

9CFE-1452



Análisis de la importancia de las correcciones atmosféricas, topográficas y sus parámetros asociados en imágenes ópticas de satélite para su uso en la clasificación de coberturas vegetales en áreas montañosas

TEIJIDO-MURIAS, I., LÓPEZ-SÁNCHEZ, C.A. y BARRIO-ANTA, M

Grupo de Investigación SMartForest. Departamento de Biología de Organismos y Sistemas, Escuela Politécnica de Mieres, Universidad de Oviedo, Campus Universitario de Mieres, C/Gonzalo Gutiérrez Quirós S/N, 33600 Mieres (España).

Resumen

En este estudio se examinó el efecto de las correcciones atmosféricas, topográficas y de BRDF aplicadas sobre las imágenes de Sentinel-2 en Google Earth Engine (GEE) para su uso en la clasificación de coberturas. El estudio se llevó a cabo en un área de orografía compleja en el norte de España y utilizó las parcelas del Inventario Forestal Nacional de España y otras parcelas ubicadas sistemáticamente para cubrir clases no forestales. Se utilizaron un total de 2,991 parcelas interpretadas fotográficamente y 15 imágenes de Sentinel-2, adquiridas en verano con una resolución espacial de 10-20 m por píxel. El objetivo general fue determinar el nivel óptimo de corrección de imágenes dentro de GEE para su uso posterior en el análisis de series temporales de imágenes. Se prestó especial atención a la clasificación de la cobertura por las principales especies forestales comerciales: *Eucalyptus globulus*, *Eucalyptus nitens*, *Pinus pinaster* y *Pinus radiata*. El algoritmo Py6S, utilizado para la corrección atmosférica, proporcionó el mejor compromiso entre el tiempo de ejecución y el tamaño de la imagen, en comparación con otros algoritmos como Sen2Cor y SIAC. Para corregir el efecto topográfico, se probó el algoritmo SCS+C con modelos digitales de elevación (MDTs) de tres resoluciones espaciales diferentes (90, 30 y 10 m por píxel). La combinación de Py6S, el algoritmo SCS+C y el MDT de alta resolución espacial (10 m por píxel) produjo la mayor precisión, lo que demostró la necesidad de ajustar la resolución espacial del DEM al tamaño del píxel de la imagen. Utilizamos la función BRDF Ross-Thick / Li-Sparse-Reciprocal para corregir la variación en la reflectividad capturada por el sensor. Las correcciones de BRDF no mejoraron significativamente la precisión de la clasificación de la cobertura terrestre con las imágenes de Sentinel-2 adquiridas en verano; sin embargo, mantuvimos esta corrección para el análisis de series temporales posterior de las imágenes, ya que esperábamos que fuera de mucha mayor importancia en imágenes con ángulos de incidencia solar más grandes. Nuestro conjunto de datos final propuesto (Py6S_AT10B), con correcciones de los efectos atmosféricos, topográficos y de BRDF con un DEM de resolución espacial de 10 m por píxel, produjo mejores estadísticas de bondad de ajuste que otros conjuntos de datos disponibles en el catálogo de GEE. Por lo tanto, se pudo comprobar que las imágenes de Sentinel-2 actualmente disponibles en GEE no son las más precisas para construir mapas de clasificación de coberturas terrestres en áreas con orografía compleja, como el norte de España.

Palabras clave

Sentinel-2; google earth engine; random forest; ifn;

1. Introducción

Determinar la extensión espacial de diferentes tipos de cobertura forestal es algo fundamental en la evaluación de recursos forestales y la planificación forestal. Tradicionalmente, se han llevado a cabo inventarios forestales que delimitan la distribución de la cobertura forestal mediante la fotointerpretación de imágenes aéreas y/o satelitales (BARRETT et al., 2016), como el Mapa Forestal Español. Sin



embargo, este método es insuficiente para áreas grandes con altos índices de cambio en la cobertura terrestre debido a actividades como la tala o los incendios forestales, ya que la actualización de estos productos se demora en el tiempo (ALONSO et al., 2021).

La combinación de imágenes satelitales multiespectrales de alta resolución con herramientas para el análisis de grandes conjuntos de datos permite la automatización del mapeo de grandes áreas con alta resolución temporal (WULDER et al., 2018). A pesar de las numerosas ventajas, también deben superarse muchas dificultades relacionadas con el uso de datos satelitales, ya que el procesamiento de imágenes es complicado y depende de varios factores, incluidos el área de estudio, el tipo de vegetación, el sensor y el modelo digital de elevación (VANONCKELEN et al., 2013).

En cuanto a los sensores ópticos, varios factores pueden distorsionar la intensidad de la energía electromagnética registrada por los satélites: i) el tipo y funcionamiento del sensor; y ii) las condiciones atmosféricas y de topografía, así como los ángulos de iluminación solar (CHUVIECO, 1990; BALTHAZAR et al., 2012; SOLA et al., 2016).

El proceso de corrección comienza con la generación de las imágenes en el techo de atmosfera (Top-Of-Atmosphere, ToA) a partir de los datos en bruto, este primer paso incluye correcciones radiométricas y geométricas (ortorrectificación). Este tipo de producto ToA es uno de los primeros a los que se puede tener acceso y generalmente es proporcionado por las agencias espaciales en repositorios disponibles para descarga gratuita. La corrección geométrica es esencial para el análisis multi-sensor y multi-temporal, de esta forma se asegura la misma posición del píxel permitiendo la comparabilidad entre uno y otro. Este tipo de corrección a veces se refiere como "corrección del terreno" (terrain-correction), este desafortunado nombre lleva a confusión con la corrección topográfica (topographic-correction) (YOUNG et al., 2017). Sin embargo, es esencial diferenciar entre la corrección topográfica (radiométrica) y la corrección del terreno (geométrica), independientemente del nombre que se dé a una u otra, ya que no toman en cuenta los mismos efectos (SOLA et al., 2016).

Enfocándonos en los efectos que distorsionan la imagen en la atmosfera (Bottom-of-Atmosphere, BoA) y que necesitan ser corregidos, podemos clasificar los niveles de corrección en tres grupos: (i) corrección atmosférica, (ii) corrección topográfica y (iii) corrección de la función de perturbación de reflectancia bidireccional (BRDF) (SANDMEIR et al., 1997). Varios componentes atmosféricos afectan las características de la energía electromagnética detectada por los sensores ópticos de los satélites. De manera similar, la topografía distorsiona la iluminación solar, lo que resulta en una alta variación en la respuesta de reflectancia para características de terreno similares (VERAVERBEKE et al., 2010). Para compensar las variaciones causadas por diferencias en pendiente, orientación y propiedades atmosféricas, se ha recomendado el uso de la corrección topográfica (SOLA, 2016) junto con la corrección atmosférica (SANDMEIR et al., 1997) para el pre-procesamiento de imágenes en áreas montañosas (VANONCKELEN et al., 2014). Además, se ha demostrado que estos tipos de corrección son más importantes aún en la clasificación de uso del suelo multitemporal derivada de series temporales de imágenes (YOUNG et al., 2017).

Sin embargo, no hay un acuerdo claro sobre el orden en el que deben aplicarse las correcciones. Así, algunos autores aplican la corrección topográfica



directamente a las imágenes ToA (HOSHIKAWA et al., 2014), mientras que otros utilizan la siguiente secuencia para las tres correcciones mencionadas: (i) adquisición de imágenes BoA tras la corrección atmosférica, (ii) corrección topográfica de la imagen BoA y (iii) uso de la corrección BRDF para minimizar el efecto de la BRDF en la imagen (GAO et al., 2009; BALTHAZAR et al., 2012; VANONCKELEN et al., 2013; ROUPIOZ et al., 2014).

Los satélites Sentinel-2A y Sentinel-2B, lanzados por la Agencia Espacial Europea (ESA) a través de su programa Copernicus en 2015 (S2A) y 2017 (S2B), tienen una resolución temporal de cinco días y las imágenes incluyen 13 bandas espectrales con resoluciones espaciales que varían entre 10, 20 y 60 m/píxel dependiendo de la banda (DRUSCH et al., 2012). Los altos niveles de resolución temporal y espacial han permitido la estimación de variables forestales con suficiente detalle espacial para inventarios forestales y otros propósitos de gestión forestal (CHIRICI et al., 2020; NOVO-FERNÁNDEZ et al., 2024). Estas imágenes se han convertido en una fuente indispensable de datos de teledetección para la investigación forestal en los últimos años (HU et al., 2020). El equipo de Sentinel-2 de la Agencia Espacial Europea desarrolló una herramienta para aplicar los diferentes tipos de corrección a las imágenes de Sentinel-2: Sen2Cor. Esta herramienta de acceso gratuito se puede instalar y usar en cualquier ordenador para obtener la imagen más representativa de un área específica, tras aplicar las correcciones atmosférica, topográfica y BRDF (MUELLER-WILM, 2019).

Recientemente se han propuesto diferentes iniciativas para proporcionar conjuntos de datos procesados para su uso por parte investigadores no expertos en teledetección. Los Datos Listos para Análisis del Comité en Satélites de Observación de la Tierra (Committee on Earth Observation satellite- Analysis Ready Data; CEOS-ARD) son datos satelitales que ya han sido procesados por expertos, lo que permite un análisis inmediato con un mínimo de esfuerzo adicional por parte del usuario. Sin embargo, estas iniciativas están lejos de ser aplicables a escalas locales o aquellas que requieren una alta precisión debido a la heterogeneidad de diferentes regiones, las diferentes combinaciones de algoritmos, así como los diferentes tipos y resoluciones de información disponibles para realizar las correcciones (Modelos digitales del terreno MDT o información acerca de la atmósfera).

Las plataformas comerciales de computación en la nube, como Google Earth Engine (GEE), están proliferando rápidamente debido a su sencillez de uso y su oferta de análisis y almacenamiento de datos en servidores remotos (AMANI et al., 2020). GEE combina un enorme catálogo de imágenes satelitales y conjuntos de datos geoespaciales a escala global ofreciendo también el procesamiento de grandes cantidades de datos (AMANI et al., 2020). Aunque es una herramienta muy útil para analizar datos geoespaciales, también presenta varios inconvenientes; algunos métodos de corrección de imágenes, como Sen2Cor, no están integrados en GEE, que solo puede usar los productos de nivel 1C y nivel 2A, disponibles en el repositorio de la ESA; la capacidad de exportación está limitada a un número máximo de píxeles, así como la capacidad de operar con objetos vectoriales que se encuentra también limitada. Para maximizar el potencial de la plataforma GEE en el marco de este trabajo, las diferentes correcciones deben aplicarse a los productos de nivel 1C para obtener la mejor imagen del área de estudio.

Los Modelos Digitales de Elevación (MDTs) proporcionan información sobre la altitud del terreno, lo que permite la creación de diferentes capas, como pendiente y orientación, necesarias para implementar la corrección topográfica. Existen



fuentes de datos globales con MDTs derivadas de análisis de imágenes radar con una resolución espacial de 90 m px-1 y otro casi global con una resolución espacial de 30 m px-1, ambos desarrollados por NASA en la Misión topográfica Radar Shuttle (SRTM). El programa Copernicus de la ESA ha generado un producto similar, un Modelo Digital de Superficie (MDS), que representa la superficie de la Tierra e incluye edificios, infraestructura y vegetación. No utilizamos el DSM en este estudio, ya que las copas de las especies de interés no permanecen constantes en el tiempo. Para la zona de estudio se dispone del MDT generado por el Instituto Geográfico Nacional de España, con una resolución espacial de 5 m px-1, derivado de una nube de puntos LIDAR con una densidad de 0.5 puntos m⁻². Aunque solo está disponible para España, este MDT tiene una ventaja importante, ya que el enfoque basado en LIDAR ofrece una mejor resolución espacial (NOVO-FERNÁNDEZ et al., 2019). Al utilizar diferentes MDTs de alta resolución, podemos comparar el efecto de esta variable (resolución) en la corrección topográfica, lo que nos permitirá seleccionar la mejor opción para nuestros propósitos.

La región de estudio, el norte de España, es un área con una topografía compleja, con grandes diferencias en elevación y pendiente. Estas características dificultan el uso de la teledetección para monitorizar los recursos forestales. La investigación donde se encuadra este estudio se ha orientado al desarrollo de un sistema automático para la estimación del recurso forestal para las especies más productivas del norte de España, basado en datos de teledetección e integrado en la plataforma GEE. Para alcanzar este objetivo se requieren de dos fases diferentes. La primera, consiste en el desarrollo de una clasificación automática de la cobertura forestal y, la segunda, en el desarrollo de modelos de crecimiento y producción con variables obtenidas de datos adquiridos por teledetección activa o pasiva como predictores. La clasificación automática de coberturas es esencial para delimitar geoespacialmente la superficie ocupada por cada especie, lo que permitirá extraer los valores de producción para cada especie.

2. Objetivos

El objetivo general de esta investigación fue establecer los mejores algoritmos de corrección atmosférica, topográfica y BRDF para las imágenes de satélite Sentinel-2 disponibles en la plataforma GEE. Este objetivo forma parte de la primera fase del estudio, que se completará pronto con (i) un análisis de series temporales de imágenes para tener en cuenta los factores fenológicos en la clasificación de la cobertura terrestre, y (ii) el uso de los mejores algoritmos de aprendizaje automático y profundo para una clasificación precisa de la cobertura terrestre.

3. Metodología

3.1. Área de Estudio

El estudio abarcó cuatro comunidades autónomas del norte de España: Galicia, Asturias, Cantabria y Euskadi (40.6° a 45.0° N; -9.6° a -1.5° W), cubriendo un área total de 52,821.44 km². Esta zona pertenece principalmente a la biorregión atlántica y se caracteriza por condiciones templadas (las temperaturas anuales medias varían entre 11.5 °C y 14.5 °C) con precipitaciones bastante uniformemente distribuidas a lo largo del año, a menudo superando los 1,000 mm anuales. Estas favorables condiciones hacen que la región sea una de las áreas forestales más importantes de España, con grandes extensiones de bosques nativos y plantaciones forestales que ocupan un área de 25,158 km². La orografía es compleja debido a la

alta variabilidad en la pendiente y la elevación (que va desde el nivel del mar hasta 2,650 m sobre el nivel del mar), lo que influye en gran medida en la distribución de la cobertura del suelo (bosques, pastizales, áreas antropogénicas, etc.). Por lo tanto, el bosque es el tipo de cobertura del suelo dominante (47.07%), seguido de cultivos y pastos (27.53%), matorral (21.47%), artificial (3.3%) y cuerpos de agua (0.65%). En las áreas arboladas, la especie arbórea predominante es *Eucalyptus globulus* (22.5%), seguida de *Pinus pinaster* (20.2%), *Quercus robur* (15.5%), *Quercus pyrenaica* (8%), *Castanea sativa* (8%), *Pinus radiata* (7.5%) y *Fagus sylvatica* (5.7%).

La forma y el tamaño de la propiedad forestal son factores importantes que determinan la precisión de la clasificación de la cobertura del suelo mediante imágenes de satélite. En el norte de España, la superficie forestal es principalmente de propiedad privada y se divide en pequeñas parcelas. Las plantaciones de las especies forestales más productivas (*E. globulus*, *P. pinaster* y *P. radiata*) se encuentran en parcelas dispersas y pequeñas (microparcelas con una superficie media de solo 0.26 ha en algunas áreas) y a menudo en franjas estrechas, lo que complica en gran medida el uso de imágenes obtenidas a través de teledetección con resoluciones de 10 m px-1.

3.2. Datos utilizados

Se prepararon tres fuentes de datos para determinar el mejor enfoque para corregir las imágenes de Sentinel-2 en la plataforma GEE: (i) datos de campo, (ii) datos de Sentinel-2 y (iii) modelos digitales del terreno (MDTs).

3.2.1. Datos de Campo

Se desarrollaron diferentes rejillas para la ubicación sistemática de parcelas circulares de 25 m de radio para el entrenamiento de la clasificación de la cobertura del suelo. Las parcelas utilizadas para determinar la cobertura forestal forman parte de la red de parcelas permanentes del cuarto Inventario Forestal Nacional de España (IFN4) y están localizadas en los nodos de una rejilla UTM de 1 km. Para una clasificación precisa de la cobertura de las parcelas, la fotointerpretación se basó en imágenes del Programa Nacional de Ortofotografía Aérea de España para 2017 (PNOA-2017) y en la actualización del cuarto Inventario Forestal Nacional (IFN4.5) para las especies forestales más productivas en 2018, así como en el cuarto IFN 4 para las restantes especies forestales.

Las parcelas de muestreo necesarias para representar otras clases de cobertura terrestre no forestal se obtuvieron utilizando dos rejillas UTM, de 1 km x 1 km y 5 km x 5 km, respectivamente. En total, se consideraron 2,991 parcelas para el análisis en este estudio, distribuidas entre las clases de uso del suelo en proporción a su extensión en el territorio. En este caso, la fotointerpretación de las parcelas se basó en PNOA-2017 y en las clases de Corine Land Cover de 2018 (CLC-2018). Se utilizó el software QGIS® (v. 3.30.1) para la fotointerpretación de las parcelas.

Tabla 1. Clasificación adoptada en el presente estudio, 3 niveles y numero de parcelas por clase.

Clase de cobertura (Nº plots)	Especie	FCC	Nº subplots
Áreas artificiales (98)	-	None	98
Cultivos y pastos (824)	-	None	824

Bosque de frondosas (575)	-	None	575
Bosque de eucalipto (283)	<i>Eucalyptus globulus</i>	FCC > 70%	123
		40% < FCC < 70%	116
		10% < FCC < 40%	20
<i>Eucalyptus nitens</i>	FCC > 70%		8
		40% < FCC < 70%	14
		10% < FCC < 40%	4
Bosque de coníferas (371)	<i>Pinus pinaster</i>	FCC > 70%	53
		40% < FCC < 70%	34
		10% < FCC < 40%	
<i>Pinus radiata</i>	FCC > 70%		125
		40% < FCC < 70%	62
		10% < FCC < 40%	8
Otras coníferas	None		92
Bosque mixto (179)	<i>Pinus sp.</i> + <i>Eucalyptus sp.</i>	None	93
<i>Eucalyptus sp.</i> + Frondosas	None		31
<i>Pinus sp.</i> + Frondosas.	None		56
Matorrales (642)	-	None	642
Agua (19)	None		19

3.2.2. Datos de Sentinel-2

Utilizamos imágenes multiespectrales de la constelación de satélites Sentinel-2 (dos satélites gemelos en órbita polar) disponibles gratuitamente en el Copernicus Open Access Hub (<https://scihub.copernicus.eu/>, acceso el 21 de diciembre de 2023) y en los repositorios de la plataforma Google Earth Engine (GEE). Las imágenes fueron procesadas a nivel 1C, lo que significa que incluyen correcciones radiométricas y geométricas, así como ortorrectificación (ESA, 2021). Estas imágenes se distribuyen en un mosaico, donde cada una de la unidad mínima se denomina “tile”. Utilizamos un total de 15 imágenes, una por “tile”, para cubrir la región de interés en la época del año que minimiza el ángulo de incidencia solar (verano).

3.2.3. Datos de Elevación Digital

Para la realización de las correcciones anteriormente mencionadas se requiere de un MDT. Se utilizaron dos MDT proporcionados por la NASA Shuttle Radar Terrain Mission (SRTM), con resoluciones espaciales de 90 m por píxel (SRTM Digital



Elevation Data Version 4) y 30 m por píxel (SRTM Digital Elevation Data Version 3). Con el objetivo de comprobar la influencia de la resolución del MDT en las diferentes correcciones, a mayores se utilizó el MDT de alta resolución espacial de 5 m por píxel, desarrollado por el Centro Nacional de Información Geográfica de España (CNIG, 2022).

3.3. Análisis de los datos

3.3.1. Parcelas de campo y clases de cobertura

Primero se clasificaron las 2,991 parcelas de tierra en 8 clases principales de cobertura. Luego, aquellas que incluían eucaliptos y coníferas se incluyeron en clases finales más detalladas, según su composición de especies y el porcentaje de Fracción de Cobertura Cubierta (FCC) (Tabla 1). Las parcelas forestales se clasificaron como masas puras cuando el área basimétrica de la especie principal superaba el 80% del área basimétrica total dentro de la parcela; de lo contrario, se clasificaron como bosque mixto. Se incluyeron las parcelas en el grupo de bosque mixto cuando el área basal de la especie principal era inferior al 80% y el área basimétrica de las especies secundarias superaba el 20%, de manera similar a lo indicado en el Mapa Forestal Nacional Español. Además, distinguimos 3 tipos de bosque mixto: *Pinus* sp + *Eucalyptus* sp.; *Eucalyptus* sp. + especies de hoja caduca; y *Pinus* sp. + especies de hoja caduca. La Fracción de Cobertura Cubierta (FCC) es una variable importante relacionada con la precisión de la clasificación, ya que cuando los valores son bajos, la capa de sotobosque introduce ruido en las firmas espectrales del dosel. Por lo tanto, las parcelas de las principales especies comerciales de madera (*E. globulus*, *E. nitens*, *P. pinaster* y *P. radiata*) se clasificaron en tres clases de FCC: superior al 70%, entre 40 y 70%, y entre 10 y 40%, para tener en cuenta este efecto en los modelos.

Para la fotointerpretación de nuestras parcelas, utilizamos las capas identificadas en el proyecto Corine Land Cover (CLC) para la cobertura terrestre no forestal y el Mapa Forestal Nacional Español (MFE) para las clases de cobertura forestal. El IFN opera en un ciclo de diez años, excepto para las especies más productivas en el norte de España, donde este ciclo se reduce a cinco años. Se utilizaron los datos de la última actualización de este inventario correspondiente al año 2018 (IFN 4.5), para identificar parcelas que contenían las 4 especies productivas. Para el resto de especies forestales se utilizó el IFN 4 como las parcelas correspondientes a bosque caducifolio, bosque mixto y otras coníferas.

3.3.2. Plataforma Google Earth Engine

La plataforma Google Earth Engine (GEE) es una plataforma de análisis geoespacial se compone de (i) servidores de almacenamiento que contienen un amplio catálogo de imágenes de satélite y conjuntos de datos geoespaciales y (ii) servidores de computación que facilitan el análisis de grandes conjuntos de datos. Hay varias formas de interactuar con la plataforma, utilizando el Editor de Código o las APIs (JavaScript, Python o REST API). Se pueden consultar las guías para desarrolladores para obtener información más detallada sobre GEE.

El Editor de Código de Earth Engine, disponible en code.earthengine.google.com, es un IDE basado en la web, el lenguaje utilizado dentro de su ventana de código es JavaScript. El Editor de Código de GEE tiene una interfaz visual fácil de usar y es ampliamente utilizado en todo el mundo. Earth Engine está disponible de forma gratuita para uso académico y de investigación proporcionando 250 GB de almacenamiento en la nube para cargar productos locales. El potencial de esta plataforma se puede resumir en cuatro características: (i) disponibiliza una base

de datos amplia y constantemente actualizada, (ii) provee al usuario de una extensa colección de funciones del lado del servidor que reduce los requisitos de potencia de computación, (iii) permite a los usuarios realizar procesamiento utilizando scripts y (iv) admite la carga de datos.

Se puede procesar una gran cantidad de información con el apoyo de esta plataforma, especialmente sobre masas forestales. Se han realizado numerosos estudios relacionados con mapas de clasificación (por ejemplo, PHAN et al., 2020; XIE et al., 2021; KAPLAN, 2020; SHAFIZADEH-MOGHADAM et al., 2021), monitoreo forestal (por ejemplo, CHEN et al., 2021; WANG et al., 2022; BOGDANOC et al., 2018), incendios forestales (por ejemplo, LONG et al., 2019; COSTA-SAURA, 2022; ARRUDA et al., 2021; ROTETA et al., 2021), entre otros (por ejemplo, BROVELLI et al., 2020; DEL VALLE Y JIANG, 2022; SARZYNSKI et al., 2021). AMANI et al. (2020) ofrecen una revisión extensa y completa sobre GEE y todas sus aplicaciones.

En este estudio, utilizamos tanto el IDE web y las herramientas de la API de Python de GEE.

3.3.3. Procesamiento de imágenes de Sentinel-2

En este apartado, se aplicaron tres tipos de corrección a imágenes satelitales de teledetección, centrándose en corregir los efectos que tienen lugar una vez atravesada la atmosfera: (i) corrección atmosférica, (ii) corrección topográfica y (iii) corrección de la Función de Distribución de Reflectancia Bidireccional (BRDF).

3.3.3.1. Corrección atmosférica

La transmisión de radiación electromagnética a través de la atmósfera se ve obstaculizada por partículas atmosféricas que varían en el espacio y el tiempo. La corrección atmosférica busca tener en cuenta estas interacciones, incluyendo gases, vapor de agua y aerosoles, para obtener los valores de reflectancia en superficie (BoA) libres del efecto de las condiciones atmosféricas.

Existen dos tipos de corrección atmosférica (THORME et al., 1997; TOKOLA et al., 1999; TEILLET et al., 2001; VOGELMANN et al., 2001 and PAOLINI et al., 2006) : (i) corrección atmosférica relativa, que asume que la aportación de la atmosfera es aditiva, y (ii) corrección atmosférica absoluta, que utiliza condiciones atmosféricas y geometrías de iluminación y observación para calcular los factores de corrección de la imagen. Este segundo enfoque es el más utilizado pudiéndose encontrar diferentes métodos, como DOS (CHAVEZ, 1988), COST (CHAVEZ, 1996), FLAASH (MATTHEW, et al., 2000), 6S (VERMOTE et al., 1997), SIAC (YIN et al., 2022) and Sen2Cor (COAH, 2017).

En este estudio se compararon tres algoritmos de corrección atmosférica: (i) Sen2Cor, (ii) 6S y (iii) SIAC.

3.3.3.2. Correcciones topográficas

El uso de datos de teledetección pasiva en áreas montañosas se ve afectado por distorsiones radiométricas causadas por la topografía, lo que influye negativamente en los productos derivados (Sola, 2015). La reflectancia depende del ángulo cenital de iluminación y de observación, aquello que en terrenos planos no supone ningún problema, sí lo es en terrenos accidentados, debido a la variación de los ángulos y la sombra topográfica.

Los métodos de corrección topográfica se dividen en tres categorías: (i) razones de bandas, que no requieren un MDT (HOLBEN y JUSTICE, 1980); (ii) métodos empíricos o semi-empíricos; y (iii) métodos basados en la física. Se debe destacar que las razones de bandas han caído en desuso con la llegada de MDTs globales

como SRTM (RABUS et al., 2003) y GDEM (ASTER VALIDATION TEAM, 2009) ya que los otros métodos utilizan MDTs para modelar los efectos de iluminación considerando la inclinación y la orientación del terreno.

Varios estudios, como los de RIAÑO et al. (2003) y HANTSON y CHUVIECO (2011), concluyeron que la corrección C y el método empírico-estadístico ofrecieron los mejores resultados. Este estudio optó por el algoritmo SCS + C de SOENEN (2005) para corregir imágenes en terrenos forestales, ya que conserva las ventajas del método SCS, al mantener la naturaleza geotrópica del crecimiento de los árboles y ajustando la sobreestimación en áreas menos iluminadas (GU y GILLESPIE, 1998), y del C (TEILLET et al., 1982).

En este estudio, se aplicó la corrección topográfica cuando la pendiente del terreno fue superior al 5%. Para ello se utilizó el editor de código de GEE empleando las funciones escritas por Patrick Burns y Matt Macander (BELCORE et al., 2020).

3.3.3.3. Correcciones BRDF

La Función de Distribución de Reflectancia Bidireccional (BRDF) caracteriza las propiedades espectrales y direccionales de la reflectividad. Al variar la reflectividad según los ángulos de iluminación y observación, la percepción de un objeto se puede ver distorsionada.

La BRDF compara la radiancia de reflectancia en una dirección con la radiancia incidente en otra, influenciada por ángulos zenital y azimutal, así como por la longitud de onda, siendo las longitudes cortas más afectadas (SANDMEIER y ITTEN, 1999).

La BRDF se utiliza para corregir la variación de la reflectividad, pero su optimización requiere conocer la clase de cobertura, ya que las propiedades de reflectividad varían según la superficie. Existen tres tipos de modelos BRDF: (i) empíricos, (ii) semi-empíricos y (iii) físicos (WANNER y STRAHLER, 1995). Los modelos empíricos y semi-empíricos que utilizan pocos parámetros son conocidos como modelos paramétricos (LUCHT y ROUGEAN, 2000), desarrollados en los años 90 (ROUGEAN et al., 1992; LI y STRAHLER, 1992; WANNER y STRAHLER, 1995). Utilizamos el método propuesto por ROY et al. (2016) para normalizar los datos de reflectancia a reflectancia BRDF ajustada para nadir en Landsat, aplicando parámetros de ROY et al. (2017a y 2017b) para imágenes de Sentinel-2. Este método utiliza el modelo BRDF Ross-Thick / Li-Sparse-Reciprocal (ROY et al., 2016), se puede encontrar una descripción completa de este en STRAHLER et al. (1999) y sus derivaciones en WANNER y STRAHLER (1995). El núcleo volumétrico, conocido como núcleo Ross-Thick, asume una cobertura de hojas densas (ROUGEAN et al., 1992).

3.3.2. Procesamiento de datos de elevación digital

Para llevar a cabo las correcciones anteriores se requirió un Modelo Digital del Terreno (MDT) que coincidiera con la resolución espacial de las imágenes. A partir del MDT de 5 m por píxel desarrollado por el IGN, se *resampleo* a 5 m px-1, y se derivaron las capas de pendiente y orientación en la plataforma GEE, que son necesarias para la aplicación de las correcciones topográficas y de BRDF.

De un total de 2,991 parcelas, el 19.45% tenía una pendiente menor al 5%, el 31.06% tenía una pendiente entre el 5% y el 15%, y el 49.52% tenía una pendiente mayor al 15%. En cuanto a la orientación, el 14.88% de las parcelas fueron clasificadas como sombreadas, el 27.01% como soleadas y el 58.11% como otras.

3.3.3. Desarrollo y evaluación del modelo

Para el desarrollo de los diferentes modelos se generaron nueve conjuntos de datos diferentes según los formatos de procesamiento, algoritmos utilizados y resoluciones del MDT. Estos son:

- **1C:** Reflectancia superior a la atmósfera, disponible en GEE.
- **S2C_A:** Reflectancia en superficie corregida atmosféricamente con el algoritmo Sen2Cor.
- **Py6S_A:** Reflectancia en superficie corregida atmosféricamente con el algoritmo Py6S.
- **SIAC_A:** Reflectancia en superficie corregida atmosféricamente con el algoritmo SIAC.
- **S2C_AT90:** Reflectancia en superficie corregida atmosféricamente con el algoritmo Sen2Cor y la opción de corrección topográfica activa. Este es el producto típico de nivel 2A distribuido por la ESA y disponible en GEE.
- **Py6S_AT90:** Reflectancia en superficie corregida atmosféricamente con el algoritmo Py6S y corrección topográfica SCS + C usando un DEM de 90 m de resolución.
- **Py6S_AT30:** Reflectancia en superficie corregida atmosféricamente con el algoritmo Py6S y corrección topográfica SCS + C usando un MDT de 30 m de resolución.
- **Py6S_AT10:** Reflectancia en superficie corregida atmosféricamente con el algoritmo Py6S y corrección topográfica SCS + C usando un MDT de 10 m de resolución.
- **Py6S_AT10B:** Reflectancia en superficie corregida atmosféricamente con el algoritmo Py6S, corrección topográfica SCS + C y corrección BRDF usando un MDT de 10 m de resolución.

Se utilizó el algoritmo de Random Forest (RF) para la clasificación de coberturas. El estudio de los estadísticos de bondad del ajuste se realizó mediante una validación cruzada repetida de 10 carpetas y se calcularon estadísticas precisión general y Kappa para evaluar el rendimiento del modelo. El efecto de las diferentes correcciones en la precisión de clasificación de la cobertura terrestre se realizó mediante el análisis ANOVA para identificar las diferencias significativas.

4. Resultados

4.1. Selección del algoritmo de corrección atmosférica

Se compararon los valores del estadístico Kappa para predecir clases de uso del suelo en un conjunto de datos sin corrección topográfica (1C) y en conjuntos de datos tras aplicar tres algoritmos de corrección atmosférica diferentes (S2C_A, Py6S_A y SIAC_A). El algoritmo Sen2Cor demostró ser el mejor para las imágenes analizadas, sin embargo, dado que el algoritmo Sen2Cor aún no está disponible en GEE, se debe utilizar uno de los otros dos algoritmos. Dado que no hay una diferencia significativa en el rendimiento de estos algoritmos, se seleccionó Py6S por tres razones principales: (i) la base de la corrección atmosférica es la misma que la de SIAC, (ii) su aplicación requiere menos esfuerzo computacional que los otros dos algoritmos, y (iii) su implementación en GEE es más sencilla.

Tabla 2. Estadísticos de bondad del ajuste para los 3 algoritmos de corrección atmosférica y las imágenes 1C.

Estadístico	Base de datos analizada			
1C	S2C_A	Py6S_A	SIAC_A	
Kappa	0.8023 (0.0218)a,b	0.8076 (0.0219)a	0.7937 (0.0204)c	0.7949 (0.0219)b,c
Overall Accuracy	0.8399 (0.0176)a,b	0.8443 (0.0177)a	0.8331 (0.0165)c	0.8362 (0.0177)b,c

4.2. Selección del mejor MDT para la corrección topográfica

La ejecución del algoritmo seleccionado para la corrección topográfica, SCS + C (SOENEN et al., 2005) requiere un Modelo Digital del Terreno (MDT). El MDT más comúnmente utilizado es el Shuttle Radar Topographic Model (SRTM), con una resolución espacial de 90 m por píxel, similar al empleado en el procesamiento de imágenes de Sentinel-2 nivel 2A. Debido a la compleja orografía de la región de estudio, también utilizamos un MDT de 30 m por píxel y un MDT de 10 m por píxel derivado del proporcionado a 5 metros por píxel por el Centro Nacional de Información Geográfica de España (CNIG).

Como se esperaba, la precisión de la clasificación de cobertura mejoró significativamente con la corrección topográfica. Además, la mejora se potenció al aumentar la resolución del MDT, aunque los MDTs de 30 y 10 m por píxel no mostraron diferencias significativas en los resultados (Tabla 3). También observamos una reducción en la desviación estándar de la firma espectral, debido a la homogeneización de las diferentes firmas espectrales para las especies de interés.

La Tabla 3 muestra el aumento porcentual en la precisión de la clasificación de la clase forestal usando diferentes MDTs para las correcciones topográficas, en relación con los datos seleccionados solo para la corrección atmosférica (Py6S_A). La aplicación de correcciones topográficas a cuerpos de agua y áreas artificiales no tuvo influencia (o solo mínima) debido a la definición de estas superficies (con pendiente menor al 5% en la mayoría de los casos). En otras clases de uso del suelo, el grado de mejora depende de la banda espectral considerada. Por ejemplo, en áreas forestales, la reducción de la varianza en las bandas del red-edge (B5, B6 y B7) es más notable en todos los casos. La mayor mejora se observó en el bosque de coníferas en todas las bandas, mientras que la mejora fue menos pronunciada para el bosque de eucalipto. La mayor mejora correspondió a las bandas del borde rojo y del infrarrojo cercano para todos los tipos de bosque.

Tabla 3. Estadísticos de bondad del ajuste para los diferentes MDT probados en el estudio.

Estadístico	Base de datos analizada			
Py6S_A	Py6S_AT90	Py6S_AT30	Py6S_AT10	
Kappa	0.7937 (0.0204)a	0.8222 (0.0211)b	0.8280 (0.0218)bc	0.8343 (0.0188)c
Overall Accuracy	0.8331 (0.0165)a	0.8562 (0.0170)b	0.8608 (0.0176)bc	0.8659 (0.0152)c

4.3. Efecto de la corrección BRDF

Comparando el conjunto de datos Py6S_AT10 (con corrección atmosférica y topográfica) con el Py6S_AT10B (que incluye corrección BRDF), no se encontraron diferencias significativas. No obstante, se recomienda la inclusión de la corrección BRDF para análisis en series temporales, donde su importancia aumenta por factores fenológicos.

Tabla 4. Estadísticos de bondad del ajuste entre el uso o no de correcciones de BRDF.

Estadístico	Py6S_AT10	Py6S_AT10B
Kappa	0.8343 (0.0188)a	0.8381 (0.0211)a
Overall Accuracy	0.8659 (0.0152)a	0.8690 (0.0171)a

4.4. Comparación entre la solución propuesta y otros conjuntos de datos disponibles en GEE

Nuestra mejor solución, Py6S_AT10B, fue comparada con dos conjuntos de datos proporcionados por la ESA. Py6S_AT10B mostró valores significativamente superiores del estadístico Kappa en comparación con las otras opciones. El análisis de variaciones del rango intercuartílico (IQR) mostró que la firma espectral en el espectro visible para áreas de vegetación era menos consistente en comparación con las bandas del borde rojo y SWIR. Además, la precisión de la clasificación aumentó en áreas sombreadas y con pendientes pronunciadas.

Tabla 5. Porcentaje de variación en el IQR entre la solución propuesta y las imágenes Sentinel-2 nivel 2A disponibles en GEE.

Clase de cobertura	Bandas espectrales									
B2	B3	B4	B5	B6	B7	B8	B8A	B11	B12	
Áreas artificiales (98)	-12%	-16%	4%	-13%	1%	7%	11%	5%	-8%	-10%
Cultivos y pastos (824)	3%	2%	6%	2%	14%	12%	16%	15%	-5%	-2%
Bosque de frondosas (575)	-59%	-21%	-45%	20%	26%	14%	15%	11%	50%	42%
Bosque de eucalipto (283)	-115%	-49%	-8%	7%	13%	13%	11%	11%	13%	11%
Bosque de coníferas (371)	-22%	-3%	-13%	7%	6%	5%	-4%	-11%	12%	5%
Bosque mixto (179)	-136%	-47%	-32%	1%	1%	4%	5%	0%	-1%	10%
Matorrales (642)	-42%	8%	-7%	21%	14%	13%	11%	11%	12%	1%
Agua (19)	-17%	1%	23%	-22%	-39%	-56%	-55%	-64%	-19%	-4%

5. Discusión

5.1. Correcciones atmosféricas

Aunque la corrección atmosférica de las imágenes de Sentinel-2 parece estar plenamente justificada, su uso sigue siendo controvertido. Algunos autores, como SCHROEDER et al. (2006), advierten que este tipo de corrección puede introducir errores adicionales y recomiendan no corregir los datos a menos que sea estrictamente necesario. Sin embargo, otros, como YOUNG et al. (2017), destacan la importancia de la corrección, especialmente al desarrollar modelos empíricos que se aplicarán más allá de los datos de entrenamiento, como en este estudio. MAHINY y TURNER (2007) enfatizan que un modelo de corrección atmosférica preciso es esencial, ya que las discrepancias en los resultados pueden ser ecológicamente importantes. NAZEER et al. (2014) también subrayan la relevancia de la corrección cuando las pequeñas diferencias en la reflectancia superficial son significativas, como en transformaciones de ratio (NDVI) o estudios de fenología de cultivos, como mencionan SOLA et al. (2012). Aunque nuestros hallazgos no revelaron mejoras en el rendimiento del modelo tras la corrección atmosférica, coincidimos con quienes defienden su uso, considerando que los beneficios superan los inconvenientes, especialmente en estudios que utilizan imágenes satelitales para el análisis de series temporales.

La aplicación de correcciones atmosféricas en este estudio generó valores Kappa similares a los obtenidos por ALONSO et al. (2021) para clases de cobertura terrestre similares y en la misma área de estudio, logrando los mejores resultados con el algoritmo Sen2Cor. El test de comparación múltiple de Tukey mostró que el rendimiento de los algoritmos implementados en GEE (Py6S y SIAC) fue similar. Sin embargo, los algoritmos SIAC y Py6S presentaron mayores IQR y desviación estándar para las bandas visibles en comparación con Sen2Cor, lo que explica su menor precisión en las estadísticas de ajuste. Este comportamiento similar se debe al método de corrección utilizado, ya que SIAC usa el modelo 6S para corregir las



imágenes (YIN et al., 2022). MAHINY y TURNER (2007) detectaron un patrón anómalo en la banda azul de la firma espectral al aplicar el modelo 6S, como en nuestro estudio.

El uso de GEE permite aprovechar información atmosférica adicional proporcionada por diversas organizaciones. Con el algoritmo Py6S, utilizamos cuatro conjuntos de datos auxiliares disponibles en los repositorios de GEE. NAZEER et al. (2014) observaron que los diferentes modelos de aerosol incluidos en el 6S generan resultados variados, lo cual es relevante en nuestra región de estudio, que incluye zonas costeras e interiores con diferentes tipos de aerosoles. Los eventos climatológicos también alteran el contenido de aerosoles, especialmente en áreas industriales. La corrección atmosférica podría mejorarse al aplicar diferentes modelos de aerosol, aunque este aspecto no se abordó en nuestro estudio.

La selección del mejor modelo parece depender de las características del terreno, como lo demuestran LANTZANAKIS et al. (2016), quienes encontraron que los diferentes modelos de corrección atmosférica ofrecen resultados diversos según el tipo de cobertura terrestre. Comparar resultados de diferentes modelos con datos espectrales de campo es una de las mejores formas de evaluar la precisión de la corrección atmosférica, aunque actualmente no se dispone de una base de datos con tales datos. Estudios previos han concluido que el algoritmo 6S computa la reflectancia superficial con mayor precisión al discriminar clases de cobertura terrestre (LANTZANAKIS et al., 2016; NAZEER et al., 2014; KIM et al., 2022).

Considerando todo lo anterior y la ausencia de diferencias significativas en el rendimiento de SIAC y Py6S, elegimos el algoritmo Py6S por su facilidad de implementación en GEE y su capacidad para manejar imágenes de mayor tamaño sin limitaciones.

5.2. Correcciones topográficas y BRDF

La corrección topográfica se considera un paso crucial en el preprocesamiento de datos para aplicaciones como la clasificación de coberturas y el análisis de series temporales en regiones de topografía compleja (SOLA, 2015). Se ha sugerido que su impacto en la precisión de los resultados es mayor que el de la corrección atmosférica (VANONCKELEN et al., 2013). El algoritmo SCS + C, utilizado en este estudio, es ampliamente empleado en la clasificación de coberturas forestales y ha sido aplicado con diversas imágenes satelitales (MOREIRA y VALERIANO, 2014; HURNI et al., 2019; DONG et al., 2020; JIANG et al., 2022; MYASER, 2020). Este algoritmo es especialmente adecuado para áreas forestales, ya que conserva la naturaleza geotrópica del crecimiento de los árboles, aunque requiere copas ideales para funcionar correctamente (SOENEN et al., 2005).

La selección de un Modelo Digital de Elevación (MDT) con la resolución espacial adecuada es fundamental para la corrección topográfica. En este estudio, se utilizaron MDTs con resoluciones espaciales de 90, 30 y 10 m px-1, evaluamos los resultados de la corrección topográfica mediante la comparación de los valores de Kappa y la Precisión General, así como la reducción del Rango Intercuartílico (IQR) en las diferentes bandas de la firma espectral. Los resultados mostraron que Py6S_AT10 fue el mejor conjunto de datos, con mejoras estadísticamente significativas ($p \leq 0.05$). Este hallazgo coincide con otros estudios (GAO y ZHANG, 2009; ZHANG et al., 2014; MOREIRA y VALERIANO, 2014).

En cuanto a la corrección BRDF, que aborda el efecto de la reflectividad entre los



ángulos de observación e iluminación, no se observó una mejora estadísticamente significativa. Se ha sugerido que la corrección BRDF contribuye poco a mejorar la clasificación de la cobertura terrestre (ZHEN et al., 2023). Sin embargo, este aspecto será más relevante en series temporales que consideren aspectos fenológicos (VERGER et al., 2002 y 2004; GUAN et al., 2020), lo que se explorará en etapas futuras de la investigación.

Determinar el efecto máximo de la sombra topográfica requiere conocer la Función de Distribución de Reflectancia Bidireccional (BRDF) para cada tipo de bosque, lo que a su vez implica tener información sobre parámetros forestales como especies y edad del rodal (VINCINI et al., 2001). La dificultad de muestreo de la BRDF (NICODEMUS et al., 1977) afecta negativamente a la corrección, y se utilizan suposiciones simplificadas o correcciones empíricas. Algunos autores sugieren que la BRDF puede ser vista como una oportunidad en la teledetección, ya que la variación en el patrón de reflectancia entre diferentes clases de cobertura puede mejorar la precisión de los mapas de clasificación, como se propuso para las imágenes del satélite POLDER (COLSTOUN y WALTHALL, 2006).

5.3. Dataset propuesto, evaluación y comparación con datasets de GEE

El algoritmo Sen2Cor aún no está disponible en las funciones de GEE, lo que llevó a investigadores como NGUYEN (2020) y YIN et al. (2022) a utilizar otros algoritmos para aplicar correcciones en esta plataforma. Tras 2019, el desarrollo de algoritmos para corregir los efectos atmosféricos se redujo debido a la disponibilidad de imágenes del nivel 2A de Sentinel-2 (reflectancia superficial) proporcionadas por la Agencia Espacial Europea (ESA). Estas imágenes ya fueron preprocesadas con correcciones atmosféricas y topográficas, utilizando un MDT de 90 m px-1, aunque puede no ser suficientemente preciso en regiones de orografía compleja.

Muchos investigadores han utilizado diferentes niveles del algoritmo Sen2Cor en estudios variados (e.g., SCHUMACHER et al., 2019; WANG et al., 2020; GUERRA-HERNANDEZ et al., 2022). Dado que Sen2Cor es un algoritmo bien conocido para la corrección de datos de Sentinel-2, comparamos nuestra mejor solución, el algoritmo Py6S, con conjuntos de datos preprocesados por la ESA disponibles en GEE.

Al comparar el conjunto de datos corregido Py6S_AT10B con los disponibles en GEE, 1C y S2C_AT90, se observó que Py6S_AT10B presentó los mejores valores en términos de precisión y estadísticas Kappa. El análisis de la mejora en la precisión por clases de pendiente y aspecto mostró que todas las clases se beneficiaron con Py6S_AT10B en relación a S2C_AT90. En las tres clases de cobertura más relevantes (bosques de coníferas, eucaliptos y mixtos), se observó una mejora en la precisión, excepto en pendientes menores al 5% en los bosques de coníferas y mayores al 15% en los bosques mixtos. La mejora en pendientes menores al 5% se debió únicamente a las correcciones atmosféricas y BRDF, ya que la corrección topográfica solo se aplicó para pendientes mayores al 5%.

La comparación con la variación del IQR (Tabla 5) mostró que, para los bosques de coníferas, hubo un aumento en el IQR en las bandas NIR y visibles. Este efecto, menos eficiente en la corrección atmosférica de Py6S en comparación con Sen2Cor, parece ser la causa de la disminución de la precisión en coníferas en pendientes menores al 5%.

5.4. Limitaciones y desarrollos futuros

El análisis de los efectos de la corrección atmosférica, la contribución de la



resolución del MDT para mejorar la corrección topográfica y las correcciones BRDF ha proporcionado la información básica necesaria para elaborar un mapa de clasificación de la cobertura del suelo en el norte de España. No obstante, existen algunas limitaciones o debilidades debido a las imágenes disponibles o a la estructura o extensión de la propiedad forestal.

En relación con lo primero, la Agencia Espacial Europea (ESA) carece actualmente de funciones estandarizadas, más allá de Sen2Cor, incluidas en Google Earth Engine, para correcciones topográficas y BRDF, donde el uso de MDT de alta resolución es esencial para mejorar la precisión de la clasificación en terrenos complejos.

Respecto a lo segundo, el pequeño tamaño de muchas propiedades forestales en el norte de España representa un gran desafío en relación con la aplicación de las diferentes correcciones de imagen. Así, incluso en terrenos planos, en pequeñas propiedades con masas forestales de diferentes edades o estructuras, la sombra de los árboles vecinos afecta directamente a los valores capturados por el sensor en un píxel particular. Este efecto es más pronunciado en áreas montañosas, especialmente con especies de alta productividad y de rotación corta, como los eucaliptos, al estar estos sometidos a un intenso aprovechamiento. Por otro lado, la corta a mata rasa en los bosques de frondosas está prohibida por las administraciones forestales regionales, si se realiza algún tipo de aprovechamiento en estas masas no es “visible” desde el sensor, lo que representa otro desafío en la clasificación de la cobertura del suelo, ya que la firma espectral varía en función del porcentaje de cobertura del dosel.

En este estudio, aplicamos varias decisiones fijas respecto al tiempo de adquisición de imágenes y al algoritmo de aprendizaje automático a utilizar; sin embargo, no consideramos índices espectrales y/o variables auxiliares, el enfoque multisensor o algoritmos de segmentación. El siguiente paso en nuestra investigación será investigar el efecto de la fenología forestal en la mejora de la clasificación de la cobertura del suelo, considerando índices espectrales y variables auxiliares y evaluando el efecto de los algoritmos de segmentación para superar las distorsiones provocadas por el pequeño tamaño de las propiedades forestales. El paso final para producir el mejor mapa de clasificación de la cobertura del suelo para el área de estudio implicará probar diferentes algoritmos de aprendizaje automático y aprendizaje profundo.

6. Conclusiones

Este estudio destaca el potencial uso de bases de datos públicas, como el Inventario Forestal Nacional de España, imágenes satelitales gratuitas de la misión Copernicus Sentinel-2 y la plataforma GEE para desarrollar mapas de clasificación de la cobertura del suelo. La implementación del algoritmo Py6S para la corrección atmosférica representó el mejor compromiso entre el tiempo de ejecución y el tamaño de la imagen, en comparación con los algoritmos Sen2Cor y SIAC.

El uso de Py6S junto con el algoritmo SCS+C y un MDT de alta resolución (10 m px-1) para corregir el efecto topográfico proporcionó resultados más precisos que otros MDT de menor resolución (90 y 30 m px-1). Este hallazgo muestra la necesidad de que el tamaño de píxel de la imagen coincida con la resolución espacial del MDT, revelando que las imágenes de Sentinel-2 disponibles en el repositorio de GEE no son la mejor opción para desarrollar mapas de clasificación precisos en áreas con orografía compleja.



La corrección BRDF no mostró mejoras significativas en la precisión de la clasificación de la cobertura del suelo en las imágenes de Sentinel-2 con bajo ángulo de incidencia solar (imágenes adquiridas en verano). Sin embargo, se propone incluir esta corrección en el conjunto de datos para el próximo paso, que será el análisis de imágenes de series temporales, ya que se espera que tenga una mayor importancia a medida que aumenta el ángulo de incidencia solar.

Además, nuestro conjunto de datos propuesto mostró mejores estadísticas de ajuste que otros conjuntos de datos actualmente disponibles en la plataforma GEE. Por lo tanto, el marco estructurado desarrollado para la corrección de imágenes de Sentinel-2 proporciona una base sólida para analizar imágenes de series temporales. Sin embargo, se deben considerar mejoras adicionales, como la inclusión de índices espectrales y/o variables auxiliares, el uso de un enfoque multisensor y algoritmos de segmentación, así como la comparación de algoritmos de aprendizaje automático y/o profundo, para desarrollar un modelo operativo preciso de clasificación de la cobertura del suelo.

7. Agradecimientos

Esta investigación ha sido posible gracias al proyecto de investigación PID2020-112839RB-I00 financiado por la Agencia Estatal de Investigación (AEI) del Ministerio de Ciencia e Innovación (MCIN/AEI/10.13039/501100011033). Mientras realizaba el presente estudio, el primer autor disfrutó de un contrato Severo Ochoa del Gobierno del Principado de Asturias (código BP21-125).

8. Bibliografía

ALONSO, L., PICOS, J., y ARMESTO, J. (2021). Forest land cover mapping at a regional scale using multi-temporal sentinel-2 imagery and RF models. **Remote sensing**, 13(12), 2237. doi:10.3390/rs1312223

AMANI, M., GHORBANIAN, A., AHMADI, S. A., KAKOOEI, M., MOGHIMI, A., MIRMAZLOUMI, S. M., MOGHADDAM, S.H.A., MAHDAVI, S., GHAHREMANLOO, M., BRISCO, B. (2020). Google Earth Engine Cloud Computing Platform for Remote Sensing Big Data Applications: A Comprehensive Review. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, 1–1. doi:10.1109/jstars.2020.3021052

ARRUDA, V. L., PIONTEKOWSKI, V. J., ALENCAR, A., PEREIRA, R. S., Y MATRICARDI, E. A. (2021). An alternative approach for mapping burn scars using Landsat imagery, Google Earth Engine, and Deep Learning in the Brazilian Savanna. **Remote Sensing Applications: Society and Environment**, 22, 100472.

ASTER, G. (2009). Validation Team: METI/ERSDAC, NASA/LPDAAC, USGS/EROS, in cooperation with NGA and other collaborators, **ASTER GDEM Validation Summary Report**.

BALTHAZAR, V., VANACKER, V., Y LAMBIN, E. F. (2012). Evaluation and parameterization of ATCOR3 topographic correction method for forest cover mapping in mountain areas. **International Journal of Applied Earth Observation and Geoinformation**, 18, 436-450. doi:10.1016/j.jag.2012.03.010

BARALDI, A., GIRONDA, M., Y SIMONETTI, D. (2009). Operational two-stage stratified topographic correction of spaceborne multispectral imagery employing an automatic spectral-rule-based decision-tree preliminary classifier. **IEEE transactions on geoscience and remote sensing**, 48(1), 112-146.

BARRETT, F., MCROBERTS, R. E., TOMPPA, E., CIENCIALA, E., Y WASER, L. T. (2016).



A questionnaire-based review of the operational use of remotely sensed data by national forest inventories. **Remote Sensing of Environment**, 174, 279–289. doi:/10.1016/j.rse.2015.08.029

BARRIO-ANTA, M., CASTEDO-DORADO, F., CÁMARA-OBREGÓN, A., LÓPEZ-SÁNCHEZ, CARLOS A. (2021). Integrating species distribution models at forest planning level to develop indicators for fast-growing plantations. A case study of *Eucalyptus globulus* Labill. in Galicia (NW Spain). **Forest Ecology and Management**, 491, 2021. doi:10.1016/j.foreco.2021.119200.

BELCORE, E., PIRAS, M. Y WOZNIAC, E. (2020) 'Specific alpine environment land cover classification methodology: Google earth engine processing for sentinel-2 data', **International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences** - ISPRS Archives, 43(B3), pp. 663–670. doi: 10.5194/isprs-archives-XLIII-B3-2020-663-2020

BELCORE, E., PIRAS, M. Y WOZNIAC, E. (2020) Specific alpine environment land cover classification methodology: Google earth engine processing for sentinel-2 data, **International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences** - ISPRS Archives, 43(B3), pp. 663–670. doi: 10.5194/isprs-archives-XLIII-B3-2020-663-2020

BOGDANOV, A. P., KARPOV, A. A., DEMINA, N. A., Y ALESHKO, R. A. (2018). Improving forest monitoring by using cloud technologies as an element of sustainable forest management. **Sovremennye problemy distantsionnogo zondirovaniya Zemli iz kosmosa**, 15(1), 89-100.

BREIMAN, L. (2001). Random forests. **Machine learning**, 45, 5-32.

BROVELLI, M. A., SUN, Y., Y YORDANOV, V. (2020). Monitoring forest change in the amazon using multi-temporal remote sensing data and machine learning classification on Google Earth Engine. **ISPRS International Journal of Geo-Information**, 9(10), 580.

DE COLSTOUN, E. C. B., Y WALTHALL, C. L. (2006). Improving global scale land cover classifications with multi-directional POLDER data and a decision tree classifier. **Remote Sensing of Environment**, 100(4), 474-485.

CASTAÑO-SANTAMARÍA, J., LÓPEZ-SÁNCHEZ, C. A., OBESO, J. R., Y BARRIO-ANTA, M. (2023). Development of a site form equation for predicting and mapping site quality. A case study of unmanaged beech forests in the Cantabrian range (NW Spain). **Forest Ecology and Management**, 529, 120711.

CHAVEZ, J. 1988. An improved dark-object subtraction technique for atmospheric scattering correction of multispectral data. **Remote Sensing of Environment** 24:459-479

CHAVEZ, J.P.S. (1996) Image-Based Atmospheric Corrections—Revisited and Improved. **Photogrammetric Engineering and Remote Sensing**, 62, 1025-1036.

CHIRICI, G., GIANNETTI, F., MCROBERTS, R. E., TRAVAGLINI, D., PECCHI, M., MASELLI, F., CHIESI M. Y CORONA, P. (2020). Wall-to-wall spatial prediction of growing stock volume based on Italian National Forest Inventory plots and remotely sensed data. **International Journal of Applied Earth Observation and Geoinformation**, 84, 101959. doi:/10.1016/j.jag.2019.101959

CHEN, S., WOODCOCK, C. E., BULLOCK, E. L., ARÉVALO, P., TORCHINAVA, P., PENG, S., Y OLOFSSON, P. (2021). Monitoring temperate forest degradation on Google



Earth Engine using Landsat time series analysis. **Remote Sensing of Environment**, 265, 112648. doi:10.1016/j.rse.2021.112648

CHUVIECO, E. (1990). Fundamentos de teledetección espacial. Madrid. Ed. Rialp. 453 pp.

CNIG (2022) Spanish National Geographic Information Centre. ALS Data. Available online: <http://centrodedescargas.cnig.es/CentroDescargas/buscadorCatalogo.do?> (accessed on 22 March 2023).

COAH (2017). Copernicus Open Access Hub. Available online: <https://scihub.copernicus.eu/> (available from May 2017).

COSTA-SAURA, J. M., BACCIU, V., RIBOTTA, C., SPANO, D., MASSAIU, A., Y SIRCA, C. (2022). Predicting and mapping potential fire severity for risk analysis at regional level using google earth engine. **Remote Sensing**, 14(19), 4812.

COHEN, J. (1960). A coefficient of agreement for nominal scales. **Educational and psychological measurement**, 20(1), 37-46.

DEL VALLE, T. M., Y JIANG, P. (2022). Comparison of common classification strategies for large-scale vegetation mapping over the Google Earth Engine platform. **International Journal of Applied Earth Observation and Geoinformation**, 115, 103092.

DONG, T., LIU, J., QIAN, B., HE, L., LIU, J., WANG, R., ... Y SHANG, J. (2020). Estimating crop biomass using leaf area index derived from Landsat 8 and Sentinel-2 data. **ISPRS Journal of Photogrammetry and Remote Sensing**, 168, 236-250.

DOXANI, G., VERMOTE, E., ROGER, J. C., GASCON, F., ADRIAENSEN, S., FRANTZ, D., ... Y VANHELLEMONT, Q. (2018). Atmospheric correction inter-comparison exercise. **Remote Sensing**, 10(2), 352.

DRUSCH, M., DEL BELLO, U., CARLIER, S., COLIN, O., FERNANDEZ, V., GASCON, F., HOERSCH, B., ISOLA, C., LABERINTI, P., MARTIMORT, P., MEYGRET A., SPOTO, F., SY, O., MARCHESE, F., Y BARGELLINI, P. (2012). Sentinel-2: ESA's optical high-resolution mission for GMES operational services. **Remote sensing of Environment**, 120, 25-36.

FAN, Y., KOUKAL, T., Y WEISBERG, P. J. (2014). A sun-crown-sensor model and adapted C-correction logic for topographic correction of high resolution forest imagery. **ISPRS journal of photogrammetry and remote sensing**, 96, 94-105.

FASSNACHT, F. E., HARTIG, F., LATIFI, H., BERGER, C., HERNÁNDEZ, J., CORVALÁN, P., Y KOCH, B. (2014). Importance of sample size, data type and prediction method for remote sensing-based estimations of aboveground forest biomass. **Remote Sensing of Environment**, 154, 102-114.

FELICÍSIMO PÉREZ, A.M.; Fernández Cepedal, G. (1984): "Estimación de la radiación solar incidente en laderas con pendiente y orientación variables". **Studia Oecologica**, 3(1/2): 267-283.

FELICÍSIMO, A.M.; GARCÍA-MANTECA, P. (1990): "Corrección del efecto topográfico de las imágenes Landsat mediante el uso de un modelo digital de elevaciones". III **Reunión Científica del Grupo de Trabajo en Teledetección: 209-216. Asociación Española de Teledetección**. Madrid.

FELICÍSIMO, A.M.; GARCÍA-MANTECA, P.; MARQUÍNEZ, J. (1993): "Efectos de la corrección del efecto topográfico en las imágenes Landsat sobre la clasificación de



la vegetación y usos del suelo". **Teledetección y Medio Ambiente. IV Reunión Científica Asociación Española de Teledetección**: 251-256.

GAO, Y., Y ZHANG, W. (2009). LULC Classification and Topographic Correction of Landsat-7 ETM+ Imagery in the Yangjia River Watershed: the Influence of DEM Resolution. **Sensors**, 9(3), 1980–1995. doi:10.3390/s90301980

GAO, M. L., ZHAO, W. J., GONG, Z. N., GONG, H. L., CHEN, Z., Y TANG, X. M. (2014). Topographic correction of ZY-3 satellite images and its effects on estimation of shrub leaf biomass in mountainous areas. **Remote Sensing**, 6(4), 2745-2764.

GISLASON, P. O., BENEDIKTSSON, J. A., Y SVEINSSON, J. R. (2006). Random forests for land cover classification. **Pattern recognition letters**, 27(4), 294-300.

GOSLEE, S. C. (2012). Topographic corrections of satellite data for regional monitoring. **Photogrammetric Engineering Y Remote Sensing**, 78(9), 973-981.

GU, D., Y GILLESPIE, A. (1998). Topographic normalization of Landsat TM images of forest based on subpixel sun-canopy-sensor geometry. **Remote sensing of Environment**, 64(2), 166-175.

GUERRA-HERNÁNDEZ, J., NARINE, L. L., PASCUAL, A., GONZALEZ-FERREIRO, E., BOTEQUIM, B., MALAMBO, L., NEUENSCHWANDERF, A., POPESCU, S.C. Y GODINHO, S. (2022). Aboveground biomass mapping by integrating ICESat-2, SENTINEL-1, SENTINEL-2, ALOS2/PALSAR2, and topographic information in Mediterranean forests. **GIScience Y Remote Sensing**, 59(1), 1509-1533.

DING, M., GUAN, Q., LI, L., ZHANG, H., LIU, C., Y ZHANG, L. (2020). Phenology-based rice paddy mapping using multi-source satellite imagery and a fusion algorithm applied to the Poyang Lake plain, Southern China. **Remote Sensing**, 12(6), 1022.

HAN, S., ZHAO, Y., CHENG, J., ZHAO, F., YANG, H., FENG, H., ... Y YANG, G. (2022). Monitoring key wheat growth variables by integrating phenology and UAV multispectral imagery data into random forest model. **Remote Sensing**, 14(15), 3723.

HANTSON, S., Y CHUVIECO, E. (2011). Evaluation of different topographic correction methods for Landsat imagery. **International Journal of Applied Earth Observation and Geoinformation**, 13(5), 691-700.

HOLBEN, B. N., Y JUSTICE, C. O. (1980). The topographic effect on spectral response from nadir-pointing sensors. **Photogrammetric Engineering and Remote Sensing**, 46(9), 1191-1200.

HOSHIKAWA, K., Y UMEZAKI, M. (2014). Effects of terrain-induced shade removal using global DEM data sets on land cover classification. **International Journal of Remote Sensing**, 35(4), 1331–1355. doi:10.1080/01431161.2013.876122

HU, T., ZHANG, Y., SU, Y., ZHENG, Y., LIN, G., Y GUO, Q. (2020). Mapping the global mangrove forest aboveground biomass using multisource remote sensing data. **Remote sensing**, 12(10), 1690. doi: /10.3390/rs12101690

HURNI, K., VAN DEN HOEK, J., Y FOX, J. (2019). Assessing the spatial, spectral, and temporal consistency of topographically corrected Landsat time series composites across the mountainous forests of Nepal. **Remote sensing of environment**, 231, 111225.

IMMITZER, M., VUOLO, F., Y ATZBERGER, C. (2016). First experience with Sentinel-2 data for crop and tree species classifications in central Europe. **Remote sensing**, 8(3), 166.



JIANG, J., JOHANSEN, K., TU, Y. H., Y MCCABE, M. F. (2022). Multi-sensor and multi-platform consistency and interoperability between UAV, Planet CubeSat, Sentinel-2, and Landsat reflectance data. **GIScience and Remote Sensing**, 59(1), 936-958.

KAPLAN, G. (2020). Broad-leaved and coniferous forest classification in Google Earth Engine using Sentinel imagery. **Environmental Sciences Proceedings**, 3(1), 64.

KIM, S., Y LEE, Y. (2022). Atmospheric Correction of Sentinel-2 Images Using Enhanced AOD Information. **Korean Journal of Remote Sensing**, 38(1), 83-101. doi: /10.7780/KJRS.2022.38.1.7

LATIFI, H., NOTHDURFT, A., Y KOCH, B. (2010). Non-parametric prediction and mapping of standing timber volume and biomass in a temperate forest: application of multiple optical/LiDAR-derived predictors. **Forestry**, 83(4), 395-407.

LANDIS, J. R., Y KOCH, G. G. (1977). An application of hierarchical kappa-type statistics in the assessment of majority agreement among multiple observers. **Biometrics**, 363-374.

LANTZANAKIS, G., MITRAKA, Z., Y CHRYSOULAKIS, N. (2017). Comparison of physically and image based atmospheric correction methods for Sentinel-2 satellite imagery. **Perspectives on atmospheric sciences** (pp. 255-261). Springer International Publishing.

LI, X., Y STRAHLER, A. H. (1992). Geometric-optical bidirectional reflectance modeling of the discrete crown vegetation canopy: effect of crown shape and mutual shadowing. **IEEE Transactions on Geoscience and Remote Sensing**, 30(2), 276-292. doi:10.1109/36.134078

LÓPEZ-SÁNCHEZ, C. A., CASTEDO-DORADO, F., CÁMARA-OBREGÓN, A., Y BARRIO-ANTA, M. (2021). Distribution of Eucalyptus globulus Labill. in northern Spain: Contemporary cover, suitable habitat and potential expansion under climate change. **Forest Ecology and Management**, 481, 118723. doi: /10.1016/j.foreco.2020.118723

LONG, T., ZHANG, Z., HE, G., JIAO, W., TANG, C., WU, B., ... YIN, R. (2019). 30 m Resolution Global Annual Burned Area Mapping Based on Landsat Images and Google Earth Engine. **Remote Sensing**, 11(5), 489. doi:10.3390/rs11050489

LUCHT, W., Y ROUJEAN, J. -L. (2000). Considerations in the parametric modeling of BRDF and albedo from multiangular satellite sensor observations. **Remote Sensing Reviews**, 18(2-4), 343-379. doi:10.1080/02757250009532395

LUCHT, W. (1998). Expected retrieval accuracies of bidirectional reflectance and albedo from EOS-MODIS and MISR angular sampling. **Journal of Geophysical Research: Atmospheres**, 103(D8), 8763-8778. doi:10.1029/98jd00089

MAHINY, A. S., Y TURNER, B. J. (2007). A comparison of four common atmospheric correction methods. **Photogrammetric Engineering and Remote Sensing**, 73(4), 361-368.

MATTHEW, M. W., ADLER-GOLDEN, S. M., BERK, A., RICHTSMEIER, S. C., LEVINE, R. Y., BERNSTEIN, L. S., MILLER, D. P. (2000). Status of atmospheric correction using a MODTRAN4-based algorithm. **Algorithms for Multispectral, Hyperspectral, and Ultraspectral Imagery VI**. doi:10.1117/12.410341

MAPAMA. Spanish National Fourth Inventory Updating. Ministerio de Agricultura,



Pesca y Alimentación. Gobierno de España. 2019. Available online: https://www.miteco.gob.es/es/biodiversidad/estadisticas/forestal_anuarios_todos.html/ (accessed on 21 December 2023)

MAPAMA. Anuario de Estadística. Avance 2018. Ministerio de Agricultura. Pesca y Alimentación. Madrid. 2019. Available online: <https://www.mapa.gob.es/estadistica/pags/anuario/2018/anuario/AE18.pdf> (accessed on 21 December 2023).

MURPHY, S. (2020) Atmospheric correction of Sentinel 2 imagery in Google Earth Engine using Py6S. Available online: https://github.com/samsammurphy/gee-atmcorr-S2/blob/master/jupyter_notebooks/sentinel2_atmospheric_correction.ipynb.

MYASER, JWAN (2020) Improvement of land cover mapping using Sentinel 2 and Landsat 8 imageries via non-parametric classification. **Doctoral thesis**, Universiti Putra Malaysia.

MOREIRA, E. P., Y VALERIANO, M. M. (2014). Application and evaluation of topographic correction methods to improve land cover mapping using object-based classification. **International Journal of Applied Earth Observation and Geoinformation**, 32, 208-217.

MURPHY, S. (2020). Atmospheric correction of Sentinel 2 imagery in Google Earth Engine using Py6S. Available online: (https://github.com/samsammurphy/gee-atmcorr-S2/blob/master/jupyter_notebooks/sentinel2_atmospheric_correction.ipynb)

NAZEER, M., NICHOL, J. E., Y YUNG, Y. K. (2014). Evaluation of atmospheric correction models and Landsat surface reflectance product in an urban coastal environment. **International journal of remote sensing**, 35(16), 6271-6291.

NGUYEN, L. B. (2020). Land cover change detection in northwestern Vietnam using Landsat images and Google Earth Engine. **Journal of Water and Land development**.

NICODEMUS, F. E., RICHMOND, J. C., HSIA, J. J., GINSBERG, I. W., Y LIMPERIS, T. (1977). Geometrical considerations and nomenclature for reflectance. **NBS Monograph**, 160.

NOVO-FERNÁNDEZ, A.; LÓPEZ-SÁNCHEZ, C.A.; CÁMARA-OBREGÓN, A.; BARRIO-ANTA, M.; TEIJIDO-MURIAS, I. (2024). Estimating Forest Variables for Major Commercial Timber Plantations in Northern Spain Using Sentinel-2 and Ancillary Data. **Forests**, 15, 99.

NOVO-FERNÁNDEZ, A., BARRIO-ANTA, M., RECONDO, C., CÁMARA-OBREGÓN, A., Y LÓPEZ-SÁNCHEZ, C. A. (2019). Integration of national forest inventory and nationwide airborne laser scanning data to improve forest yield predictions in north-western Spain. **Remote Sensing**, 11(14), 1693.

MUELLER-WILM. U. S2 MPC: Sen2Cor Configuration and User Manual. Ref. S2-PDGS-MPC-L2A-SUM-V2.8. 2019. Available online: <http://step.esa.int/thirdparties/sen2cor/2.8.0/docs/S2-PDGS-MPC-L2A-SRN-V2.8.pdf> (accessed on 16 December 2019).

PAOLINI, L., GRINGS, F., SOBRINO, J. A., JIMÉNEZ MUÑOZ, J. C., Y KARSZENBAUM, H. (2006). Radiometric correction effects in Landsat multi-date/multi-sensor change detection studies. **International Journal of Remote Sensing**, 27(4), 685-704.



PENNER, M., PITT, D. G., Y WOODS, M. E. (2013). Parametric vs. nonparametric LiDAR models for operational forest inventory in boreal Ontario. **Canadian Journal of Remote Sensing**, 39(5), 426-443.

PHAN, T. N., KUCH, V., Y LEHNERT, L. W. (2020). Land Cover Classification using Google Earth Engine and Random Forest Classifier—The Role of Image Composition. **Remote Sensing**, 12(15), 2411. doi:10.3390/rs12152411

RABUS, B., EINEDER, M., ROTH, A., Y BAMLER, R. (2003). The shuttle radar topography mission—a new class of digital elevation models acquired by spaceborne radar. **ISPRS journal of photogrammetry and remote sensing**, 57(4), 241-262.

RIAÑO, D., CHUVIECO, E., SALAS, J., Y AGUADO, I. (2003). Assessment of different topographic corrections in Landsat-TM data for mapping vegetation types (2003). **IEEE Transactions on geoscience and remote sensing**, 41(5), 1056-1061.

ROUPIOZ, L., NERRY, F., JIA, L., Y MENENTI, M. (2014). Improved surface reflectance from remote sensing data with sub-pixel topographic information. **Remote Sensing**, 6(11), 10356-10374. doi:10.3390/rs61110356

ROSS, J. K., Y MARSHAK, A. L. (1988). Calculation of canopy bidirectional reflectance using the Monte Carlo method. **Remote Sensing of Environment**, 24(2), 213-225.

ROTETA, E., BASTARRIKA, A., IBISATE, A., Y CHUVIECO, E. (2021). A preliminary global automatic burned-area algorithm at medium resolution in Google Earth Engine. **Remote Sensing**, 13(21), 4298.

ROUJEAN, J.-L., LEROY, M., Y DESCHAMPS, P.-Y. (1992). A bidirectional reflectance model of the Earth's surface for the correction of remote sensing data. **Journal of Geophysical Research**, 97(D18), 20455. doi:10.1029/92jd01411

ROY, D. P., ZHANG, H. K., JU, J., GOMEZ-DANS, J. L., LEWIS, P. E., SCHAAF, C. B., ... KOVALSKYY, V. (2016). A general method to normalize Landsat reflectance data to nadir BRDF adjusted reflectance. **Remote Sensing of Environment**, 176, 255-271. doi:10.1016/j.rse.2016.01.023

ROY, D. P., LI, J., ZHANG, H. K., YAN, L., HUANG, H., Y LI, Z. (2017a). Examination of Sentinel-2A multi-spectral instrument (MSI) reflectance anisotropy and the suitability of a general method to normalize MSI reflectance to nadir BRDF adjusted reflectance. **Remote Sensing of Environment**, 199, 25-38. doi:10.1016/j.rse.2017.06.019

ROY, D.P.; LI, Z.; ZHANG, H.K. (2017b) Adjustment of Sentinel-2 Multi-Spectral Instrument (MSI) Red-Edge Band Reflectance to Nadir BRDF Adjusted Reflectance (NBAR) and Quantification of Red-Edge Band BRDF Effects. **Remote Sens.** 9, 1325. <https://doi.org/10.3390/rs9121325>

SANDMEIER, S., Y ITTEN, K. I. (1997). A physically-based model to correct atmospheric and illumination effects in optical satellite data of rugged terrain. **IEEE Transactions on Geoscience and Remote Sensing**, 35(3), 708-717. doi:10.1109/36.581991

SARZYNSKI, T., REGE, A., WARNEKAR, S. B., WU, S., Y LEE, J. S. H. (2021). Google Earth Engine, an innovative technology for forest conservation. **Innovative forestry for a sustainable future**, 35.

SHAFIZADEH-MOGHADAM, H., KHAZAEI, M., ALAVIPANAH, S. K., Y WENG, Q.



(2021). Google Earth Engine for large-scale land use and land cover mapping: An object-based classification approach using spectral, textural and topographical factors. **GIScience Y Remote Sensing**, 58(6), 914-928.

SCHUMACHER, J.; RATTAY, M.; KIRCHHÖFER, M.; ADLER, P.; KÄNDLER, G. (2019) Combination of Multi-Temporal Sentinel 2 Images and Aerial Image Based Canopy Height Models for Timber Volume Modelling. **Forests**, 10, 746. <https://doi.org/10.3390/f10090746>

SMITH, J. A., LIN, T. L., Y RANSON, K. J. (1980). The Lambertian assumption and Landsat data. **Photogrammetric Engineering and Remote Sensing**, 46(9), 1183-1189.

SOENEN, S.A., PEDDLE, D.R., Y COBURN, C.A. (2005). SCS+C: A modified sun-canopy-sensor topographic correction in forested terrain. **IEEE Transactions on Geoscience and Remote Sensing**, 43, 2148-2159.

SOLA, I. (2015). Evaluation of topographic correction algorithms on satellite images. **Doctoral Thesis, Public University of Navarre**, 182 pp.

SOLA, I., GONZÁLEZ-AUDÍCANA, M., Y ÁLVAREZ-MOZOS, J. (2015). Validation of a simplified model to generate multispectral synthetic images. **Remote Sensing**, 7(3), 2942-2951

SOLA, I., GONZÁLEZ-AUDÍCANA, M., Y ÁLVAREZ-MOZOS, J. (2016). Multi-criteria evaluation of topographic correction methods. **Remote Sensing of Environment**, 184, 247-262. doi:10.1016/j.rse.2016.07.002

SCHROEDER, T., BEHNERT, I., SCHAALE, M., FISCHER, J., Y DOERFFER, R. (2007). Atmospheric correction algorithm for MERIS above case-2 waters. **International Journal of Remote Sensing**, 28(7), 1469-1486.

TANG, D., QIN, B., FENG, X., Y LIU, T. (2015). Effective LSTMs for target-dependent sentiment classification. arXiv preprint arXiv:1512.01100.

TEILLET, P. M., BARKER, J. L., MARKHAM, B. L., IRISH, R. R., FEDOSEJEVS, G., Y STOREY, J. C. (2001). Radiometric cross-calibration of the Landsat-7 ETM+ and Landsat-5 TM sensors based on tandem data sets. **Remote sensing of Environment**, 78(1-2), 39-54. doi: /10.1016/S0034-4257(01)00248-6

TEILLET, P. M., GUINDON, B., Y GOODENOUGH, D. G. (1982). On the slope-aspect correction of multispectral scanner data. **Canadian Journal of Remote Sensing**, 8(2), 84-106

THORNE, K., MARKHARN, B., BARKER, P. S., Y BIGGAR, S. J. P. E. (1997). Radiometric calibration of Landsat. **Photogrammetric Engineering and Remote Sensing**, 63(7), 853-858

TOKOLA, T., LÖFMAN, S., Y ERKKILÄ, A. (1999). Relative calibration of multitemporal Landsat data for forest cover change detection. **Remote sensing of environment**, 68(1), 1-11. doi: /10.1016/S0034-4257(98)00096-0

VANONCKELEN, S., LHERMITTE, S., Y VAN ROMPAEY, A. (2013). The effect of atmospheric and topographic correction methods on land cover classification accuracy. **International Journal of Applied Earth Observation and Geoinformation**, 24, 9-21. doi:/ 10.1016/j.jag.2013.02.003

VANONCKELEN, S., LHERMITTE, S., BALTHAZAR, V., Y VAN ROMPAEY, A. (2014). Performance of atmospheric and topographic correction methods on Landsat imagery in mountain areas. **International Journal of Remote Sensing**, 35(13),



4952-4972. doi: /10.1080/01431161.2014.933280

VAN ROSSUM, G., Y Drake, F. L. (2009). Python.

VERMOTE, E. F., TANRÉ, D., DEUZE, J. L., HERMAN, M., Y MORCETTE, J. J. (1997). Second simulation of the satellite signal in the solar spectrum, 6S: An overview. **IEEE transactions on geoscience and remote sensing**, 35(3), 675-686. doi: 10.1109/36.581987

VERAVERBEKE, S., VERSTRAETEN, W. W., LHERMITTE, S., Y GOOSSENS, R. (2010). Illumination effects on the differenced Normalized Burn Ratio's optimality for assessing fire severity. **International Journal of Applied Earth Observation and Geoinformation**, 12(1), 60-70. doi: 10.1016/j.jag.2009.10.004

VERGER, A., GILABERT, M.A., CAMACHO-DE COCA, F. AND MELIÁ, J. (2002). Influencia del ángulo cenital de iluminación en los índices de vegetación. **Revista de Teledetección**. 18:75-89

VERGER, A., CAMACHO-DE COCA, F. AND MELIÁ, J. (2004). Influencia de la geometría de adquisición en el NDVI. **Revista de Teledetección**. 21:95-99.

VERGER, A., CAMACHO-DE COCA, F. AND MELIÁ, F. (2005) Revisión de los modelos paramétricos de BRDF **Revista de Teledetección**, 2005, vol. 23, p. 65-80.

VINCINI, M., REEDER, D., Y FRAZZI, E. (2011). Influences of topography on TM data and vegetation indices of deciduous forests. (url: <http://srtm.det.unifi.it/Atticonvegno/doc/RP16.pdf>)

VOGELMANN, J. E., HOWARD, S. M., YANG, L., LARSON, C. R., WYLIE, B. K., Y VAN DRIEL, N. (2001). Completion of the 1990s National Land Cover Data Set for the conterminous United States from Landsat Thematic Mapper data and ancillary data sources. **Photogrammetric Engineering and Remote Sensing**, 67(6).

WANG, Z., LIU, K., CAO, J., PENG, L., Y WEN, X. (2022). Annual change analysis of mangrove forests in China during 1986-2021 based on Google Earth engine. **Forests**, 13(9), 1489.

WANG, D., WAN, B., LIU, J., SU, Y., GUO, Q., QIU, P., Y WU, X. (2020). Estimating aboveground biomass of the mangrove forests on northeast Hainan Island in China using an upscaling method from field plots, UAV-LiDAR data and Sentinel-2 imagery. **International Journal of Applied Earth Observation and Geoinformation**, 85, 101986. doi:10.1016/j.jag.2019.101986

WANNER, W., LI, X., Y STRAHLER, A. H. (1995). On the derivation of kernels for kernel-driven models of bidirectional reflectance. **Journal of Geophysical Research: Atmospheres**, 100(D10), 21077-21089.

WILSON, R. T. (2013). Py6S: A Python interface to the 6S radiative transfer model. **Computers and Geosciences**, 51, 166-171.

WULDER, M. A., COOPS, N. C., ROY, D. P., WHITE, J. C., Y HERMOSILLA, T. (2018). Land cover 2.0. **International Journal of Remote Sensing**, 39(12), 4254-4284. doi: /10.1080/01431161.2018.1452075

XIE, B., CAO, C., XU, M., DUERLER, R. S., YANG, X., BASHIR, B., ... Y WANG, K. (2021). Analysis of regional distribution of tree species using multi-seasonal sentinel-1Y2 imagery within google earth engine. **Forests**, 12(5), 565.

YANG SHAO, LI, G. L., GUENTHER, E., Y CAMPBELL, J. B. (2015). Evaluation of Topographic Correction on Subpixel Impervious Cover Mapping With CBERS-2B



Data. **IEEE Geoscience and Remote Sensing Letters**, 12(8), 1675–1679. doi:10.1109/lgrs.2015.2419135

YIN, F., LEWIS, P. E., Y GÓMEZ-DANS, J. L. (2022). Bayesian atmospheric correction over land: Sentinel-2/MSI and Landsat 8/OLI. **Geoscientific Model Development**, 15(21), 7933-7976. doi: /10.5194/gmd-15-7933-2022, 2022.

YOUNG, N. E., ANDERSON, R. S., CHIGNELL, S. M., VORSTER, A. G., LAWRENCE, R., Y EVANGELISTA, P. H. (2017). A survival guide to Landsat preprocessing. **Ecology**, 98(4), 920-932.

ZHANG, Y., YAN, G., Y BAI, Y. (2014). Sensitivity of topographic correction to the DEM spatial scale. **IEEE Geoscience and remote sensing letters**, 12(1), 53-57.

ZHEN, Z.; CHEN, S.; YIN, T.; GASTELLU-ETCHEGORRY, J.-P. (2023) Improving Crop Mapping by Using Bidirectional Reflectance Distribution Function (BRDF) Signatures with Google Earth Engine. **Remote Sens.**, 15, 2761. <https://doi.org/10.3390/rs15112761>