

CONAMA 2024

CONGRESO NACIONAL DEL MEDIO AMBIENTE

Impacto de Infraestructuras Viarias en Ecosistemas Forestales: Evaluación Autovía Ourense-Celanova



CONAMA 2024

IMPACTO DE INFRAESTRUCTURAS VIARIAS EN ECOSISTEMAS FORESTALES: EVALUACIÓN AUTOVÍA OURENSE-CELANOVA

Autor Principal: Gabriel Eduardo Suárez-Fernández (CINTECX, Universidade de Vigo, Grupo de Investigación en Geo-tecnologías Aplicadas, Campus Universitario de Vigo, As Lagoas, Marcosende, 36310 Vigo, España)

Otros autores: Joaquín Martínez-Sánchez (CINTECX, Universidade de Vigo, Grupo de Investigación en Geo-tecnologías Aplicadas, Campus Universitario de Vigo, As Lagoas, Marcosende, 36310 Vigo, España); Pedro Arias (CINTECX, Universidade de Vigo, Grupo de Investigación en Geo-tecnologías Aplicadas, Campus Universitario de Vigo, As Lagoas, Marcosende, 36310 Vigo, España).

ÍNDICE

Título

Resumen

Palabras Clave

1. Introducción
2. Área de Estudio y Materiales
3. Metodología
4. Resultados
5. Discusión y Conclusión

Agradecimientos

Bibliografía

IMPACTO DE INFRAESTRUCTURAS VIARIAS EN ECOSISTEMAS FORESTALES: EVALUACIÓN AUTOVÍA OURENSE-CELANOVA

RESUMEN

Las áreas forestales son fundamentales para la biodiversidad, economía y el bienestar social. Sin embargo, la construcción de infraestructuras viales, aunque cruciales también para el crecimiento económico y la sostenibilidad, puede tener efectos adversos en los ecosistemas circundantes, generando efectos como la fragmentación del hábitat y la alteración de la composición de las masas forestales. Como resultado, en este estudio se analiza el impacto de la Autovía Ourense-Celanova (AG-31) en la superficie forestal circundante, utilizando ortofotos y técnicas de Aprendizaje Automático para cartografiar y calcular la espesura forestal antes y después de la construcción de la vía en 2013. A través de modelos de clasificación "Random Forest", se logró una precisión superior al 85%, y se demostró que, en una franja de 100 metros alrededor del dominio público de la autovía, las diferencias en la superficie forestal eran estadísticamente significativas, evidenciando una disminución en los años posteriores a la construcción. Además, un modelo de regresión logística, que consideró el tiempo transcurrido desde la construcción y la distancia a la infraestructura, alcanzó una precisión del 52%. Los hallazgos subrayan el impacto de la construcción de infraestructuras viales en la superficie forestal de la región de Ourense, destacando la idoneidad de combinar teledetección y análisis estadístico para realizar evaluaciones más detalladas de las interacciones entre infraestructuras y ecosistemas forestales, sus cambios y sus diversos impactos.

PALABRAS CLAVE

Autovía, Espesura, Aprendizaje Automático, Random Forest, Masas Forestales

1. INTRODUCCIÓN

Las áreas forestales desempeñan un papel fundamental en los ecosistemas, la biodiversidad y la sociedad. No sólo ayudan a mantener y preservar los recursos naturales, sino que también proporcionan materiales esenciales como alimentos, madera y energía, además de ofrecer servicios culturales (Ali, 2023; Siry et al., 2005). Por su parte, la infraestructura vial es esencial para el transporte y el crecimiento económico, siendo un elemento clave para lograr los Objetivos de Desarrollo Sostenible (ODS) de la Agenda 2030 (United Nations, 2015). Sin embargo, aunque estas infraestructuras son fundamentales para la sostenibilidad, también plantean importantes desafíos ambientales que deben gestionarse cuidadosamente.

A pesar de los múltiples beneficios que las infraestructuras viales aportan a la economía (Ng et al., 2017), su impacto en los ecosistemas circundantes puede ser negativo, afectando a la fauna, el suelo y la dispersión de semillas (Mahon et al., 2019; Uliasz-Misiak et al., 2022). Por un lado, las vías rodadas facilitan la propagación de especies invasoras y alteran las condiciones abióticas del entorno, impactando la estructura y composición de los bosques cercanos (Coffin, 2007; Lemke et al., 2019). Por otro lado, estas infraestructuras propician la fragmentación del hábitat, lo que puede resultar en una mayor pérdida de biodiversidad y aislamiento, especialmente en áreas forestales cercanas a los bordes (Wekesa et al., 2019).

El efecto de borde, producido por infraestructuras lineales como carreteras, tiene varios efectos adversos sobre las áreas forestales (Nguyen et al., 2023). Este fenómeno aumenta la vulnerabilidad de los ecosistemas y disminuye su resiliencia frente a perturbaciones externas (Campbell et al., 2018; Davidson et al., 2021). Sin embargo, el efecto de borde es un proceso complejo que depende de factores bióticos y abióticos específicos de cada región (Ibáñez et al., 2014). Las alteraciones en las condiciones abióticas, como la radiación solar, la humedad del suelo y la temperatura, pueden modificar la dinámica sucesional y la composición de las especies forestales (Brando et al., 2019). Por su parte, los aumentos en la luz podrían incrementar el crecimiento de árboles o arbustos en las zonas afectadas, promoviendo mayor productividad o diversidad estructural (Dormann et al., 2020).

Los impactos de las infraestructuras dependen de múltiples factores: tanto de la infraestructura en sí (años desde su construcción, tipo de materiales, orientación) como de las características del ecosistema afectado (distancia a la infraestructura, orientación geográfica, tipo de bosque, y región climática) (Braham et al., 2023; Vepakomma et al., 2018; Zhou et al., 2020). Por ello, es esencial estudiar las interacciones entre infraestructura vial y áreas forestales de manera contextualizada, especialmente en regiones de alta productividad forestal, como el norte de España.

La dinámica de la vegetación alrededor de infraestructuras lineales sigue siendo un área que requiere mayor investigación. Esto es particularmente relevante en la Región Biogeográfica Atlántica, donde prácticamente no existen estudios que analicen las sinergias y antagonismos en la interfaz entre infraestructuras viales y áreas forestales. Definir y modelar estas interacciones puede proporcionar una visión más completa sobre cómo gestionar el impacto de las infraestructuras y preservar los ecosistemas circundantes.

Hasta ahora, las mediciones in situ han sido la herramienta principal para analizar los efectos de borde en la vegetación, utilizando transectos y parcelas de muestreo para capturar cambios en

la estructura del bosque (Delgado et al., 2007; Silva da Costa et al., 2020). No obstante, estos procedimientos son costosos en tiempo y recursos, lo que limita la capacidad para recopilar datos en grandes áreas. Además, las mediciones in situ están restringidas a puntos discretos, lo que dificulta capturar la variabilidad a lo largo de grandes distancias (Liang et al., 2016).

Para superar estas limitaciones, las tecnologías de teledetección se han convertido en una herramienta indispensable para medir las características de la vegetación a múltiples escalas y en diferentes intervalos de tiempo (Zeng et al., 2022). Soluciones tecnológicas como imágenes satelitales de alta resolución u ortofotografía aérea permiten analizar los cambios en la estructura y composición del bosque en grandes áreas y durante largos periodos temporales (Bright et al., 2019; Melchiorre & Boschetti, 2018; Yang et al., 2022). Estas tecnologías ofrecen una visión detallada de la evolución de los impactos ambientales a lo largo del tiempo y proporcionan datos continuos que son difíciles de obtener mediante métodos tradicionales (Chinembiri et al., 2023). Por lo tanto, las tecnologías de teledetección permiten extraer información ecológicamente relevante sobre las características de la vegetación circundante a las carreteras, proporcionando una visión detallada de la evolución a los impactos de la estructura y composición forestal a lo largo del tiempo.

Considerando este contexto, se propone un enfoque integral para evaluar cómo la construcción de infraestructuras viales en regiones forestales afecta la superficie forestal y el estado vegetativo de dichas masas forestales. En particular, el objetivo de este estudio es analizar estadísticamente las diferencias en la superficie forestal de las zonas adyacentes previo y posterior a la construcción de la Autovía Ourense-Celanova (AG-31), ubicada al noroeste de la península ibérica, en la provincia de Ourense, cuya inauguración fue en 2013. Para ello, se hará uso de tecnologías de teledetección y técnicas de Aprendizaje Automático.

2. ÁREA DE ESTUDIO Y MATERIALES

El área de estudio se localiza al noroeste de la Península Ibérica, específicamente en la provincia de Ourense, ubicada en la Comunidad Autónoma de Galicia. El tramo seleccionado para este estudio se sitúa entre el PK 1+500 y el final de la autovía Ourense-Celanova (AG-31) en su conexión con la carretera nacional OU-540 (Figura 1). Esta autovía fue inaugurada en el año 2013 como una de las principales vías de comunicación del interior de Galicia, proporcionando un acceso rápido a las ciudades del norte de Portugal. Además, es importante destacar que la autovía se desarrolló como un proyecto de colaboración público-privada entre la Xunta de Galicia y las empresas constructoras Copasa SA y Extraco SA.




Figura 1. Zona de Estudio (EPSG:25829 – ETRS89 Huso 29)

En cuanto a los materiales y herramientas utilizadas, se emplea RStudio 2022.12.0 con la versión 4.1.3 de R para el análisis estadístico y procesamiento de datos, mientras que QGIS 3.19.9 se utiliza para la visualización y generación de capas geoespaciales, como puntos aleatorios y cuadrículas, lo que facilita la integración de datos geográficos. Por otro lado, se utilizan las ortofotos del Plan Nacional de Ortofotografía Aérea (PNOA) (Gobierno de España: Ministerio de Transportes, 2020) correspondientes a los años previos y posteriores a la construcción de la vía. Las imágenes analizadas corresponden a los años 2003, 2007, 2009, 2014, 2017 y 2020. Las ortofotos del año 2011 se descartan debido a que la autovía estaba en construcción. Además, a través de Google Earth Engine (Gorelick et al., 2017), se obtuvieron los valores medios para cada píxel de las imágenes satelitales del programa Landsat correspondientes a las fechas desde el 01 de junio hasta el 30 de septiembre de cada uno de los años mencionados.

3. METODOLOGÍA

El planteamiento general desarrollado se representa en la Figura 2 y abarca tres etapas principales: En la fase inicial, se adquieren, reescalan y procesan tanto las ortofotos como las imágenes de satélite del programa Landsat. En la segunda fase, se entrenan y evalúan los modelos basados en técnicas de Aprendizaje Automático, más específicamente en Análisis de Componentes Principales y modelos “Random Forest”. Por último, se procede al análisis estadístico de las diferencias en la superficie forestal de las zonas adyacentes previo y posterior a la construcción de la Autovía.

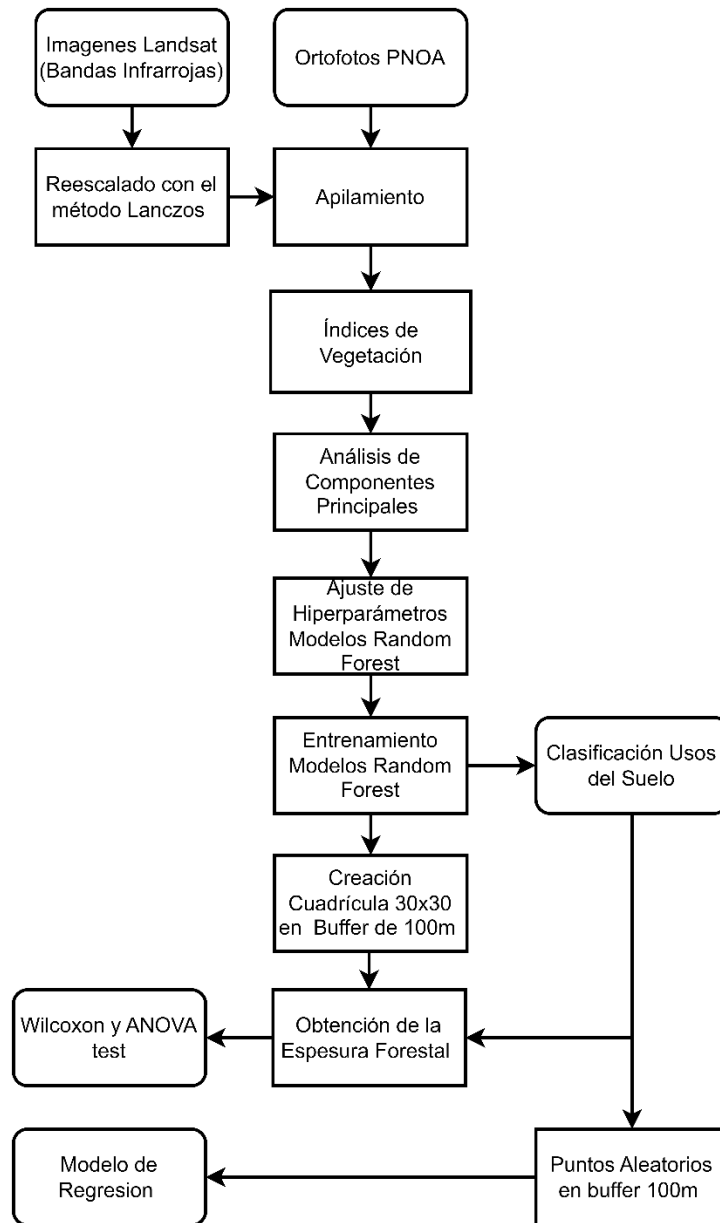


Figura 2. Flujo de Trabajo.

3.1. Obtención y Procesado de Datos de Teledetección

Se utiliza un conjunto de datos de distintas fuentes de teledetección para realizar el análisis de componentes principales y entrenar los modelos “Random Forest” que permitan estimar la fracción de cabida cubierta o el porcentaje de suelo cubierto por vegetación y, por tanto, las superficies forestales. Los datos utilizados, como ya se ha mencionado previamente, corresponden a las ortofotos obtenidas del PNOA y al valor medio de las imágenes de satélite del programa Landsat obtenidas a través de Google Earth Engine. En consecuencia, y debido a las diferencias en la resolución espacial entre ambas fuentes de datos (30m para imágenes satelitales y 0,5m o menos, dependiendo del año, para las ortofotos), se utiliza el método de

interpolación lanczos (Sales et al., 2023) para reescalar las resoluciones de ambas fuentes a una resolución espacial objetivo de 0,5m.

Posteriormente, se calcula un conjunto de índices espectrales de vegetación a partir principalmente de las bandas del espectro visible de las ortofotos, cuyos valores de reflectancia fueron escalados en un rango desde 0 hasta 1, coincidiendo con el rango de valores de reflectancia de las imágenes Landsat. Adicionalmente, se calcula también un índice de vegetación de la combinación de las bandas infrarrojas de las imágenes Landsat y de las bandas de las ortofotos. El objetivo es extraer información sobre la salud y el estado de la vegetación en las áreas circundantes a la infraestructura vial, permitiendo aumentar la precisión en la identificación de la presencia de vegetación y tipos de vegetación. Los índices espectrales de vegetación utilizados, así como su ecuación, se muestran en el Cuadro 1.

Cuadro 1. Índices Espectrales de Vegetación Calculados como Predictores

Índice	Ecuación	Fuente
Índice de Vegetación de Diferencia Normalizada (NDVI)	$\frac{NIR - Red}{NIR + Red}$	Rouse et al. (1973)
Índice de Vegetación de Diferencia Visible (GLI)	$\frac{(2 * Green) - Red - Blue}{(2 * Green) + Red + Blue}$	Louhaichi et al. (2001)
Índice de Diferencia Normalizada Verde-Rojo (NGRDI)	$\frac{Green - Red}{Green + Red}$	Gitelson et al. (2002)
Índice de Relación Ajustada Visible (VARI)	$\frac{Green - Red}{Green + Red - Blue}$	Gitelson et al. (2003)
Índice de Relación Verde-Rojo (GRR)	$\frac{Green}{Red}$	Gamon & Surfus (1999)
Índice de Vegetación Verde-Rojo Modificado (MGRVI)	$\frac{(Green^2) - (Red^2)}{(Green^2) + (Red^2)}$	Bendig et al. (2015)
Índice de Vegetación Visible (VEG)	$\frac{Green}{(Red^{0.667}) + (Blue^{(1-0.667)})}$	Hague et al. (2006)

3.2. Entrenamiento y Validación de los Modelos de Machine Learning

En lo que respecta al entrenamiento y validación de los modelos para generar las máscaras de identificación de presencia de vegetación para cada una de las ortofotos utilizadas en combinación con su respectiva imagen satelital y sus índices de vegetación, se usan un total de 500 puntos seleccionados manualmente sobre las ortofotos y distribuidos en cuatro clases: cultivos, forestal, carreteras y casas/núcleos poblacionales. A dichos puntos se les realiza el análisis de componentes principales, seleccionando aquellos vectores que describan más del 99% de la varianza de los valores de reflectancia. Posteriormente, dichos puntos se particionan en una proporción 80/20 utilizados para entrenamiento y testeo de los modelos, es decir, el número total de puntos con los valores de reflectancia en el nuevo espacio vectorial se divide asignando aleatoriamente el 80 % para el entrenamiento y el 20 % para la prueba del modelo,

garantizando que la división se realiza proporcionalmente a través del territorio y las variables explicativas.

A continuación, como se ha mencionado en distintas ocasiones a lo largo de este documento, se emplea el algoritmo "Random Forest", el cual ofrece varias ventajas en diversos campos (Liu et al., 2015; Nandy et al., 2021; Nitze et al., 2015). Este tipo de modelos supera a otros métodos de aprendizaje automático tanto en precisión como en manejo de conjuntos de datos siendo, además, menos sensible al ajuste de parámetros, utilizando algoritmos bagging o boosting para seleccionar predictores (Wang et al., 2016). No obstante, se requiere un ajuste cuidadoso de los hiperparámetros para evitar una complejidad excesiva del modelo y el sobreentrenamiento (Maxwell et al., 2018; Singh et al., 2024). Por lo tanto, se realiza un total de 464 simulaciones para seleccionar los hiperparámetros "ntree" y "mtry" más adecuados para cada modelo entrenado, respectivo a cada ortofoto con su respectiva imagen Landsat.

Por último, los modelos de clasificación generados se evalúan mediante la matriz de confusión y el coeficiente Kappa (Ecuación 1). El coeficiente Kappa mide la concordancia entre las predicciones y las observaciones, ajustando el rendimiento del modelo en relación con las expectativas aleatorias. Un Kappa más alto indica una mayor concordancia, ofreciendo una evaluación precisa y sólida del modelo.

$$Kappa = \frac{N \sum_{i=1}^k X_{ii} - \sum_{i=1}^k (X_{i+} * X_{+i})}{N^2 - \sum_{i=1}^k (X_{i+} * X_{+i})} \quad (1)$$

En dicha ecuación: N representa el número total de observaciones, y k es el número de clases. X_{ii} denota la frecuencia observada de la clase i tanto en las observaciones reales como en las predicciones. X_{i+} es la suma de la fila i -ésima de la matriz de confusión, y X_{+i} es la suma de la columna i -ésima de la matriz de confusión.

3.3. Análisis y Evaluación de los Cambios en la Superficie Forestal

Una vez que los modelos han sido entrenados, se aplican al conjunto de imágenes utilizadas, obteniendo así una clasificación de los usos del suelo para las cuatro clases definidas. Posteriormente, los resultados se binarizan utilizando como clase objetivo la categoría "forestal", a la cual se le asigna un valor de 1, mientras que a las tres clases restantes un valor de 0.

A continuación, se crea una cuadrícula de 30x30 metros, coincidente con el tamaño de píxel de Landsat, la cual abarca los 100 metros alrededor del dominio público de la autovía, excluyendo este último del cálculo. Para cada celda de la cuadrícula, se calcula la fracción de cabida cubierta para cada año analizado. Asimismo, se determina el valor medio de los años previos y posteriores a la construcción de la vía. Este análisis permite observar las variaciones en la cobertura forestal a lo largo del tiempo.

Posteriormente, se realiza un test ANOVA para evaluar si existen diferencias en la superficie forestal o en el porcentaje de suelo cubierto por vegetación entre los años previos y posteriores, evaluando cada uno de manera individual, así como considerando los valores medios previos y

posteriores. Este enfoque estadístico ofrece una visión clara de si las variaciones observadas son estadísticamente significativas. Asimismo, y dado que no se puede asumir la normalidad en la distribución de las muestras, se lleva a cabo una prueba de Wilcoxon para comparar los valores medios de los años previos y posteriores, analizando estos valores de manera pareada con el fin de identificar cambios específicos en la cobertura forestal.

Finalmente, se desarrolla un modelo de regresión que permite explorar la relación entre las variables analizadas, utilizando tanto los años como la distancia al dominio público de la autovía. Este modelo no solo facilita la comprensión del impacto de la autovía en el uso del suelo, sino que también ayuda a predecir tendencias futuras en la cobertura forestal. Además, proporciona una herramienta valiosa para la comprensión y análisis de los impactos sobre el territorio, contribuyendo así al entendimiento de los impactos en los ecosistemas forestales en la región.

4. RESULTADOS

En este apartado se presentan los principales resultados derivados del análisis de los datos y del entrenamiento de los modelos obtenidos mediante la metodología empleada. Los resultados se organizan siguiendo la metodología, desde la preparación de los datos hasta el entrenamiento de los modelos y análisis estadístico de las diferencias. El Cuadro 2 muestra el total de vectores seleccionados después del análisis de componentes principales, así como los hiperparámetros con el mejor ajuste y las métricas de evaluación. En dicho cuadro se puede observar que todos los modelos alcanzaron precisiones superiores al 85% y coeficientes kappa de concordancia casi perfecta

Cuadro 2. Resumen de los hiperparámetros y métricas obtenidas.

Año Modelo	Número de CP	mtry	ntree	Precisión Test	Kappa Test	Error Test en Forestal
2003	6	6	50	0.96	0.95	0.04
2007	7	2	50	0.88	0.84	0.08
2009	5	5	50	0.94	0.92	0.04
2014	6	2	500	0.88	0.84	<0.01
2017	5	4	100	0.93	0.91	0.08
2020	5	2	50	0.90	0.87	<0.01

En lo que respecta a la distribución de las superficies forestales, la Figura 3 muestra la distribución media de cada uno de los años analizados a través de un diagrama de cajas. En dicho diagrama, se puede observar que, para los años posteriores a la construcción de la vía, es decir, a partir del año 2014, hay una disminución en la superficie forestal, tendencia que se mantiene a lo largo de los diversos años. Por su parte, es importante destacar una disminución notable en la superficie media para el año 2007, lo cual ocurre puntualmente para ese año en particular, siendo analizado en mayor profundidad en la siguiente sección de discusión. Del mismo modo, la Figura 4 muestra los valores medios en un diagrama de cajas de todos los años previos y posteriores a la construcción, es decir, el valor medio de la superficie para cada uno de los puntos analizados: por un lado, para los años 2003, 2007 y 2009 como periodo previo a la construcción, y por el otro, para 2014, 2017 y 2020 como años posteriores a la construcción.

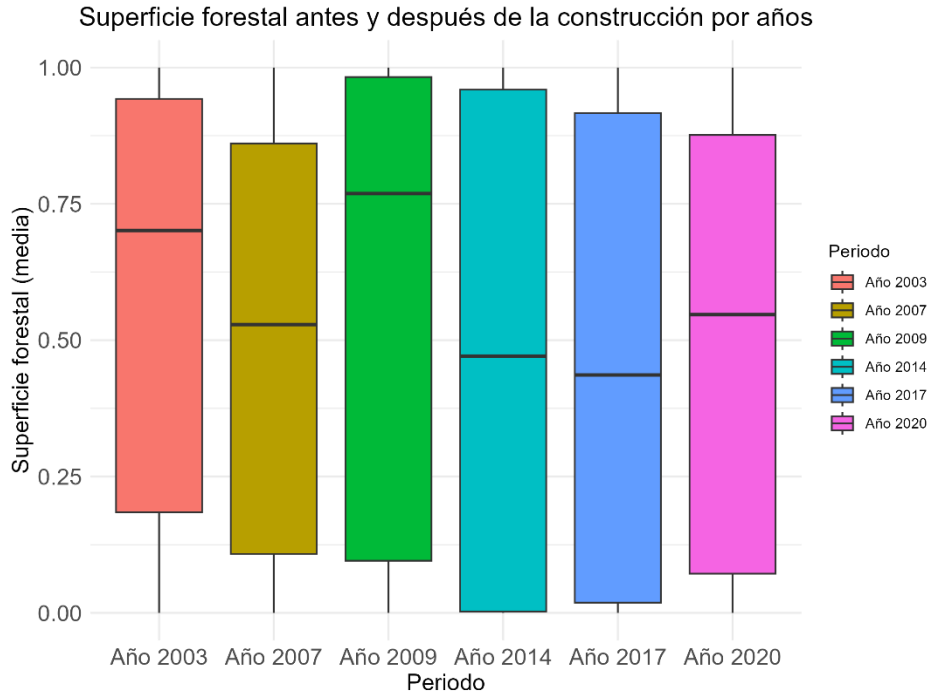


Figura 3. Diagrama de Cajas para cada uno de los años previos y posteriores a la construcción de la autovía.

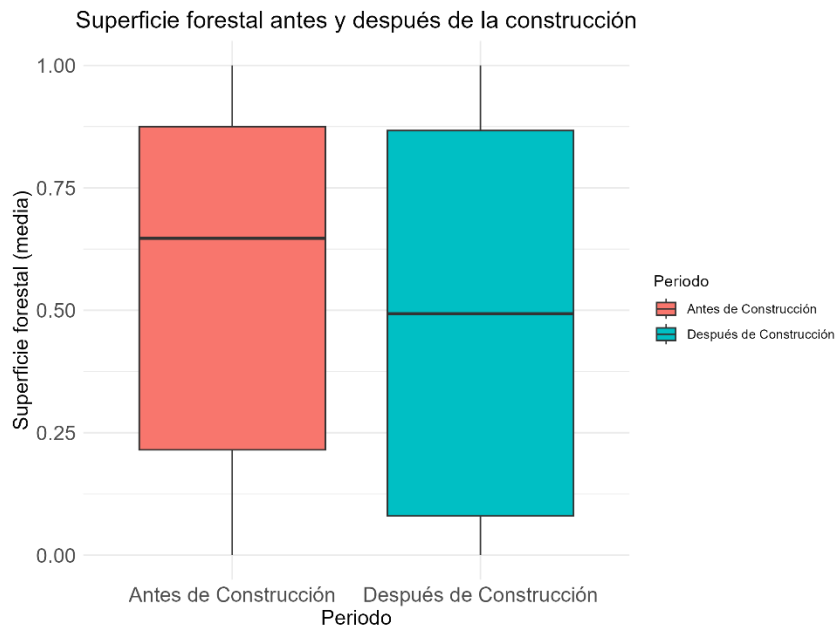


Figura 4. Diagrama de Cajas de los valores medios de los años previos y posteriores a la construcción de la autovía.

Finalmente, se realizó el test de ANOVA y el test de Wilcoxon, en los cuales se demostró que la superficie media antes de la construcción de la autovía es significativamente diferente de la

superficie media después de la construcción de la autovía, con p valores menores a 0.01 para la prueba pareada de Wilcoxon. En el cuadro 3, se pueden observar las distintas pruebas aplicadas para los diferentes períodos y los valores de p obtenidos para cada una de las pruebas. Asimismo, en lo referente al modelo de regresión, el cuadro 4 muestra las diferentes métricas de rendimiento obtenidas en el modelo y, en donde las variables utilizadas, es decir, distancia a la vía y los años desde o previos a la construcción, resultaron ser estadísticamente significativas, con p valores inferiores a 0.001.

Cuadro 3. P valores para las pruebas estadísticas pareadas.

Período Pareado	P Valor (Anova)	P Valor (Wilcoxon)
Media Antes/Después	---	<0.001
2009 (previo)/2014 (posterior)	---	<0.001
Cada año individualmente	<0.001	---

Cuadro 4. Resumen de las métricas de Rendimiento del Modelo de Regresión

Métrica	Valor
Precisión	0.5231
Sensibilidad	0.5436
Especificidad	0.5485
Valor F1	0.5331

5. DISCUSIÓN Y CONCLUSIÓN

Se realizaron varios análisis de componentes principales de los datos de teledetección empleados y se ajustaron los hiperparámetros de los diversos modelos random forest para clasificar e identificar la vegetación arbórea y, por tanto, obtener la superficie forestal y la fracción de cabida cubierta en los diferentes años previos y posteriores a la construcción de la autovía AG-31. Como resultado, se exploraron diferentes fuentes de datos de teledetección, su combinación y reescalado óptimo en conjunto con variables proxy, tales como los índices de vegetación, para estudiar los cambios y afecciones que podría tener la construcción de una autovía en relación a la espesura de las masas forestales para la región de Ourense. Por lo tanto, en esta sección se analizan y discuten los resultados obtenidos utilizando la metodología desarrollada.

Por su parte, los resultados obtenidos indican una disminución significativa en la superficie forestal tras la construcción de la autovía, corroborando la hipótesis de que las infraestructuras lineales pueden tener efectos adversos en los ecosistemas circundantes, lo cual se encuentra en línea con lo demostrado por Braham et al. (2023) o Vepakomma et al. (2018), quienes, a pesar de no haber analizado el estado previo y posterior a la construcción de una infraestructura lineal, analizaron las diferencias en la espesura forestal a distintas distancias de dicha infraestructura o perturbación ya construida, obteniendo que la fracción de cabida cubierta era menor cuanto más cerca se encontraba del borde de la infraestructura, exponiendo el impacto de este tipo de alteraciones en los ecosistemas forestales circundantes. Sin embargo, Nguyen et al. (2023)

demonstró que la presencia o ausencia de una perturbación lineal puede tener diversos impactos en los ecosistemas forestales, pero la espesura de las masas forestales no se ve significativamente alterada, lo cual contrasta con nuestro análisis. No obstante, la aplicación de pruebas estadísticas, como ANOVA y Wilcoxon, han permitido establecer que las diferencias observadas en la superficie media de vegetación antes y después de la construcción son estadísticamente significativas, lo cual sugiere que la construcción de la autovía no solo ha alterado la estructura de las masas forestales, sino que también ha tenido un impacto duradero en la composición de la vegetación en la zona. Además, los resultados del modelo de regresión reflejan la significación tanto de la escala temporal como de la distancia de las masas forestales a la infraestructura del transporte, lo que respalda la relevancia de las variables analizadas en la evaluación de estos impactos.

Asimismo, es importante destacar la disminución en la superficie media de vegetación en el año 2007, anterior a la inauguración de la autovía, la cual podría estar vinculada a incendios forestales ocurridos en la región analizada (Suárez-Fernández et al., 2023). Aunque la superficie afectada por dichas perturbaciones no fuera excesiva, la alteración de las áreas circundantes a las zonas quemadas pudo impactar negativamente el estado vegetativo de las masas forestales adyacentes. Esto se corrobora ya que, como se observa, para la siguiente imagen analizada, la señal espectral de la vegetación ya había mostrado signos de recuperación, alcanzando ese valor medio de la superficie de vegetación previo al 2007, lo cual concuerda con lo señalado por Melchiorre & Boschetti (2018), quienes afirman que, tras un incendio, la vegetación para las latitudes y bioma analizado suele tardar aproximadamente 67 días en recuperar su estado espectral. Sin embargo, como demuestran Bright et al. (2019) y Guz et al. (2022), este tiempo de recuperación podría variar de acuerdo con la severidad del incendio, al tipo de vegetación dominante y a la climatología posterior a la perturbación. A pesar de ello, las diferencias en la superficie forestal para el año mencionado se observan de manera puntual, a diferencia de la superficie media posterior a la construcción, cuyo valor se mantiene relativamente constante en los diferentes años analizados.

Con respecto a la generación de los modelos random forest para la clasificación de las cuatro clases utilizadas, se observó que todos los modelos alcanzaron métricas de desempeño con precisiones bastante altas, lo cual se debió en parte al ajuste de los hiperparámetros. Tal como refleja Maxwell et al. (2018; Singh et al., 2024), el ajuste cuidadoso de los hiperparámetros «mtry» y «ntree» es necesario para evitar una complejidad excesiva del modelo y el sobreentrenamiento, siendo específico para cada modelo, lo cual permitió una optimización del equilibrio entre estabilidad y capacidad de predicción para cada uno de los años analizados. Asimismo, mediante el análisis de componentes principales, se permitió, por un lado, reducir la dimensionalidad del conjunto de datos explicativos y, por otro, eliminar problemas como la multicolinealidad, siendo este uno de los limitantes más comunes en los trabajos de teledetección. Chan et al. (2022) muestra que los análisis de multicolinealidad permiten identificar y eliminar variables redundantes que no aportan información adicional al modelo, a la vez que mejoran la interpretabilidad de los resultados y la robustez del modelo final, facilitando así una clasificación más precisa y confiable de las diferentes clases de uso del suelo.

En cuanto a las limitaciones de este estudio, por un lado, es importante destacar la no consideración que otros tipos de actividades pudiesen tener en la variabilidad de la estructura forestal, es decir, futuras investigaciones deberían de centrarse en analizar la influencia y presión que pudiesen tener los diversos usos del suelo y las diversas actividades económicas en

la alteración de la estructura de las masas forestales. Por otro lado, la falta de datos que permitiesen describir la distribución vertical de la estructura es otro de los limitantes; una descripción de la estructura vertical a lo largo de distintos periodos temporales es esencial, ya que proporciona información crucial sobre la diversidad y la salud del ecosistema forestal. La estructura vertical puede influir en la capacidad de las masas forestales para soportar cambios ambientales, así como en su resiliencia ante perturbaciones, lo que a su vez afecta la biodiversidad y la funcionalidad del ecosistema. Por lo tanto, integrar este tipo de análisis en estudios futuros podría ofrecer una comprensión más completa de las dinámicas forestales y sus respuestas a las intervenciones humanas.

En conclusión, este estudio proporcionó evidencia sobre el impacto de la construcción de infraestructuras viales en la superficie forestal en la región de Ourense, lo cual ha permitido una comprensión más contextualizada de los impactos antropogénicos en dicha región, evidenciando la disminución en la fracción de cabida cubierta media tras la construcción de la autovía AG-31. Además, la combinación de teledetección y análisis estadístico ha permitido una evaluación detallada de los cambios e impactos en la vegetación, subrayando la necesidad de un enfoque integral en la gestión del territorio que contemple la interacción entre infraestructuras y ecosistemas forestales. Por consiguiente, futuros trabajos deben continuar explorando estas interacciones considerando las limitaciones anteriormente mencionadas y evaluando diversas regiones climáticas.

AGRADECIMIENTOS

Este trabajo ha contado con el apoyo de «Ayudas para la Formación de Profesorado Universitario (FPU)», Ministerio de Educación, Gobierno de España [FPU21/03038]. La publicación forma parte del proyecto TED2021-132000B-I00, financiado por MCIN/AEI/10.13039/501100011033 y por la Unión Europea «NextGenerationEU»/PRTR».

BIBLIOGRAFIA

- Ali, A. (2023). Linking forest ecosystem processes, functions and services under integrative social–ecological research agenda: current knowledge and perspectives. In *Science of the Total Environment* (Vol. 892). Elsevier B.V. <https://doi.org/10.1016/j.scitotenv.2023.164768>
- Bendig, J., Yu, K., Aasen, H., Bolten, A., Bennertz, S., Broscheit, J., Gnyp, M. L., & Bareth, G. (2015). Combining UAV-based plant height from crop surface models, visible, and near infrared vegetation indices for biomass monitoring in barley. *International Journal of Applied Earth Observation and Geoinformation*, 39, 79–87. <https://doi.org/10.1016/j.jag.2015.02.012>
- Braham, N., Valeria, O., & Imbeau, L. (2023). Characterization of Vegetation Dynamics on Linear Features Using Airborne Laser Scanning and Ensemble Learning. *Forests*, 14(3). <https://doi.org/10.3390/f14030511>
- Brando, P. M., Silvério, D., Maracahipes-Santos, L., Oliveira-Santos, C., Levick, S. R., Coe, M. T., Migliavacca, M., Balch, J. K., Macedo, M. N., Nepstad, D. C., Maracahipes, L., Davidson, E.,

- Asner, G., Kelle, O., & Trumbore, S. (2019). Prolonged tropical forest degradation due to compounding disturbances: Implications for CO₂ and H₂O fluxes. *Global Change Biology*, 25(9), 2855–2868. <https://doi.org/10.1111/gcb.14659>
- Bright, B. C., Hudak, A. T., Kennedy, R. E., Braaten, J. D., & Henareh Khalyani, A. (2019). Examining post-fire vegetation recovery with Landsat time series analysis in three western North American forest types. *Fire Ecology*, 15(1). <https://doi.org/10.1186/s42408-018-0021-9>
- Campbell, M. J., Edwards, W., Magrath, A., Alamgir, M., Porolak, G., Mohandass, D., & Laurance, W. F. (2018). Edge disturbance drives liana abundance increase and alteration of liana–host tree interactions in tropical forest fragments. *Ecology and Evolution*, 8(8), 4237–4251. <https://doi.org/10.1002/ece3.3959>
- Chan, J. Y. Le, Leow, S. M. H., Bea, K. T., Cheng, W. K., Phoong, S. W., Hong, Z. W., & Chen, Y. L. (2022). Mitigating the Multicollinearity Problem and Its Machine Learning Approach: A Review. In *Mathematics* (Vol. 10, Issue 8). MDPI. <https://doi.org/10.3390/math10081283>
- Chinembiri, T. S., Mutanga, O., & Dube, T. (2023). Hierarchical Bayesian geostatistics for C stock prediction in disturbed plantation forest in Zimbabwe. *Ecological Informatics*, 73. <https://doi.org/10.1016/j.ecoinf.2022.101934>
- Coffin, A. W. (2007). From roadkill to road ecology: A review of the ecological effects of roads. *Journal of Transport Geography*, 15(5), 396–406. <https://doi.org/10.1016/j.jtrangeo.2006.11.006>
- Davidson, S. J., Goud, E. M., Malhotra, A., Estey, C. O., Korsah, P., & Strack, M. (2021). Linear Disturbances Shift Boreal Peatland Plant Communities Toward Earlier Peak Greenness. *Journal of Geophysical Research: Biogeosciences*, 126(8). <https://doi.org/10.1029/2021JG006403>
- Delgado, J. D., Arroyo, N. L., Arévalo, J. R., & Fernández-Palacios, J. M. (2007). Edge effects of roads on temperature, light, canopy cover, and canopy height in laurel and pine forests (Tenerife, Canary Islands). *Landscape and Urban Planning*, 81(4), 328–340. <https://doi.org/10.1016/j.landurbplan.2007.01.005>
- Dormann, C. F., Bagnara, M., Boch, S., Hinderling, J., Janeiro-Otero, A., Schäfer, D., Schall, P., & Hartig, F. (2020). Plant species richness increases with light availability, but not variability, in temperate forests understorey. *BMC Ecology*, 20(1). <https://doi.org/10.1186/s12898-020-00311-9>
- Gamon, J. A., & Surfus, J. S. (1999). Assessing leaf pigment content and activity with a reflectometer. *New Phytologist*, 143(1), 105–117. <https://doi.org/10.1046/j.1469-8137.1999.00424.x>
- Gitelson, A. A., Kaufman, Y. J., Stark, R., & Rundquist, D. (2002). Novel algorithms for remote estimation of vegetation fraction. *Remote Sensing of Environment*, 80(1), 76–87. [https://doi.org/10.1016/S0034-4257\(01\)00289-9](https://doi.org/10.1016/S0034-4257(01)00289-9)

- Gitelson, A. A., Viña, A., Arkebauer, T. J., Rundquist, D. C., Keydan, G., & Leavitt, B. (2003). Remote estimation of leaf area index and green leaf biomass in maize canopies. *Geophysical Research Letters*, *30*(5). <https://doi.org/10.1029/2002GL016450>
- Gobierno de España: Ministerio de Transportes, M. y A. Urbana. (2020). *Centro de Descargas del CNIG (IGN)*. DOI: 10.7419/162.09.2020. <http://centrodedescargas.cnig.es/CentroDescargas/index.jsp>
- Gorelick, N., Hancher, M., Dixon, M., Ilyushchenko, S., Thau, D., & Moore, R. (2017). Google Earth Engine: Planetary-scale geospatial analysis for everyone. *Remote Sensing of Environment*, *202*, 18–27. <https://doi.org/10.1016/j.rse.2017.06.031>
- Guz, J., Sangermano, F., & Kulakowski, D. (2022). The Influence of Burn Severity on Post-Fire Spectral Recovery of Three Fires in the Southern Rocky Mountains. *Remote Sensing*, *14*(6). <https://doi.org/10.3390/rs14061363>
- Hague, T., Tillett, N. D., & Wheeler, H. (2006). Automated Crop and Weed Monitoring in Widely Spaced Cereals. *Precision Agriculture*, *7*(1), 21–32. <https://doi.org/10.1007/s11119-005-6787-1>
- Ibáñez, I., Katz, D. S. W., Peltier, D., Wolf, S. M., & Connor Barrie, B. T. (2014). Assessing the integrated effects of landscape fragmentation on plants and plant communities: The challenge of multiprocess-multiresponse dynamics. *Journal of Ecology*, *102*(4), 882–895. <https://doi.org/10.1111/1365-2745.12223>
- Lemke, A., Kowarik, I., & von der Lippe, M. (2019). How traffic facilitates population expansion of invasive species along roads: The case of common ragweed in Germany. *Journal of Applied Ecology*, *56*(2), 413–422. <https://doi.org/10.1111/1365-2664.13287>
- Liang, X., Kankare, V., Hyypä, J., Wang, Y., Kukko, A., Haggrén, H., Yu, X., Kaartinen, H., Jaakkola, A., Guan, F., Holopainen, M., & Vastaranta, M. (2016). Terrestrial laser scanning in forest inventories. *ISPRS Journal of Photogrammetry and Remote Sensing*, *115*, 63–77. <https://doi.org/10.1016/j.isprsjprs.2016.01.006>
- Liu, M., Liu, X., Liu, D., Ding, C., & Jiang, J. (2015). Multivariable integration method for estimating sea surface salinity in coastal waters from in situ data and remotely sensed data using random forest algorithm. *Computers and Geosciences*, *75*, 44–56. <https://doi.org/10.1016/j.cageo.2014.10.016>
- Louhaichi, M., Borman, M. M., & Johnson, D. E. (2001). Spatially Located Platform and Aerial Photography for Documentation of Grazing Impacts on Wheat. *Geocarto International*, *16*(1), 65–70. <https://doi.org/10.1080/10106040108542184>
- Mahon, C. L., Holloway, G. L., Bayne, E. M., & Toms, J. D. (2019). Additive and interactive cumulative effects on boreal landbirds: winners and losers in a multi-stressor landscape. *Ecological Applications*, *29*(5). <https://doi.org/10.1002/eap.1895>
- Maxwell, A. E., Warner, T. A., & Fang, F. (2018). Implementation of machine-learning classification in remote sensing: An applied review. In *International Journal of Remote*

- Sensing* (Vol. 39, Issue 9, pp. 2784–2817). Taylor and Francis Ltd. <https://doi.org/10.1080/01431161.2018.1433343>
- Melchiorre, A., & Boschetti, L. (2018). Global analysis of burned area persistence time with MODIS data. *Remote Sensing*, 10(5). <https://doi.org/10.3390/rs10050750>
- Nandy, S., Srinet, R., & Padalia, H. (2021). Mapping Forest Height and Aboveground Biomass by Integrating ICESat-2, Sentinel-1 and Sentinel-2 Data Using Random Forest Algorithm in Northwest Himalayan Foothills of India. *Geophysical Research Letters*, 48(14). <https://doi.org/10.1029/2021GL093799>
- Ng, C. P., Law, T. H., Wong, S. V., & Kulanthayan, S. (2017). Relative improvements in road mobility as compared to improvements in road accessibility and economic growth: A cross-country analysis. *Transport Policy*, 60, 24–33. <https://doi.org/10.1016/j.tranpol.2017.08.004>
- Nguyen, T. A., Ehbrecht, M., & Camarretta, N. (2023). Application of point cloud data to assess edge effects on rainforest structural characteristics in tropical Sumatra, Indonesia. *Landscape Ecology*, 38(5), 1191–1208. <https://doi.org/10.1007/s10980-023-01609-x>
- Nitze, I., Barrett, B., & Cawkwell, F. (2015). Temporal optimisation of image acquisition for land cover classification with random forest and MODIS time-series. *International Journal of Applied Earth Observation and Geoinformation*, 34(1), 136–146. <https://doi.org/10.1016/j.jag.2014.08.001>
- Rouse, J. W., Haas, R. H., Schell, J. A., & Deering, D. W. (1973). Monitoring Vegetation Systems in the Great Plains with ERTS. *3rd ERTS Symposium, NASA SP-351*, 309–317.
- Sales, V., Marques, A., Racolte, G., Nunes, A., Guimaraes, T., Zanotta, D., Spigolon, A., Gonzaga, L., & Roberto Veronez, M. (2023). Evaluation of Resampling Techniques to Provide Better Synthesized Input Data to Super-Resolution Deep Learning Model Training. *International Geoscience and Remote Sensing Symposium (IGARSS), 2023-July*, 7368–7371. <https://doi.org/10.1109/IGARSS52108.2023.10281470>
- Silva da Costa, W., Da Cunha, M., José F. Pena Rodrigues, P., de Andrade Iguatemy, M., Valladares, F., & Franca Barros, C. (2020). Intraspecific variation in functional wood anatomy of tropical trees caused by effects of forest edge. *Forest Ecology and Management*, 473. <https://doi.org/10.1016/j.foreco.2020.118305>
- Singh, R. K., Biradar, C. M., Behera, M. D., Prakash, A. J., Das, P., Mohanta, M. R., Krishna, G., Dogra, A., Dhyani, S. K., & Rizvi, J. (2024). Optimising carbon fixation through agroforestry: Estimation of aboveground biomass using multi-sensor data synergy and machine learning. *Ecological Informatics*, 79. <https://doi.org/10.1016/j.ecoinf.2023.102408>
- Siry, J. P., Cabbage, F. W., & Ahmed, M. R. (2005). Sustainable forest management: Global trends and opportunities. *Forest Policy and Economics*, 7(4), 551–561. <https://doi.org/10.1016/j.forpol.2003.09.003>

- Suárez-Fernández, G. E., Martínez-Sánchez, J., & Arias, P. (2023). A NOVEL METHODOLOGY FOR THE AUTOMATIC ACQUISITION OF REAL FOREST FIRE DATASETS OVER LONG PERIODS OF TIME. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*, 48(1/W1-2023), 465–472. <https://doi.org/10.5194/isprs-archives-XLVIII-1-W1-2023-465-2023>
- Uliasz-Misiak, B., Winid, B., Lewandowska-Śmierchalska, J., & Matuła, R. (2022). Impact of road transport on groundwater quality. *Science of the Total Environment*, 824. <https://doi.org/10.1016/j.scitotenv.2022.153804>
- United Nations. (2015). *Resolution adopted by the General Assembly on 25 September 2015. Transforming our world: the 2030 Agenda for Sustainable Development.*
- Vepakomma, U., Kneeshaw, D. D., & De Grandpré, L. (2018). Influence of natural and anthropogenic linear canopy openings on forest structural patterns investigated using LiDAR. *Forests*, 9(9). <https://doi.org/10.3390/f9090540>
- Wang, L., Zhou, X., Zhu, X., Dong, Z., & Guo, W. (2016). Estimation of biomass in wheat using random forest regression algorithm and remote sensing data. *Crop Journal*, 4(3), 212–219. <https://doi.org/10.1016/j.cj.2016.01.008>
- Wekesa, C., Kirui, B. K., Maranga, E. K., & Muturi, G. M. (2019). Variations in forest structure, tree species diversity and above-ground biomass in edges to interior cores of fragmented forest patches of Taita Hills, Kenya. *Forest Ecology and Management*, 440, 48–60. <https://doi.org/10.1016/j.foreco.2019.03.011>
- Yang, Q., Liu, X., Huang, Z., Guo, B., Tian, L., Wei, C., Meng, Y., & Zhang, Y. (2022). Integrating satellite-based passive microwave and optically sensed observations to evaluating the spatio-temporal dynamics of vegetation health in the red soil regions of southern China. *GIScience and Remote Sensing*, 59(1), 215–233. <https://doi.org/10.1080/15481603.2021.2023841>
- Zeng, Y., Hao, D., Huete, A., Dechant, B., Berry, J., Chen, J. M., Joiner, J., Frankenberg, C., Bond-Lamberty, B., Ryu, Y., Xiao, J., Asrar, G. R., & Chen, M. (2022). Optical vegetation indices for monitoring terrestrial ecosystems globally. *Nature Reviews Earth & Environment*, 3(7), 477–493. <https://doi.org/10.1038/s43017-022-00298-5>
- Zhou, K., Lindenbergh, R., Gorte, B., & Zlatanova, S. (2020). LiDAR-guided dense matching for detecting changes and updating of buildings in Airborne LiDAR data. *ISPRS Journal of Photogrammetry and Remote Sensing*, 162, 200–213. <https://doi.org/10.1016/j.isprsjprs.2020.02.005>