce”, su rendimiento fue limitado en las demás categorías, especialmente en cortas e incendios.




Figura 6. Ejemplo de la cartografía por tipo de cambio generada para Asturias(izquierda), Huesca (centro) y Sevilla (derecha) en 2022. Representación de las clases: Rojo, incendios forestales; Verde oscuro, cortas; Verde claro, claras; Marrón, desbroces.

4.3 Implementación del desarrollo en una aplicación de uso interno

Con el objetivo de facilitar el uso de la herramienta desarrollada para el personal técnico de PEFC España y permitir la generación semestral de cartografías de cambios destinadas a uso para la selección de áreas a auditar en función del riesgo, se diseñó un formulario intuitivo en GEE. Este formulario

permite a los usuarios seleccionar de manera sencilla las fechas específicas para la detección de cambios, así como las provincias de interés. La Figura 7 presenta un ejemplo preliminar del diseño del formulario, concebido para optimizar su funcionalidad y accesibilidad.




Figura 7. Formulario preliminar para la generación semestral de cartografías de cambios

5. Discusión

El sistema de detección y clasificación de cambios desarrollado en el Grupo Operativo “Bosques 3.0” representa un avance significativo en la aplicación de tecnologías de teledetección y análisis automatizado para la gestión sostenible de los recursos forestales en España. Los resultados obtenidos en las tres provincias piloto—Asturias, Huesca y Sevilla—permiten evaluar tanto las fortalezas como las limitaciones del sistema desarrollado.

La implementación del algoritmo CCDC en las zonas piloto permitió generar cartografías de “Cambio” – “No Cambio” con una alta precisión global en la mayoría de los casos. No obstante, los errores de comisión y omisión presentaron variaciones significativas entre provincias, reflejando la influencia de las características locales en la capacidad del algoritmo para detectar cambios. En la provincia de Huesca, el error de comisión fue elevado (27%), lo que podría mitigarse filtrando grupos de píxeles menores a cinco en lugar de tres tal y como se ha intentado en la cartografía actual. De esta forma eliminamos el ruido al tiempo que mantenemos la unidad mínima de mapeo de 0,5 ha establecida para el proyecto. En contrapartida, esta medida podría incrementar el error de omisión, que actualmente este se sitúa en un 9%, por lo que un aumento leve seguiría siendo aceptable para el seguimiento de los cambios sobre terreno.

En contraste, en Sevilla el error de omisión alcanzó el 19%, debido al incremento en el número de observaciones necesarias para identificar un evento



como cambio, implementado para reducir el ruido característico de las masas forestales más abiertas. Estas diferencias ponen de manifiesto las dificultades del algoritmo para ajustar su sensibilidad y rendimiento a las condiciones particulares de cada región.

El análisis detallado de los errores de comisión reveló que, en algunos casos, los cambios detectados en la respuesta espectral no eran perceptibles en las imágenes de alta resolución utilizadas para la fotointerpretación. Las cortas totales o parciales son más fáciles de fotointerpretar ya que sus efectos permanecen en el tiempo; sin embargo, si se trata de claras en las que únicamente se extrae un porcentaje bajo de árboles, este efecto puede ser no visible en el momento en el que la ortoimagen de alta resolución está disponible (Puettmann et al., 2016). Además, esta discrepancia podría deberse a procesos de decaimiento forestal que, aunque detectables mediante índices espectrales, no generan alteraciones visuales evidentes en las imágenes.

La precisión de los modelos al clasificar tipos de cambio, como cortas, claras, desbroces e incendios, mostró importantes variaciones entre provincias. En Asturias, el modelo alcanzó una precisión global del 83%, con un excelente desempeño en la clase “corta”, pero dificultades para detectar “claras” y “desbroces”. El error de comisión en la clase “cortas”, con un valor del 6%, es comparable al reportado por Chirici et al. (2011), quienes obtuvieron un error del 7,9% utilizando imágenes SPOT. En Huesca, la precisión global fue del 75%, destacando la clase “clara” como la mejor clasificada, mientras que las clases “corta”, “desbroce” e “incendio” presentaron errores elevados. Sevilla registró la precisión global más baja (62%). La precisión limitada en ciertas clases, como los desbroces y las claras, evidencia la necesidad de integrar más variables predictoras que puedan capturar mejor las dinámicas asociadas a estos tipos de cambio.

Dentro de los posibles pasos hacia la obtención de un producto más preciso se debe considerar la corrección topográfica de las imágenes (Tejido-Murias et al. 2024), la cual se ha visto que tiene una influencia significativa a nivel de clasificación de coberturas, y la cual debe estudiarse en el análisis de series temporales. Aunque este proceso presente un importante desafío debido a las limitaciones computacionales de la plataforma GEE.

Así mismo, los resultados resaltan la influencia crítica de la muestra de entrenamiento en la precisión de la clasificación. Disponer de conjuntos de entrenamiento fiables, verificables y equilibrados será esencial para mejorar el rendimiento de los modelos en el futuro. La colaboración entre grupos de investigación dedicados a este campo podría impulsar avances significativos mediante el intercambio de bases de datos, como la del Subsistema de Información Territorial, EIKOS, del Inventario Español del Patrimonio Natural y de la Biodiversidad (IEPNB), desarrollado por MITECO.

6. Conclusiones



El estudio con tres provincias piloto confirma que la teledetección es una herramienta eficaz para el monitoreo continuo y automatizado de las masas forestales. A pesar de contar con ciertas limitaciones, el sistema ha demostrado su capacidad para optimizar los procesos de seguimiento en superficies forestales certificadas. El uso de plataformas como Google Earth Engine, combinado con algoritmos avanzados de detección de cambios, proporciona información precisa y actualizada que respalda la gestión forestal con un coste económico reducido. Además, este enfoque basado en datos refuerza la transparencia en la certificación forestal y facilita el cumplimiento de estándares internacionales como los de PEFC.

Las herramientas de teledetección desarrolladas en el marco del Grupo Operativo “Bosques 3.0” representan un avance significativo en la digitalización de la gestión forestal en España. No obstante, su éxito a largo plazo dependerá de la capacidad para adaptar los modelos a las condiciones locales, incorporar nuevas fuentes de datos y mejorar la precisión en la clasificación de los tipos de cambio. Este proyecto ha demostrado la viabilidad técnica de un sistema escalable a nivel nacional de detección continua de cambios en la cobertura forestal mediante teledetección, contribuyendo a la mejora en la evaluación y seguimiento de la gestión forestal bajo los estándares de certificación de PEFC.

Los resultados obtenidos destacan tanto las fortalezas como los desafíos pendientes de abordar, y han sido incorporados en la etapa final del desarrollo del proyecto para optimizar el proceso de escalado a las demás provincias. En los próximos meses, la herramienta será implementada por PEFC España en el ámbito nacional y tanto entidades coordinadoras de los certificados, como los auditores acreditados comenzarán a hacer uso de los resultados, lo que permitirá realizar una validación exhaustiva del algoritmo y de sus resultados. Este proceso proporcionará una comprensión aún más detallada de las condiciones en las que el sistema funciona con mayor eficacia, además de aportar información clave para futuras mejoras y ajustes.

7. Agradecimientos

Queremos expresar nuestro agradecimiento al equipo técnico de Google AI for Nature and Society por su valioso apoyo en la búsqueda de soluciones óptimas basadas en la nube, fundamentales para el desarrollo de los algoritmos requeridos en este proyecto.

El Grupo Operativo “Bosques 3.0” es el responsable del contenido de este artículo y ha recibido para su proyecto de innovación una subvención de 352.139,20 €. El importe del proyecto es financiado al 100% con fondos procedentes del Instrumento de Recuperación Europeo (EU Next Generation), tal como se establece en el Real Decreto 169/2018, de 23 de marzo.

La Dirección General de Desarrollo Rural, Innovación y Formación Agroalimentaria (DGDRIFA), es la autoridad de gestión encargada de la aplicación de la ayuda del FEADER. «Fondo Europeo Agrícola de Desarrollo Rural: Europa



invierte en las zonas rurales»



8. Bibliografía

ARÉVALO, P., BULLOCK, E.L., WOODCOCK, C.E., OLOFSSON, P.; 2020. A Suite of Tools for Continuous Land Change Monitoring in Google Earth Engine. *Front. Clim.* 2, 576740.

BRADLEY, A.P.; 1997. The use of the area under the ROC curve in the evaluation of machine learning algorithms. *Pattern Recognition* 30, 1145–1159.

BREIMAN, L.; 2001. Random Forest. *Machine Learning* 45, 5–32.

CAI, Y., SHI, Q., LIU, X.; 2022. Mapping forest disturbance using pure forest index time series and ccdc algorithm. *Int. Arch. Photogramm. Remote Sens. Spatial Inf. Sci.* XLVIII-3/W1-2022, 1–6.

CHIRICI, G., GIULIARELLI, D., BISCONTINI, D., TONTI, D., MATTIOLI, W., MARCHETTI, M., CORONA, P., 2011. Large-scale monitoring of coppice forest clearcuts by multitemporal very high resolution satellite imagery. A case study from central Italy. *Remote Sensing of Environment* 115, 1025–1033.

ORTEGA, M.E, DE LA MANO, D., FERNÁNDEZ, S., GARRIDO B.; 2011. El monte en Asturias, Gobierno del Principado de Asturias. Consejería de Medio Rural y Pesca. Dirección General de Política Forestal. 84.

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.

GROGAN, K., PFLUGMACHER, D., HOSTERT, P., KENNEDY, R., FENSCHOLT, R.; 2015. Cross-border forest disturbance and the role of natural rubber in mainland Southeast Asia using annual Landsat time series. *Remote Sensing of Environment* 169, 438–453.

HANSEN, M.C., POTAPOV, P.V., MOORE, R., HANCHER, M., TURUBANOVA, S.A., TYUKAVINA, A., THAU, D., STEHMAN, S.V., GOETZ, S.J., LOVELAND, T.R., KOMMAREDDY, A., EGOROV, A., CHINI, L., JUSTICE, C.O., TOWNSHEND, J.R.G.; 2013.



High-Resolution Global Maps of 21st-Century Forest Cover Change. *Science* 342, 850–853.

KENNEDY, R.E., YANG, Z., COHEN, W.B.; 2010. Detecting trends in forest disturbance and recovery using yearly Landsat time series: 1. LandTrendr — Temporal segmentation algorithms. *Remote Sensing of Environment* 114, 2897–2910.

PASQUARELLA, V.J., ARÉVALO, P.; BRATLEY, K.H., BULLOCK, E.L., GORELICK, N., YANG, Z., KENNEDY, R.E., 2022. Demystifying LandTrendr and CCDC temporal segmentation. *International Journal of Applied Earth Observation and Geoinformation* 110, 102806.

PUETTMANN, K., ARES, A., BURTON, J., DODSON, E., 2016. Forest Restoration Using Variable Density Thinning: Lessons from Douglas-Fir Stands in Western Oregon. *Forests* 7, 310.

ROBLA GONZÁLEZ, E.; VALLEJO BOMBÍN, R; LERNER CUZZI, M.; 2017. La Foto Fija del Mapa Forestal de España, fuente de información para el cálculo de tendencias e indicadores de los ecosistemas forestales españoles. Principales resultados. 7º Congreso Nacional Forestal. Plasencia.

TEIJIDO-MURIAS, I., BARRIO-ANTA, M., y LÓPEZ-SÁNCHEZ, C. A. 2024. Evaluation of Correction Algorithms for Sentinel-2 Images Implemented in Google Earth Engine for Use in Land Cover Classification in Northern Spain. *Forests*, 15(12), 2192.

WULDER, M. A., ROY, D. P., RADELOFF, V. C., LOVELAND, T. R., ANDERSON, M. C., JOHNSON, D. M., HEALEY, S., ZHU, Z., SCAMBOS, T. A., PAHLEVAN, N., HANSEN, M., GORELICK, N., CRAWFORD, C. J., MASEK, J. G., HERMOSILLA, T., WHITE, J. C., BELWARD, A. S., SCHAAF, C., WOODCOCK, C. E., ... COOK, B. D.; 2022. Fifty years of Landsat science and impacts. *Remote Sensing of Environment*, 280, 113195.

ZHU, Z., WOODCOCK, C.E.; 2012. Object-based cloud and cloud shadow detection in Landsat imagery. *Remote Sensing of Environment* 118, 83–94.

ZHU, Z., WOODCOCK, C.E.; 2014. Continuous change detection and classification of land cover using all available Landsat data. *Remote Sensing of Environment* 144, 152–171.