

Premio Universitario de la SECF al mejor Trabajo Fin de Máster Oficial

Integrando teledetección e inventario multi-temporales a escala árbol (Eucalyptus) para predecir dinámica forestal y optimizar la gestión forestal en Mato Grosso, Brasil

Integrating remote sensing and multi-temporal inventory at tree scale (Eucalyptus) to predict forest dynamics and optimize forest management in Mato Grosso, Brazil

Tupinambá-Simões, F.^{1*}; Guerra-Hernández, J.³; Pascual, A.²; Bravo Oviedo, F.¹

¹ *Instituto de Investigación sobre Gestión Forestal Sostenible UVA-INIA, Palencia, Spain*

² *Departamento de Ciencias Geográficas, Universidad de Maryland, College Park, MD 20742, Estados Unidos de América*

³ *Centro de Investigación Forestal, Escuela de Agricultura, Universidad de Lisboa, Lisboa, Portugal*

* Autor de correspondencia: frederico.tupinamba@uva.es

Resumen

El establecimiento de especies arbóreas de rápido crecimiento (*Eucalyptus* spp.) es crucial para suministrar productos forestales a las economías en desarrollo. Sin embargo, la creciente frecuencia, gravedad y duración de las sequías amenazan la viabilidad de estos importantes ecosistemas. En Mato Grosso (Brasil), donde el estrés hídrico es el principal factor limitante del eucalipto, se registró en 2019 el segundo evento de sequía más grande de toda la serie histórica. Los datos del inventario forestal que comprenden miles de mediciones de árboles tomadas en 2019, 2020 y 2021 se han modelado utilizando modelos de efectos mixtos para identificar los factores más significativos que influyen en la mortalidad y la dinámica de crecimiento de los cuatro genotipos de eucalipto diferentes. Se utilizó un vehículo aéreo no tripulado (UAV) para obtener un mosaico de imágenes en el espectro visible -rojo, verde y azul (RGB)- a muy alta resolución (VHR), además de modelos digitales de superficie (DSM) y cálculos del índice de vegetación (VI), que se utilizaron en la clasificación de la mortalidad mediante una segmentación centrada en el objeto. Las tasas de crecimiento y mortalidad se vieron significativamente afectadas durante la sequía; el efecto de la sequía de 2019 fue más pronunciado en rodales con alta densidad de árboles. La selección del material genético y la densidad de plantación pueden utilizarse como factores silvícolas para gestionar más eficientemente las plantaciones forestales frente a los efectos del cambio climático, incluyendo los eventos de estrés hídrico extremo. Implicaciones: Este estudio ilustra la necesidad de ajustar las directrices silvícolas para reducir el impacto de la sequía en las plantaciones de *Eucalyptus* y cómo las tecnologías de teledetección, las mejoras genéticas y la investigación operativa aplicada pueden integrarse para mejorar la eficiencia y la resiliencia de las plantaciones de *Eucalyptus* y explorar los límites óptimos de productividad bajo el cambio global.

Palabras clave: *Seguimiento forestal, dinámica de crecimiento, silvicultura de producción, productividad.*

Abstract

Establishing fast-growing tree species (*Eucalyptus* spp.) is crucial in supplying forest products to developing economies. However, the increasing frequency, severity and duration of droughts threaten these important ecosystems' viability. In Mato Grosso, Brazil, where water stress is the main limiting factor for eucalyptus, the second-largest drought event in the entire historical series was recorded in 2019. The forest inventory data comprising thousands of tree measurements taken in 2019, 2020, and 2021 have been modeled using mixed effects models to identify the most significant factors influencing mortality and growth dynamics of the four different eucalyptus genotypes. An unmanned aerial vehicle (UAV) was used to obtain a mosaic of images in the visible spectrum - red, green, and blue (RGB) - at very high resolution (VHR), in addition to digital surface models (DSM) and vegetation index (VI) calculations, which were used in the classification of mortality using object-focused segmentation. Growth and mortality rates were significantly affected during the drought; The drought effect of 2019 was more pronounced in stands with high tree density. Genetic material selection and planting density can be used as silvicultural factors to more efficiently manage forest plantations in the face of climate change effects, including extreme water stress events. Implications: This study illustrates the need to adjust silvicultural guidelines to reduce the impact of drought on *Eucalyptus* plantations and how remote sensing technologies, genetic improvements, and applied operational research can be integrated to improve the efficiency and resilience of *Eucalyptus* plantations and explore optimal productivity limits under global change.

Palabras clave: *Forest monitoring, growth dynamics, production forestry, productivity.*

1. Introducción

Los bosques nativos y las plantaciones forestales comerciales se han visto fuertemente afectados por los impactos del cambio climático en las últimas décadas (Brook *et al.*, 2008; Foley *et al.*, 2005; Phillips *et al.*, 2009). Los episodios de sequía, los incendios forestales, los daños bióticos o los vientos amenazan el flujo de suministro de productos de las plantaciones forestales comerciales (Booth, 2013; Kirilenko & Sedjo, 2007; Laclau *et al.*, 2013). La reducción de la presión sobre los ecosistemas nativos es un resultado indirecto de la gestión sostenible y eficiente de las especies de crecimiento rápido.

Los bosques de eucalipto representan una importante fuente de ingresos para la economía brasileña, sector que se vio fuertemente afectado por una intensa y dañina sequía, el segundo episodio más seco jamás registrado en el país. La alteración de la dinámica de crecimiento puede tener efectos prolongados en los árboles, por lo que se necesita una evaluación más prolongada en el tiempo para evaluar el impacto real del 2019, efectivamente.

La sequía de 2019 podría haber expuesto a los genotipos a condiciones inéditas. La escala de los activos comerciales aboga por sistemas de prospección como los vehículos aéreos no tripulados (del inglés UAV) capaces de obtener imágenes de las plantaciones a alta resolución (Guerra-Hernández *et al.*, 2017, 2018). Los indicadores ecológicos y las variables de estructural de árbol individual derivadas de datos 3D requieren de ejercicios de validación y calibración que aseguren una estimación óptima de los patrones de mortalidad y evitar así el uso de imágenes hiperespectrales más costosas.

2. Objetivos

Específicamente, los objetivos en este estudio fueron:

1. Evaluar la mortalidad y la dinámica de crecimiento hacia los factores operativos del diseño de la plantación.
2. Crear mapas de mortalidad forestal debido a la sequía usando imágenes UAV en combinación con datos de calibración en campo.

3. Material y métodos

3.1 Área de estudio

El estudio se realizó en el municipio de Tangará da Serra, Mato Grosso, Brasil (*Fig. 1*). En el año 2019 presentó temperaturas máximas, mínimas y medias por encima de la media histórica, mientras que las precipitaciones estuvieron por debajo de la media de Junio a Diciembre, excepto en Agosto que mostró un ligero incremento (*Fig. 2*).

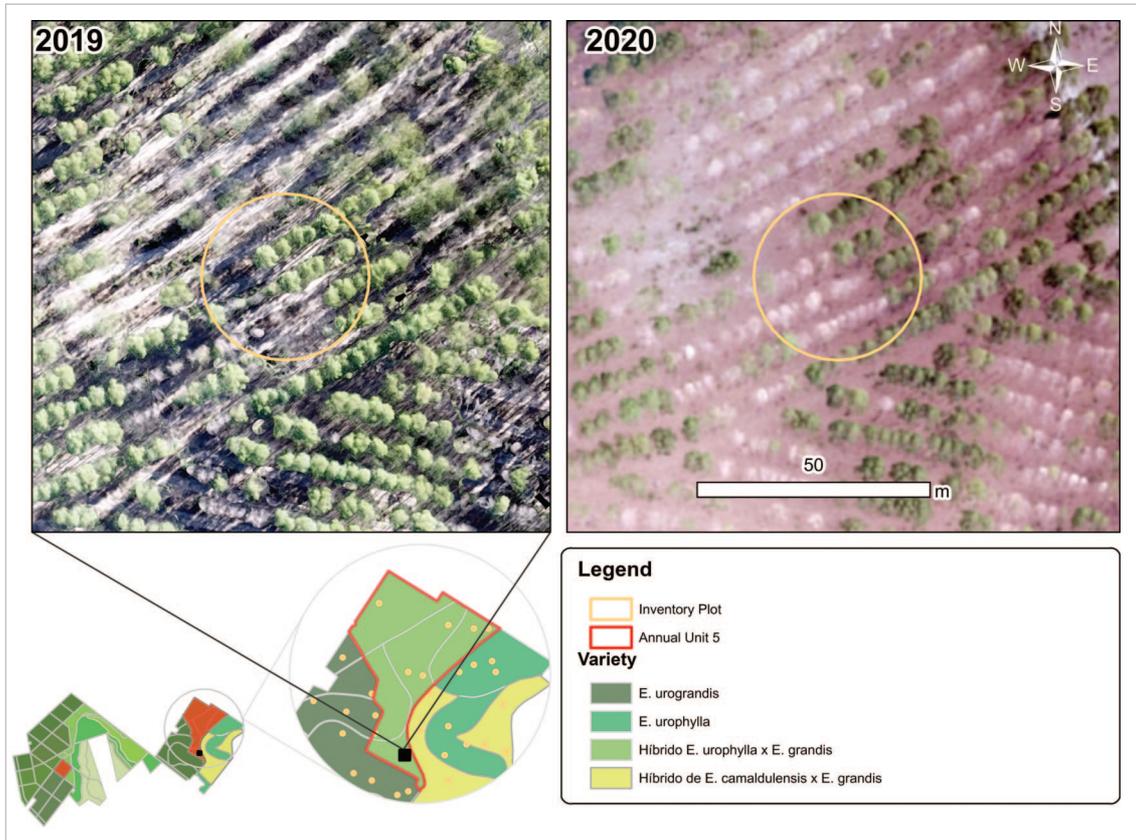


Figura 1. Área de estudio ubicada en Tangará da Serra, estado de Mato Grosso, en la región centro-oeste de Brasil. El mosaico de 4 bandas de LandSat 8 después de la sequía de 2019 (agosto de 2020) se presenta como fondo utilizando la representación de la vegetación en falso color (654 en el RGB).



Figura 2. Climograma de Tangará da Serra comparando la tendencia media 1982-2019, representada con puntos, con la temperatura media mensual del año 2019 (líneas) y la precipitación mensual del año (bars).

El área de estudio comprende 1.400 hectáreas de eucaliptos, compuestos por *E. urograndis*, el híbrido de *E. urophylla* x *E. grandis* (H13 - Miranda *et al.*, 2019), el *E. urophylla* (I144 - Pena, 2018), y el *E. camaldulensis* x *E. grandis* (1277 - dos Reis *et al.*, 2006) (Fig. 3).

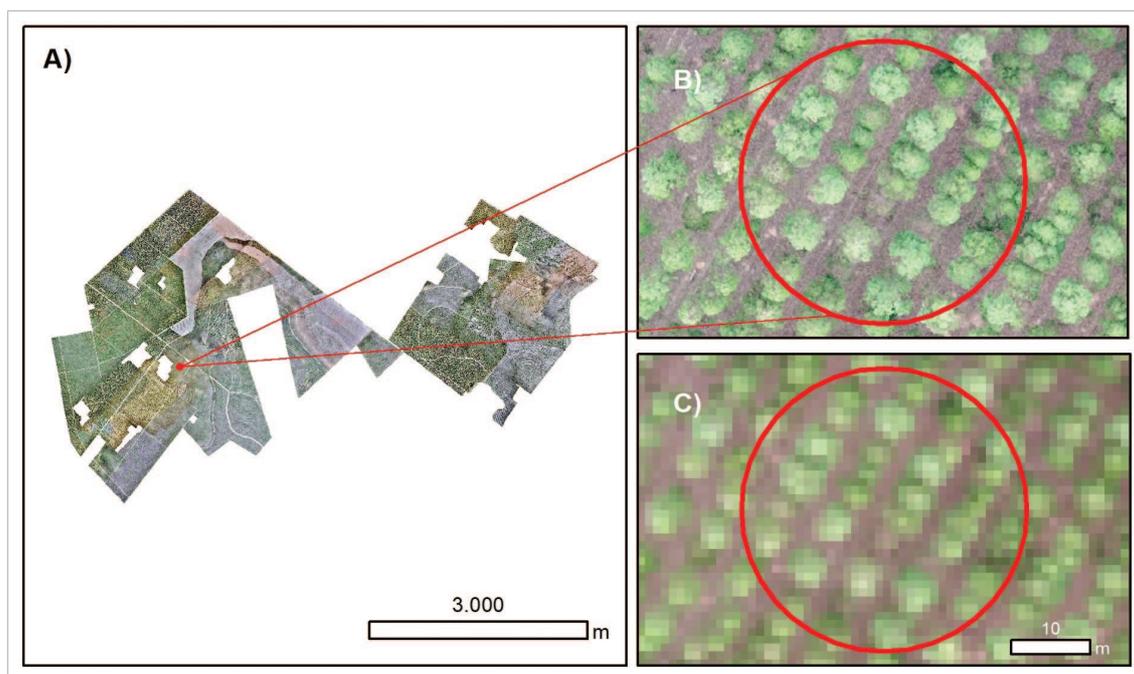


Figura 3. Visión general aérea de la zona de estudio mediante imágenes recogidas durante los muestreos con drones en 2019 y 2020 sobre el cuadro delimitador de la UPA n° 5 (cuadrado rojo) para ilustrar los efectos de la sequía de 2019 en la zona de entrenamiento. Se presenta la distribución espacial de los genotipos de los clones.

3.2 Datos de inventarios forestales multitemporales

Las mediciones a nivel de árbol se realizaron en abril de 2019 (t_1) y después de la sequía en Junio de 2020 (t_2) se utilizaron para evaluar la mortalidad de los árboles después de las condiciones de sequía; y sus consecuencias se confirieron en abril de 2021 (t_3). Los árboles fueron etiquetados y marcados en el campo para contabilizar adecuadamente el crecimiento y la mortalidad en t_2 y t_3 (Fig. 4).

Las mediciones de la altura de los árboles se ajustaron a los datos de las especies individuales, utilizando modelos de altura-diámetro para predecir la altura en las observaciones de los árboles restantes para los tres estudios, con el paquete de regresión no lineal "nlstools" (Baty *et al.*, 2015) en el software estadístico R (R Core Team, 2020).

3.3 Modelos de efectos mixtos para evaluar la mortalidad de los árboles

En esta investigación se utilizaron modelos de efectos mixtos para entender la influencia de los niveles de carga y genotipos principalmente en la mortalidad de los

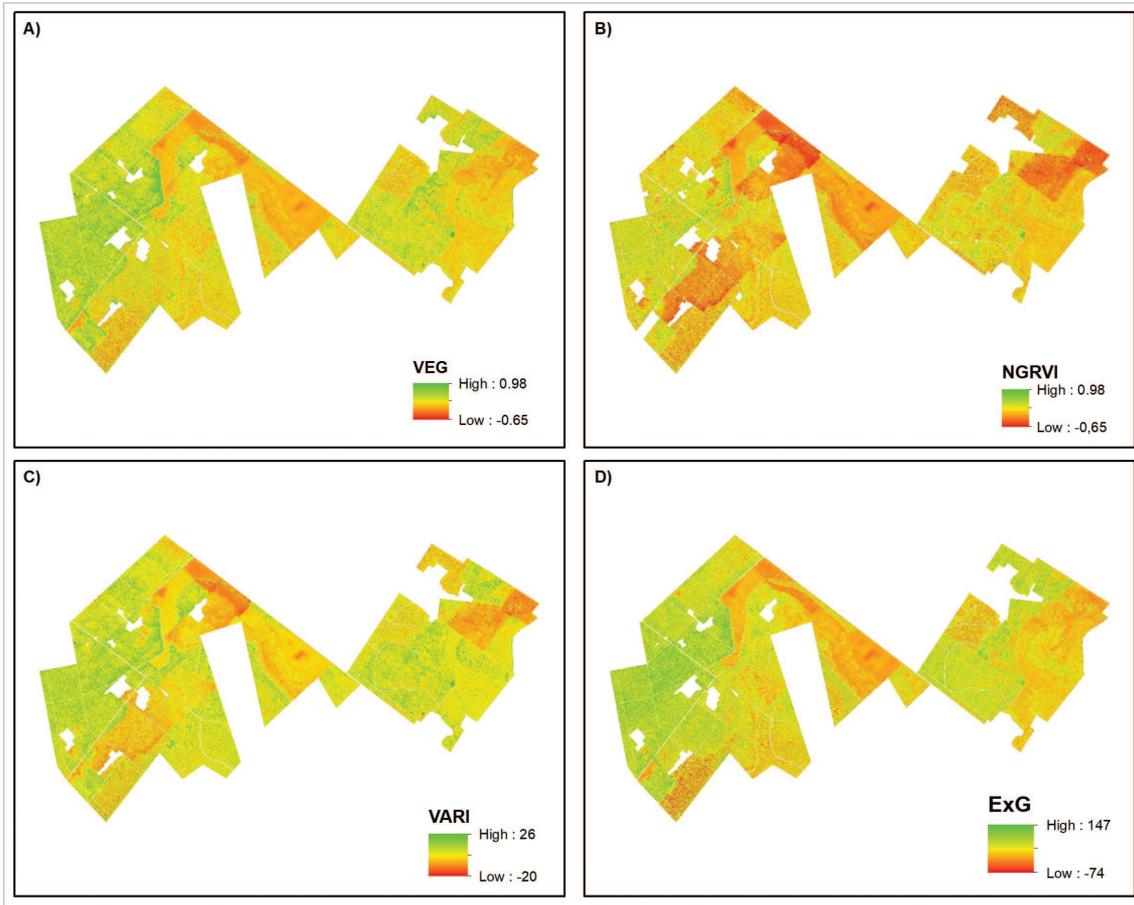


Figura 4. Registro fotográfico de todos los primeros árboles de la parcela, con coordenadas y acimut. La marca azul de la derecha indica el límite de la parcela, mientras que la F de la derecha representa el primer árbol de la parcela. Se marcó la altura del pecho a 1,3 m en todos los árboles medidos para poder seguir la evolución a lo largo de los muestreos anuales.

árboles de t_1 a t_2 utilizando las observaciones de t_3 para corregir los posibles errores de identificación de la mortalidad de los árboles en los estudios de campo durante t_2 al determinar si un árbol estaba muerto o vivo. Los dos factores y la interacción genotipo x repoblación se utilizaron como efectos aleatorios junto a la edad de rotación de los árboles. Las variables a nivel de árbol, como el diámetro a la altura de pecho (DAP) o el volumen del árbol, o a nivel de rodal, como la densidad en t_1 , el área basal y el volumen del rodal, se probaron como variables predictoras en el componente fijo de los modelos (*Tab. 1*). Los modelos se ajustaron usando el software estadístico R y el paquete "lme4" (Bates *et al.*, 2015).

Tabla 1. Conjunto de modelos de efectos aleatorios y mixtos utilizados para evaluar la mortalidad de los árboles.

Modelo	Definición	Síntesis	Fórmula
1	Intercepción aleatoria con media fija	(1 g)	$M = (1 \text{ Genotipo})$
2			$M = (1 \text{ Stocking})$
3			$M = (1 \text{ Age})$
4	Interceptación variable entre g^1 y g^2 dentro de g^1	(1 g^1 / g^2)	$M = (1 \text{ Genotipo} / \text{Stocking})$
5			$M = (1 \text{ Genotipo} / \text{Age})$
6	Intercepción que varía entre g^1 y g^2 dentro de la variable fija	$x + (1 g^1 / g^2)$	$M = DBH + g + v + DG + (1 \text{ Stocking} / \text{Age})$

* M es un valor binario que expresa la probabilidad de que un individuo esté vivo o muerto; DAP es el diámetro a la altura del pecho (1,30 m sobre el nivel del suelo); g es el área basal de cada árbol (m^2); v es el volumen individual (m^3); DG es el diámetro medio cuadrático; Genotipo son los cuatro genotipos diferentes probados, Stocking es la clase de densidad de plantación actual en 2019; Age es la edad del rodal (años).

3.4 Estudios fotogramétricos con vehículos aéreos no tripulados

Se utilizó un UAV estándar DJI Mavic. Recorriendo un total de 6.392 imágenes en 2020, entre el 10 y el 22 de diciembre, que se utilizarán para crear una nube de puntos de malla 3D a partir de la cual generar un Modelo Digital de Superficie (MDS), que permite la ortorectificación del mosaico (Fig. 5).

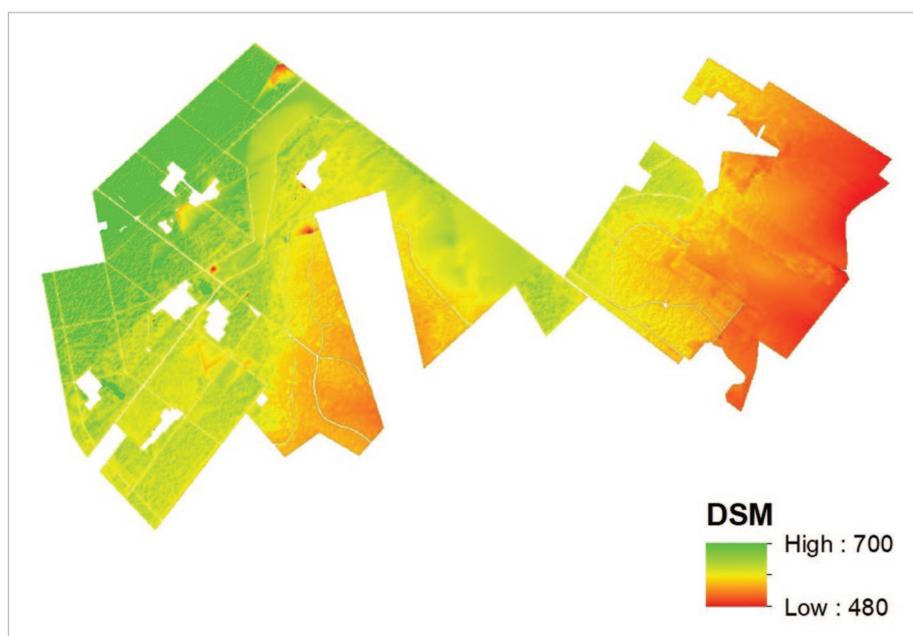


Figura 5. Mosaico de imágenes de la zona de estudio B) Zona ampliada con una resolución de 7 cm/píxel C) Ampliación del mosaico a 1 m/píxel.

Las imágenes en mosaico se utilizaron además para crear áreas segmentadas homogéneas donde predecir la probabilidad de mortalidad utilizando la relación estadística derivada de las áreas de entrenamiento (parcelas). La segmentación de las imágenes se realizó mediante el software Orfeo-toolbox (Grizonnet *et al.*, 2017) y el algoritmo *Mean-Shift* (MSS) fue utilizado para segmentación, que combina dos parámetros en la búsqueda (Y. Wang *et al.*, 2006): El radio espacial debe estar cerca del tamaño de los objetivos (Chehata *et al.*, 2014): el radio de la parcela de 18 m aquí.

Los objetos segmentados (polígonos) y las coordenadas de las parcelas de muestreo —considerando un *buffer* de 18 m— se utilizaron para calcular los estadísticos predictores candidatos a partir de las imágenes mosaico RGB a 1 m de resolución, los índices ecológicos derivados de las imágenes a la misma resolución (*Tab. 2*) y el MDS creado (*Tab. 3*). El valor medio de los índices basados en imágenes (*Fig. 6*) y las estadísticas basadas en el MDS (*Fig. 7*) se calcularon considerando el radio de 18 m para el caso de las parcelas de muestra y toda la extensión para cada objeto segmentado.

Tabla 2. Conjunto de índices ecológicos calculados a partir de mosaicos de imágenes y del Modelo Digital de Superficie

Índices de vegetación	Parámetros	Fórmula	Referencia
Visible-band difference vegetation	VDVI	$\frac{(2G - R - B)}{(2G + R + B)}$	(X. Wang <i>et al.</i> , 2015)
Visible Atmospherically Resistant	VARI	$\frac{(G - R)}{(G + R - B)}$	(Rouse <i>et al.</i> , 1973)
New Green-Red Vegetation	NGRDI	$\frac{(G - R)}{(G + R)}$	(Zhang <i>et al.</i> , 2019)
Red-Green Ratio	RGRI	$\frac{R}{G}$	(Verrelst <i>et al.</i> , 2008)
Excess Green	ExG	$2G - R - B$	(Mao <i>et al.</i> , 2003)
Color Index of Vegetation	CIVE	$0.441R - 0.811G + 0.385B + 18.78745$	(Kataoka and Okamoto, 2003)
Vegetative	VEG	$\frac{G}{(R^a B^{(1-a)})}$	(Wheeler, 2006)
Red-edge ratio Normalized Vegetation	RERNDVI	$\frac{(B - R)}{(B + G)}$	(Buschmann and Nagel, 1993)
Red Edge Green Normalized Vegetation	REGNDVI	$\frac{(B - G)}{(R + G)}$	(Barnes <i>et al.</i> , 2000)
Red-edge ratio Normalized Vegetation	RERNDVI	$\frac{(B - R)}{(B + G)}$	(Buschmann and Nagel, 1993)
Texture	GLCMmean (Window size of 3 x 3 pixels and a 45-degree shift)	“mean”, “variance”, “homogeneity”, “contrast”, “dissimilarity”, “entropy”, “Second moment”, “correlation”	

Tabla 3. Conjunto de indicadores de banda de imagen calculados a partir de la inferencia y del Modelo Digital de Superficie

Clase	Variable	Fórmula	Referencia
Pendiente	$SLOPE_{sd}$	Pendiente	(Horn, 1981)
Índice de posición topográfica	TPI_{mean} TPI_{sd}	$TPI = y - \sum_{i=1}^8 \frac{y_i}{8}$, con y es la altitud de una celda e y_i es la altitud de la i -ésima celda adyacente.	(Wilson <i>et al.</i> , 2007)
Índice de rugosidad del terreno	TRI_{mean} TRI_{sd}	$TRI = \sum_{i=1}^8 \frac{ y_i - y }{8}$, con y es la altitud de una celda e y_i es la altitud de la i -ésima celda adyacente	
Rugosidad Textura	$ROUGHNESS_{mean}$ $ROUGHNESS_{sd}$ $GLCM_{mean}$ (Window size of 3x3 pixels and a 45-degree shift)	La rugosidad es la diferencia entre el valor máximo y el mínimo de una celda y sus 8 celdas circundantes "media", "varianza", "homogeneidad", "contraste", "disimilitud", "entropía", "segundo momento", "correlación"	

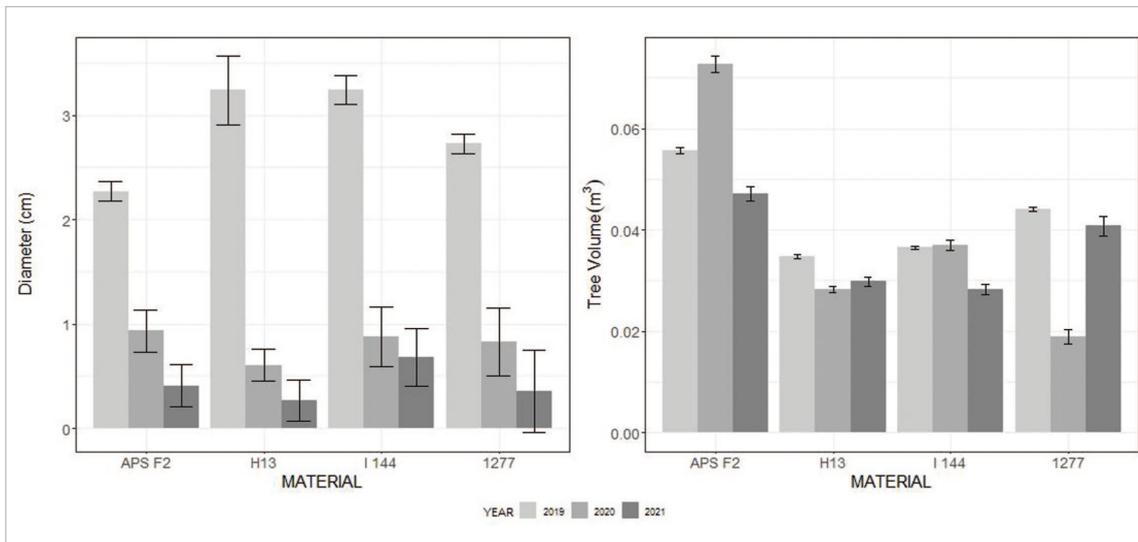


Figura 6. Representación de punta-a-punta de los diferentes índices de vegetación para toda el área de entrenamiento utilizando las imágenes de mosaico de 1 m: A) Vegetative (VEG). B) New Green-Red Vegetación (NGRVI). C) Visible Atmospherically Resistant (VARI), y D) Excess Green (ExG).

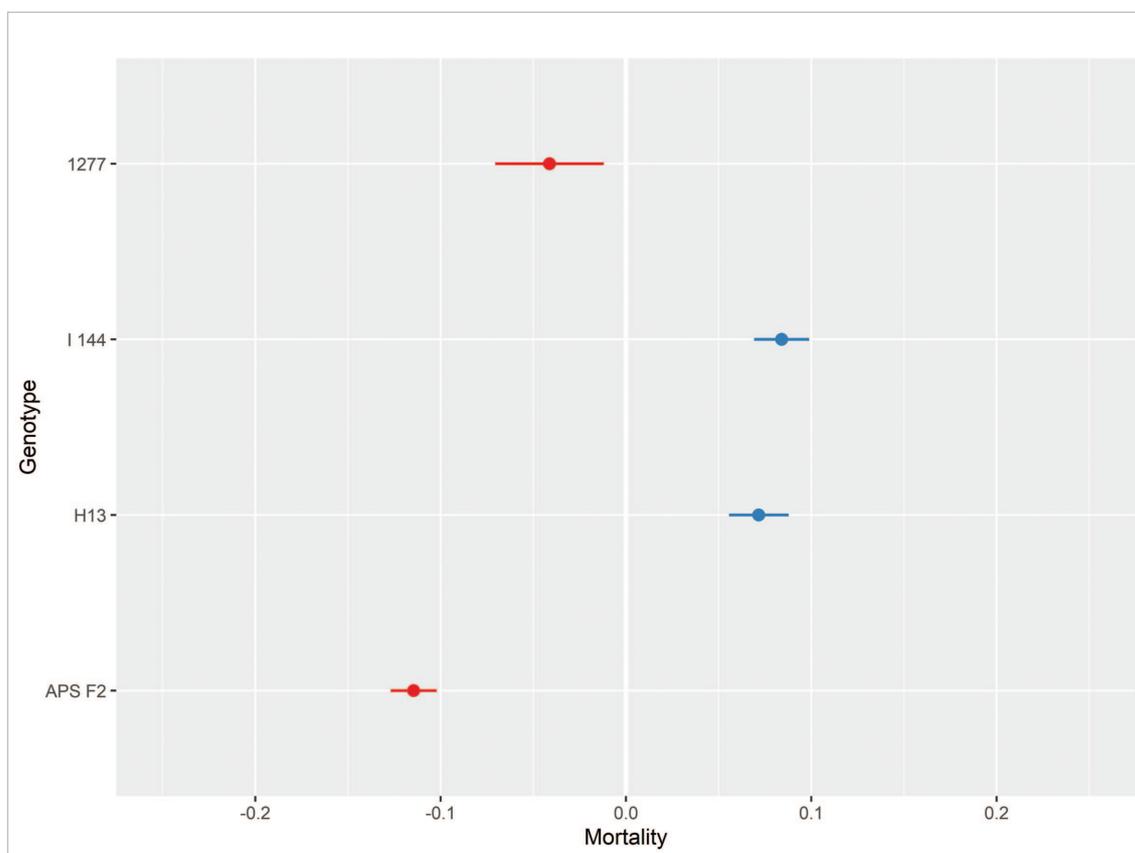


Figura 7. Mosaico de imágenes de la zona de estudio del Modelo Digital de Superficie (MDS) obtenido mediante imágenes estereoscópicas de UAV, con un límite superior de altura de 700 metros y un límite inferior de 480 metros.

La mortalidad como variable de respuesta se convirtió en un vector de dos clases: las parcelas del estudio del terreno se clasificaron como "Vivas" - volumen de árboles muertos menor o igual al 5% del volumen total de la parcela - o como "Muertas" para las parcelas con un volumen de árboles muertos superior al 5%. Se trabajó con el algoritmo de árboles de clasificación *Random Forest* —implementado en el paquete *SegOptim* (Gonçalves *et al.*, 2019) en el software estadístico R— para entrenar un modelo.

4. Resultados

4.1 Dinámica de crecimiento de los atributos biofísicos de los árboles

El incremento medio anual del DAP en el año 2019 fue de 2,87 cm de media. El incremento periódico del DAP de t_1 a t_2 disminuyó a 0,82 cm y bajó a 0,51 cm de t_2 a t_3 . Antes de la sequía, *E. urophylla* x *E. grandis* (H13) produjo el máximo incremento de DAP (3,24 cm) mientras que *E. urograndis* (APS F2) mostró el límite in-

ferior. Los valores disminuyeron a 0,61 y 0,93 después de la sequía. y para t_3 H13 tuvo la tasa de crecimiento más baja entre los materiales genéticos con 0,89 cm, mientras que I 144 tuvo un crecimiento ligeramente mejor que los demás (*Fig. 8*). La reducción del crecimiento fue más pronunciada en los valores de la media por encima de 700 árboles por ha, y los clones se comportaron de forma diferente.

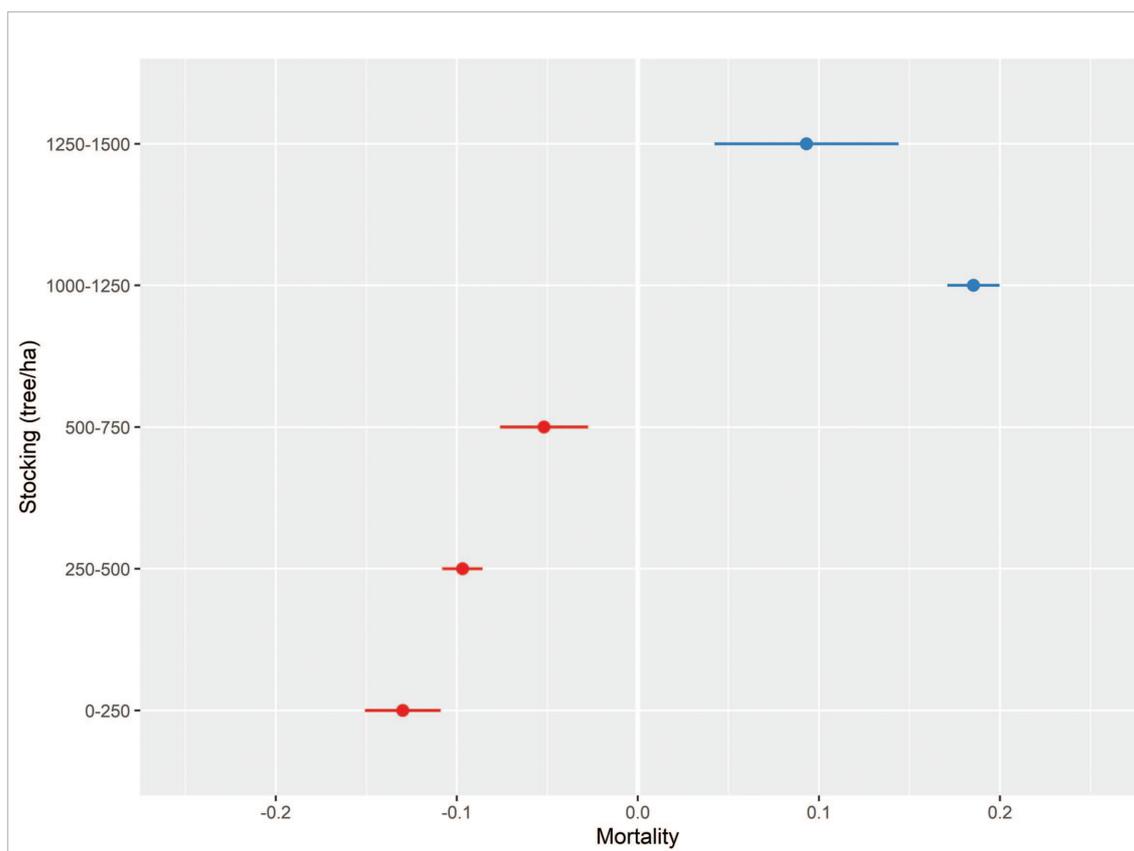


Figura 8. Crecimiento medio anual en diámetro, expresado en cm (izquierda). Incremento del volumen individual de los árboles, expresado en m^3 por árbol (derecha). Las barras representan los valores medios y el rango el error estándar en mm (izquierda) y m^3 (derecha).

4.2 Evaluación de la mortalidad de los árboles mediante efectos mixtos

Los árboles muertos representaron el 2% del total de individuos encuestados en 2019. En los dos años siguientes el valor aumentó hasta el 18% y el 22%, siendo *E. urophylla* x *E. grandis* (H13) el genotipo que presentó la mayor mortalidad, mientras que *E. urograndis* (APS F2) fue el clon más resistente. Los rodales con mayores densidades registraron mortalidades relativas más altas, entre el 53% y el 73% para densidades entre 1.000-1.500 árboles ha^{-1} . Los coeficientes del modelo LME permitieron la trazabilidad de los efectos anidados al evaluar la influencia de los genotipos, las poblaciones, la edad y sus interacciones (*Fig. 9*). Los efectos para los

modelos #1, #2 y #3 mostraron un alto nivel de mortalidad para los genotipos I144 (0,084) y H13 (0,072). El modelo #3 mostró que los árboles de entre 2 y 5 años fueron los que más sufrieron la sequía. Los clones H13 e I144 tuvieron la mayor mortalidad en rodales más densos y la menor mortalidad en densidades más bajas (Modelo #4).

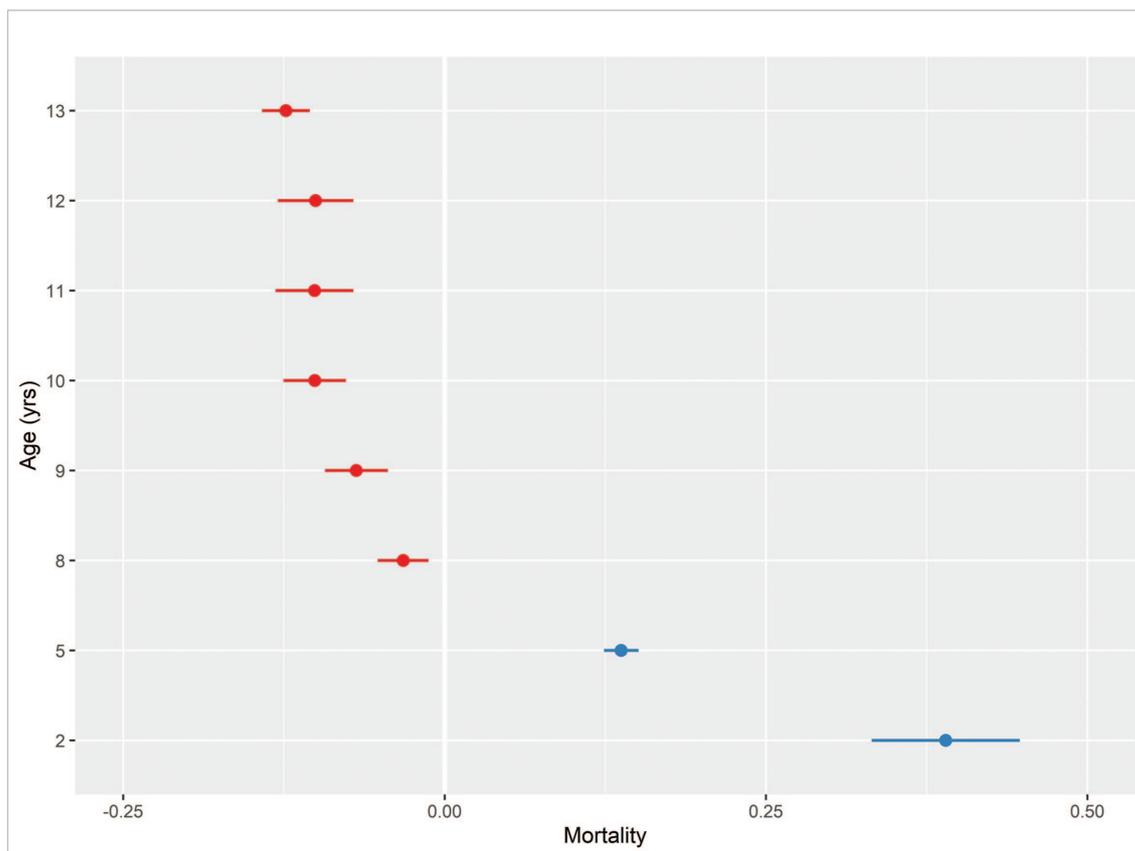


Figura 9. Coeficientes de los modelos de efectos mixtos lineales probados. De izquierda a derecha, se presentan los resultados de los modelos 1 a 3. Los valores representan la diferencia entre la estimación global del modelo y el nivel de efecto aleatorio específico, azul para los valores por encima del global y rojo por debajo.

4.3 Precisión de la clasificación mediante datos de teledetección

El resultado global obtenido en la clasificación basada en RF de los objetos segmentados tuvo una precisión global (OA) del 89% (Tab. 4). Los coeficientes kappa de Cohen calculados mostraron una concordancia sustancial y altas precisiones para ambas clases, especialmente para clasificar parcelas con condiciones de vida, por encima del 90% de precisión.

Los resultados sobre la importancia de las variables al utilizar el umbral del 5% en el volumen para filtrar los segmentos vivos y muertos mostraron que las 4 variables más importantes y 6 de las 10 más importantes pertenecían a variables basadas

Tabla 4. Precisión de la clasificación de imágenes por grupo en dos clases (vivo y muerto), PA = precisión del productor, UA = precisión del usuario, valor mostrado en negrita = precisión global. Las frecuencias de clasificación y de referencia (comprobación de campo) están dispuestas en filas y columnas.

	Predicción del estado de viva/muerta sobre objetos segmentados				
	Estado de salud	Viva	Muerta	Σ	PA
Observada	Viva	3.634	281	3.915	0,93
	Muerta	277	715	992	0,72
	Σ	3.911	996	4.349	
	UA	0,93	0,72		0,89
Cohen's kappa = 0,70					

en el MDS. Entre los índices generados a partir de la composición del color natural, sólo REGNDVI_{mean} y RERNDVI_{mean} se encuentran entre los 10 más importantes. El índice NGRVI también presenta dos variables entre las más importantes (NGRVI_{mean} y NGRVI_{sd}). El mapa de supervivencia/mortalidad para el área de estudio se mostró y superpuso sobre el mosaico de color natural (*Fig. 10*). Los mapas permitieron identificar las zonas más críticas para apoyar la decisión de gestión y tener una estimación del área total afectada por la mortalidad. Considerando el número total y la superficie de los segmentos clasificados, 922,70 ha fueron clasificadas como "Vivas" y 394,38 ha fueron clasificadas como "Muertas". La superficie prevista afectada por la mortalidad representa el 29,9% del área de estudio.

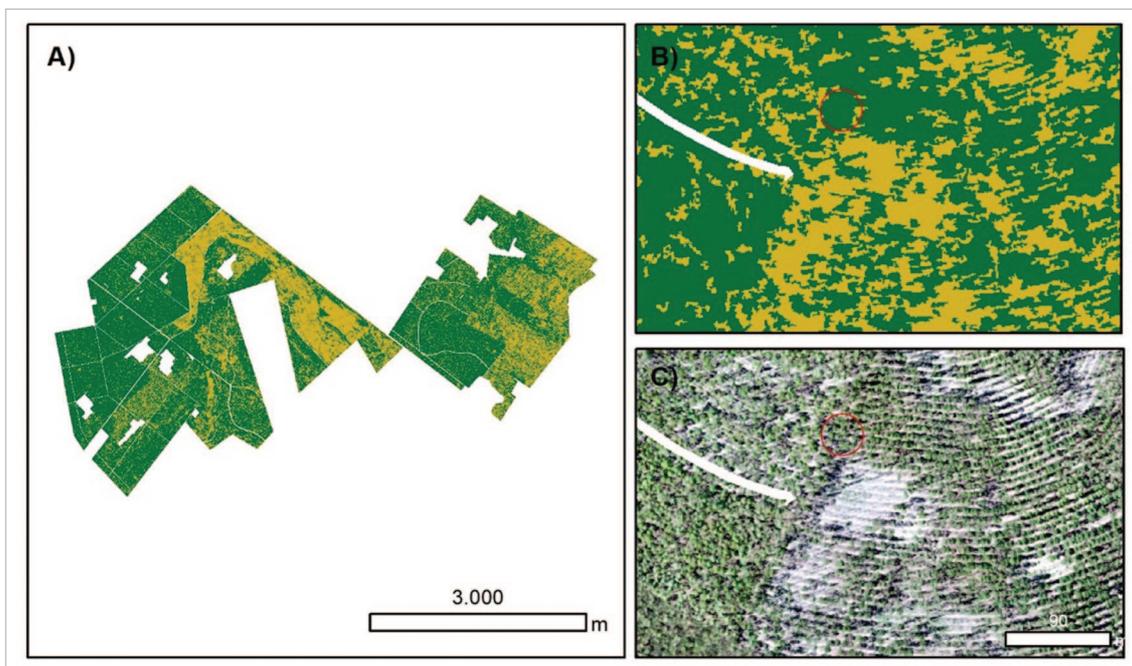


Figura 10. Clasificación de la zona de estudio mediante Random Forest (A) vivo en color verde / muerto en amarillo); (B) zona ampliada con alta mortalidad para resaltar la clasificación, (c) sobre el mosaico de color natural.

5. Discusión

La investigación confirmó el grave impacto de la sequía de 2019 en el área de estudio. La densidad de plantación y la interacción de esta con el factor genotipo explicaron el impacto del episodio de sequía de 2019 en la zona de Tangará da Serra en Brasil. La evaluación a nivel de parcela utilizando datos terrestres bajo un modelo de efectos mixtos se apoyó con una clasificación basada en la teledetección utilizando imágenes de UAV para estimar la probabilidad de mortalidad y finalmente su predicción en alta resolución. La investigación reúne el diseño del estudio con UAV, el procesamiento de los datos de las imágenes, técnicas de segmentación, dos enfoques de modelización diferentes (regresión y clasificación) y mapeo final para informar ser usado en toma de decisiones.

Las interacciones entre la densidad de población y la selección de clones mostraron que los clones *E. urophylla* (I 144) y *E. urophylla* x *E. grandis* (H13) son más susceptibles a la muerte en condiciones de alta densidad, aunque mostraron mortalidades más bajas en áreas menos pobladas. Las tasas de crecimiento anual del DAP disminuyeron de más de 3 cm antes de la sequía a 0,55 cm, en promedio, en el estudio de 2020, a medida que la población de árboles aumenta de menos de 250 árboles ha⁻¹ a más de 1.250, respectivamente. Sin embargo, las densidades de 250-500 árboles ha⁻¹ presentaron la menor mortalidad.

La fotogrametría basada en estudios con UAV se ha aplicado con éxito para obtener características 3D en estudios anteriores (Guerra-Hernández *et al.*, 2018; Leblanc, 2018; Tomastík *et al.*, 2019). Los valores kappa de Cohen mostraron una concordancia sustancial en sus resultados: OA de 0,89 y 0,70 en el índice kappa de Cohen.

Nuestros resultados mostraron que los índices procedentes del RGB y las variables texturales y estructurales derivadas del MDS serían suficientes para detectar la mortalidad a nivel de paisaje y para estimar con suficiencia la tasa de afección por sequía en áreas forestales continuas.

6. Conclusiones

La adaptación de los parámetros silvícolas en las plantaciones forestales de eucalipto es un enfoque imprescindible para aumentar la resiliencia de los activos forestales bajo la creciente amenaza de la incertidumbre climática y la intensificación de la sequía. El estudio proporciona una evaluación de la sequía de 2019 utilizando estudios multitemporales sobre el terreno y una metodología de valoración detallada apoyada en la fotogrametría. Nuestros resultados abogan por una acción de gestión inmediata sobre la densidad de población y las estrategias de selección de clones en Brasil, donde el papel de la silvicultura comercial desempeña un papel importante en la cadena de suministro de materias primas global y la presión sobre los ecosistemas forestales nativos.

7. Bibliografía

- Barnes, E.M.; Clarke, T.R.; Richards, S.E.; Colaizzi, P.D.; Haberland, J.; Kostrzewski, M.; Waller, P.; Choi C., R.E.; Thompson, T.; Lascano, R.J.; Li, H.; Moran, M.S.; 2000. Coincident detection of crop water stress, nitrogen status and canopy density using ground based multispectral data. Proc. 5th Int. Conf. Precis Agric, July 2015.
- Bates, D.; Mächler, M.; Bolker, B.M.; Walker, S.C.; 2015. Fitting linear mixed-effects models using lme4. *Journal of Statistical Software*, 67(1). <https://doi.org/10.18637/jss.v067.i01>
- Baty, F.; Ritz, C.; Charles, S.; Brutsche, M.; Flandrois, J.P.; Delignette-Muller, M.L.; 2015. A toolbox for nonlinear regression in R: The package nlstools. *Journal of Statistical Software*, 66(5), 1–21. <https://doi.org/10.18637/jss.v066.i05>
- Booth, T.H.; 2013. Eucalypt plantations and climate change. *Forest Ecology and Management*, 301, 28–34. <https://doi.org/10.1016/j.foreco.2012.04.004>
- Brook, B.W.; Sodhi, N.S.; Bradshaw, C.J.A.; 2008. Synergies among extinction drivers under global change. *Trends in Ecology and Evolution*, 23(8), 453–460. <https://doi.org/10.1016/j.tree.2008.03.011>
- Buschmann, C.; Nagel, E.; 1993. In vivo spectroscopy and internal optics of leaves as basis for remote sensing of vegetation. *International Journal of Remote Sensing*, 14(4), 711–722. <https://doi.org/10.1080/01431169308904370>
- Chehata, N.; Orny, C.; Boukir, S.; Guyon, D.; Wigneron, J.P.; 2014. Object-based change detection in wind storm-damaged forest using high-resolution multispectral images. *International Journal of Remote Sensing*, 35(13), 4758–4777. <https://doi.org/10.1080/01431161.2014.930199>
- dos Reis, G.G.; Reis, M.D.G.F.; Fontan, I.D.C.I.; Monte, M.A.; Gomes, A.N.; de Oliveira, C.H.R.; 2006. Crescimento de raízes e da parte aérea de clones de híbridos de *Eucalyptus grandis* x *Eucalyptus urophylla* e de *Eucalyptus camaldulensis* x *Eucalyptus* spp submetidos a dois regimes de irrigação no campo. *Revista Arvore*, 30(6), 921–931. <https://doi.org/10.1590/S0100-67622006000600007>
- Foley, J.A.; DeFries, R.; Asner, G.P.; Barford, C.; Bonan, G.; Carpenter, S.R.; Chapin, F.S.; Coe, M.T.; Daily, G.C.; Gibbs, H.K.; Helkowski, J.H.; Holloway, T.; Howard, E.A.; Kucharik, C.J.; Monfreda, C.; Patz, J.A.; Prentice, I.C.; Ramankutty, N.; Snyder, P.K.; 2005. Global consequences of land use. *Science*, 309(5734), 570–574. <https://doi.org/10.1126/science.1111772>
- Gonçalves, J.; Pôças, I.; Marcos, B.; Múcher, C.A.; Honrado, J.P.; 2019. SegOptim—A new R package for optimizing object-based image analyses of high-spatial resolution remotely-sensed data. *International Journal of Applied Earth Observation and Geoinformation*, 76(December 2018), 218–230. <https://doi.org/10.1016/j.jag.2018.11.011>
- Grizonnet, M.; Michel, J.; Poughon, V.; Inglada, J.; Savinaud, M.; Cresson, R.; 2017. Orfeo ToolBox: open source processing of remote sensing images. *Open Geospatial Data, Software and Standards*, 2(1), 15. <https://doi.org/10.1186/s40965-017-0031-6>
- Guerra-Hernández, J.; Cosenza, D.N.; Rodriguez, L.C.E.; Silva, M.; Tomé, M.; Díaz-Varela, R.A.; González-Ferreiro, E.; 2018. Comparison of ALS- and UAV(SfM)-derived high-density point clouds for individual tree detection in Eucalyptus plantations. *International Journal of Remote Sensing*, 39(15–16), 5211–5235. <https://doi.org/10.1080/01431161.2018.1486519>
- Guerra-Hernández, J.; González-Ferreiro, E.; Monleón, V.J.; Faias, S.P.; Tomé, M.; Díaz-Varela, R.A.; 2017. Use of multi-temporal UAV-derived imagery for estimating individual tree

- growth in *Pinus pinea* stands. *Forests*, 8(8), 1–19. <https://doi.org/10.3390/f8080300>
- Horn, B.K.P.; 1981. Hill Shading and the Reflectance Map. *Proceedings of the IEEE*, 69(1), 14–47. <https://doi.org/10.1109/PROC.1981.11918>
- Kataoka, T.; Okamoto, H.; 2003. Crop Growth Estimation System Using Machine Vision. *Aim*, 1079–1083.
- Kirilenko, A.P.; Sedjo, R.A.; 2007. Climate change impacts on forestry. *Proceedings of the National Academy of Sciences of the United States of America*, 104(50), 19697–19702. <https://doi.org/10.1073/pnas.0701424104>
- Laclau, J.P.; Gonçalves, J.L. de M.; Stape, J.L.; 2013. Perspectives for the management of eucalypt plantations under biotic and abiotic stresses. *Forest Ecology and Management*, 301(November 2011), 1–5. <https://doi.org/10.1016/j.foreco.2013.03.007>
- Leblanc, S.; 2018. Off-the-Shelf Unmanned Aerial Vehicles for 3D Vegetation Mapping. March.
- Mao, W., Student, P. D., Wang, Y., & Wang, Y. 2003. Real-time Detection of Between-row Weeds Using Machine Vision. 0300(03).
- Miranda, D.L.C.; Lisboa, G.D.S.; Silva, F. da; Sanquetta, C.R.; Corte, A.P.D.; Condé, T.M.; 2019. Crescimento de híbridos de eucalipto no estado de Mato Grosso. *Advances in Forestry Science*, 6(2). <https://doi.org/10.34062/afs.v6i2.7360>
- Pena, R.F. 2018. Análise Silvicultural de Clones de Eucalipto e Características Productivas do Pasto em Sistema Silvipastoril, em Coronel Pacheco, M.G.
- Phillips, O.L.; Aragão, L.E.O.C.; Lewis, S.L.; Fisher, J.B.; Lloyd, J.; López-González, G.; Malhi, Y.; Monteagudo, A.; Peacock, J.; Quesada, C.A.; Van Der Heijden, G.; Almeida, S.; Amaral, I.; Arroyo, L.; Aymard, G.; Baker, T.R.; Bánki, O.; Blanc, L.; Bonal, D.; ... Torres-Lezama, A.; 2009. Drought sensitivity of the amazon rainforest. *Science*, 323(5919), 1344–1347. <https://doi.org/10.1126/science.1164033>
- R Core Team. 2020. R: A Language and Environment for Statistical Computing. {{ISBN} 3-900051-07-0}. <http://www.r-project.org/>
- Rouse, J.; Haas, R.H.; Schell, J.A.; Deering, D.; 1973. Monitoring vegetation systems in the great plains with ERTS.
- Tomastík, J.; Mokros, M.; Surovy, P.; Grznárová, A.; Merganic, J. 2019. UAV RTK/PPK method- An optimal solution for mapping inaccessible forested areas? *Remote Sensing*, 11(6). <https://doi.org/10.3390/RS11060721>
- Verrelst, J.; Schaepman, M.E.; Koetz, B.; Kneubühler, M.; 2008. Angular sensitivity analysis of vegetation indices derived from CHRIS / PROBA data. 112, 2341–2353. <https://doi.org/10.1016/j.rse.2007.11.001>
- Wang, X.; Wang, M.; Wang, S.; Wu, Y.; 2015. Extraction of vegetation information from visible unmanned aerial vehicle images. *Nongye Gongcheng Xuebao/Transactions of the Chinese Society of Agricultural Engineering*, 31, 152–159. <https://doi.org/10.3969/j.issn.1002-6819.2015.05.022>
- Wang, Y.; Soh, Y.S.; Schultz, H.; 2006. Individual Tree Crown Segmentation in Aerial Forestry Images by Mean Shift Clustering and Graph-based Cluster Merging. *International Journal of Computer Science and Network Security*, 6(11), 40–45.
- Wheeler, T.H.Æ.N.D.T.Æ.H. 2006. Automated crop and weed monitoring in widely spaced cereals. 21–32. <https://doi.org/10.1007/s11119-005-6787-1>
- Wilson, M.F.J.; O’Connell, B.; Brown, C.; Guinan, J.C.; Grehan, A.J.; 2007. Multiscale terrain analysis of multibeam bathymetry data for habitat mapping on the continental slope. In: *Marine Geodesy* (Vol. 30, Issues 1–2). <https://doi.org/10.1080/01490410701295962>

Zhang, X.; Zhang, F.; Qi, Y.; Deng, L.; Wang, X.; Yang, S.; 2019. New research methods for vegetation information extraction based on visible light remote sensing images from an unmanned aerial vehicle (UAV). *International Journal of Applied Earth Observation and Geoinformation*, 78(June 2019), 215–226. <https://doi.org/10.1016/j.jag.2019.01.001>

