



8º CONGRESO FORESTAL ESPAÑOL

La **Ciencia forestal** y su contribución a
los **Objetivos de Desarrollo Sostenible**



8CFE

Edita: Sociedad Española de Ciencias Forestales

Cataluña | Catalunya - 27 junio | juny - 1 julio | juliol 2022

ISBN 978-84-941695-6-4

© Sociedad Española de Ciencias Forestales

Organiza



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

TUPINAMBÁ-SIMÓES, F.^{1, 5}, BRAVO OVIEDO, F.^{1, 5}, GUERRA-HERNÁNDEZ, J.^{3, 4} y PASCUAL, A.^{2, 4}

¹ Universidad de Valladolid | UVa - Instituto Universitario de Investigación en Gestión Forestal Sostenible, Palencia, Spain.

² Centro para el Descubrimiento Global y la Ciencia de la Conservación, Universidad del Estado de Arizona, Hilo, EEAA.

³ 3edata, Centro de iniciativas empresariales, Fundación CEL. Lugo, Spain.

⁴ Centro de Investigación Forestal, Escuela de Agricultura, Universidad de Lisboa, Lisboa, Portugal.

⁵ Instituto de Investigación sobre Gestión Forestal Sostenible UVa-INIA, Palencia, Spain.

Resumen

La plantación de especies arbóreas de rápido crecimiento (*Eucalyptus spp.*) desempeña un papel crucial en el suministro de productos forestales a las economías en crecimiento, al tiempo que alivia la presión sobre los bosques autóctonos en relación con los cambios de uso del suelo y la sobreexplotación de los recursos forestales, en su mayoría ecosistemas nativos. La viabilidad de estos importantes ecosistemas se ve amenazada por la creciente frecuencia, gravedad y duración de las sequías. En Mato Grosso, Brasil, donde el estrés hídrico es el principal factor limitante del eucalipto, se registró en 2019 el segundo mayor episodio de sequía de toda la serie histórica. Los datos del inventario forestal que comprenden miles de mediciones de árboles tomados en los años 2019, 2020 y 2021, se han modelizado utilizando modelos de efectos mixtos para identificar los factores más significativos que influyen en la mortalidad y la dinámica de crecimiento de los cuatro diferentes genotipos de eucalipto (es decir, los clones comerciales) después de la grave sequía de 2019. Se utilizó un vehículo aéreo no tripulado (UAV de su nombre en inglés) para obtener un mosaico de imágenes en el espectro visible - rojo, verde y azul (RGB) - de muy alta resolución (VHR), además de modelos digitales de superficie (MDS) y cálculos del índice de vegetación (IV), que se utilizaron en la clasificación de la mortalidad utilizando segmentación enfocada a objetos. Se utilizaron técnicas de valoración para cuantificar los impactos financieros de la sequía en la producción, la rentabilidad y la dinámica forestal. Las tasas de crecimiento y las tasas de mortalidad se vieron muy afectadas durante la sequía; El efecto de la sequía de 2019 fue más pronunciado en los rodales con alta densidad de árboles. En promedio, la sequía de 2019 desencadenó unas pérdidas estimadas de \$3,5k ha⁻¹ debido al aumento de la mortalidad. La selección del material genético y la densidad de plantación pueden utilizarse como factores silvícolas para gestionar de una forma más eficiente las plantaciones forestales ante los efectos del cambio climático actual que incluyen los episodios extremos de estrés hídrico. Implicaciones: Este estudio ilustra la necesidad de ajustar las directrices silvícolas para reducir el impacto de la sequía en las plantaciones de eucalipto, la importancia de la ciencia de la propagación clonal 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 eucalipto y explorar los límites óptimos de productividad bajo el cambio global.

Palabras clave

Seguimiento forestal, dinámica de crecimiento, silvicultura de producción, productividad.

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 mejora de los rendimientos y la eficiencia en el uso de los recursos es especialmente relevante en Brasil, donde la conversión de los bosques nativos en silvicultura y agricultura comercial está teniendo un fuerte impacto en la biodiversidad de los biomas forestales que deben conservarse (BRADSHAW ET AL., 2010; LOARIE ET AL., 2009). 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. Según la NASA, las temperaturas globales de la superficie de la Tierra en 2019 fueron las segundas más cálidas desde 1880, los últimos cinco años han sido los más cálidos de los últimos 140 años (SCHMIDT & ARNDT, 2020). ¿En qué medida la supervivencia de los genotipos seleccionados en el marco de los programas de reproducción clonal (DE ARAUJO ET AL., 2019) se vio afectada por la sequía y cuál fue el papel de los umbrales de repoblación? La interacción genotipo × ambiente captado en los ensayos de reproducción podría haber sido diseñada bajo niveles de estrés más bajos en comparación con el evento extremo de 2019 (FERRAZ ET AL., 2013; VAN EEUWIJK ET AL., 2016). 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 reducción de las existencias de las plantaciones de eucaliptos podría hacer frente a una gestión orientada a la producción, aunque el aumento de las tasas de crecimiento en diseños de plantación menos dispersos podría compensarlo.

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 UAV capaces de obtener imágenes de las plantaciones a alta resolución (GUERRA-HERNÁNDEZ ET AL., 2017, 2018). La visión general de los efectos de la sequía se beneficia de la combinación de las mediciones de los árboles en campo a lo largo de las series de tiempo para capturar las condiciones ante y ex-post, y la tecnología de teledetección para diagnosticar los impactos de espacialmente continuo través de los paisajes (LAES ET AL., 2006; LEITE ET AL., 2020; TANG & SHAO, 2015; TEODORO & ARAUJO, 2016; TORRES-SÁNCHEZ ET AL., 2015). Sin embargo, hay retos de investigación por delante en cuanto a la eficacia de utilizar sólo imágenes de color natural, que consiste en las tres bandas estándar del espectro de color (Rojo, Verde y Azul - RGB), en los estudios que utilizan UAV para detectar el deterioro y la mortalidad de los árboles. El uso de índices ecológicos basados en las bandas RGB y las variables estructurales derivadas de los modelos digitales de superficie (MDS) como variables predictoras de la salud de los bosques requiere todavía de un importante ejercicio de validación para asegurar que las variables RGB son suficientes para detectar la mortalidad a nivel de rodal en zonas afectadas por la sequía, evitando la necesidad de adquirir costosos sensores hiperespectrales o multiespectrales de alta gama.

2. Objetivos

Específicamente, los objetivos en este estudio fueron (i) evaluar la mortalidad y la dinámica de crecimiento hacia los factores operativos del diseño de la plantación para informar mejor a los administradores sobre qué parámetros deben ser revisados en las rotaciones sucesivas, (ii) evaluar las implicaciones financieras de los resultados relacionados con el estrés de la sequía para una plantación a gran escala encuestada en 2019, 2020 y 2021, y (iii) crear mapas de salud forestal impulsados por la tecnología de imágenes UAV en combinación con encuestas en tierra para estimar el porcentaje de área afectada por la mortalidad debido a la sequía. Esta investigación apoyada por los actores privados de la región de Mato Grosso representa una evaluación oportuna y relevante - que reúne la medición tradicional de los bosques, la ciencia del crecimiento y el rendimiento y las soluciones de la ciencia de datos basadas en el creciente conocimiento de la teledetección- a partir

de la cual se puede parametrizar mejor el futuro de la importante masa forestal de eucaliptos en Brasil y en todo el mundo.

3. Metodología

3.1 Área de estudio

El estudio se realizó en el municipio de Tangará da Serra, Mato Grosso, Brasil (Figura 1). El clima es tropical con una estación seca prolongada durante el invierno. La precipitación durante la estación húmeda suele ser inferior a 1000 mm con temperaturas medias en todos los meses superiores a 18 °C. 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 pequeño incremento sobre la tendencia (Figura 2).

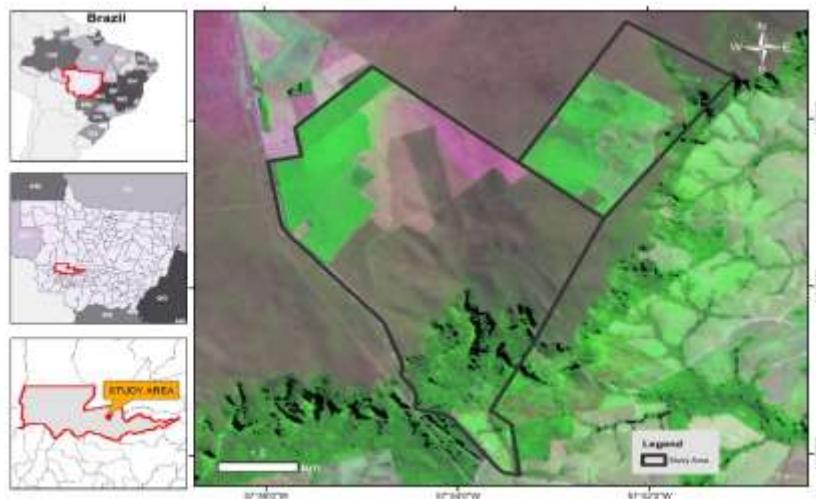


Figura 1. Área de estudio ubicada en Tangará da Serra, estado de Mato Grosso, en la región centro-oeste de Brasil. El mosaico de 4 bandas de LandSat 8 después de la sequía de 2019 (agosto de 2020) se presenta como fondo utilizando la representación de la vegetación en falso color (654 en el RGB).

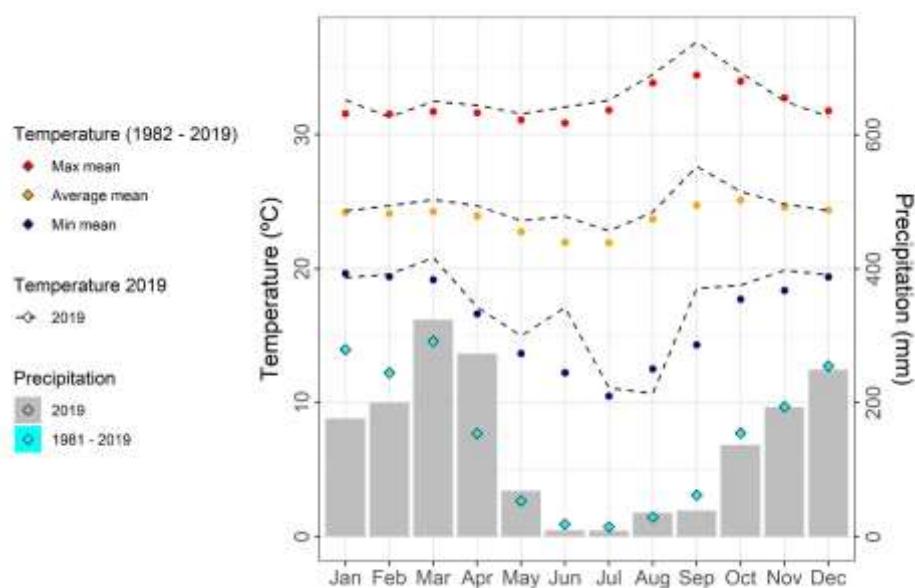


Figura 2. Climograma de Tangrá da Serra comparando la tendencia media 1982-2019, representada con puntos, con la temperatura media mensual del año 2019 (líneas) y la precipitación mensual del año (bars).

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). Los niveles de existencias se iniciaron con 1.136 árboles ha⁻¹ en 2006 antes de pasar al rango de 649 y 1.300 árboles ha⁻¹ para las operaciones de plantación después del año 2011 (Figura 3).

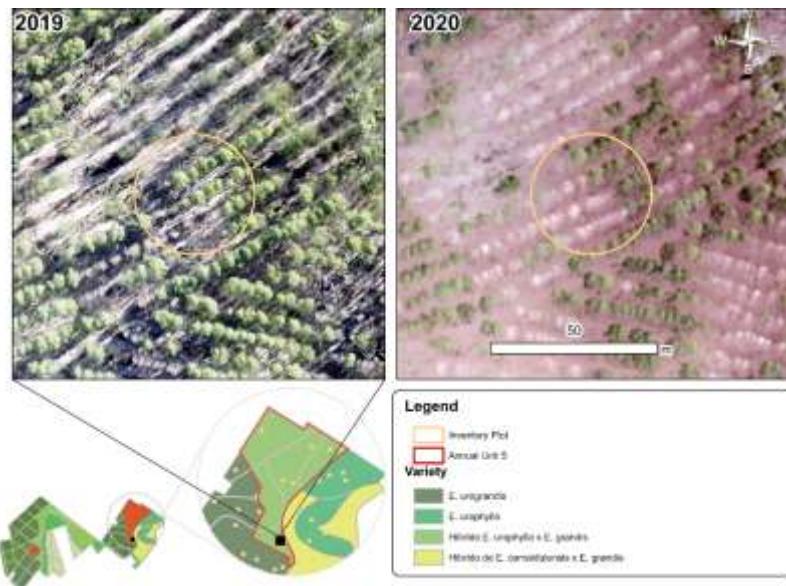


Figura 3. Visión general aérea de la zona de estudio mediante imágenes recogidas durante los muestreos con drones en 2019 y 2020 sobre el cuadro delimitador de la UPA nº 5 (cuadrado rojo) para ilustrar los efectos de la sequía de 2019 en la zona de entrenamiento. Se presenta la distribución espacial de los genotípos 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 confirmaron en abril de 2021 (t_3). El conjunto de 144 parcelas de inventario instaladas en t_1 y se volvió a visitar en t_2 y t_3 para supervisar el estado de la plantación y evaluar los daños. La distribución de las parcelas de muestreo de 18 m de radio se distribuyó aleatoriamente en los diferentes años de rotación. Se tomaron las alturas de los árboles dominantes, con un mínimo del 10% de los individuos de la parcela, las demás alturas se predijeron para completar los estudios (Tabla 1) utilizando modelos dependientes del diámetro a altura del pecho - DAP (Tabla 2). Los árboles fueron etiquetados y marcados en el campo para contabilizar adecuadamente el crecimiento y la mortalidad en t_2 y t_3 (Figura 4).



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.

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). El mejor ajuste se determinó en las distribuciones residuales más bajas, y las estimaciones de los parámetros utilizando un nivel de significación $p<0,05$ y sus errores estándar asociados. El mejor rendimiento en términos de error cuadrático medio (RMSE) apoyó la predicción de la altura de los árboles que carecían de la medición de la altura del suelo (Tabla 3).

Tabla 1. Tabla resumen de las mediciones a nivel de árbol y de rodal.

Variables	2019		2020		2021	
	Media	Rango	Media	Rango	Media	Rango
Edad (años)	8,0	1,2 - 12,3	9,2	2,3 - 13,4	10,1	3,2 - 14,3
Área basal ($m^2 ha^{-1}$)	13,5	6,0 - 22,5	14,3	6,0 - 23,8	14,3	4,2 - 23,9
DMC (cm)	21,1	11,5 - 30,4	21,9	9,7 - 31,5	23,1	11,7 - 32,0
DAP (cm)	18,1	3,15 - 42,9	23,1	2,9 - 44,9	20,2	2,9 - 45,4
Altura dominante (m)	27,9	12,9 - 36,9	27,9	12,9 - 36,9	31,5	14,8 - 42,3
Altura total del árbol (m)	23,2	2,72 - 34,9	9,2	2,1 - 35,2	24,7	0,9 - 39,0

Tabla 2. Tabla con las ecuaciones altura-diámetro utilizadas para determinar la altura de los árboles.

Modelo	Referencia	Modelos
1	HENRICHSEN	$h = \beta_0 + \beta_1 \ln(dbh) + \varepsilon$
2	PARABOLIC	$h = \beta_0 + \beta_1 dbh + \beta_2 dbh^2 + \varepsilon$
3	AZEVEDO ET AL. (1999)	$h = \beta_0 + \beta_1 dbh^2 + \varepsilon$
4	SOARES ET AL. (2006)	$h = \beta_0 + \beta_1 \left(\frac{1}{dbh^2} \right) + \varepsilon$
5	TROREY	$h = \beta_0 + \beta_1 \left(\frac{1}{dbh} \right) + \beta_2 \left(\frac{1}{dbh^2} \right) + \varepsilon$
6	HOSSFELD1 (1822)	$h = 1.3 + \frac{\beta_0 dbh^2}{(dbh + \beta_1)^2} + \varepsilon$
7	HOSSFELD2 (1822)	$h = 1.3 + \frac{dbh^{\beta_0}}{(\beta_1 + \beta_2 dbh^{\beta_0})} + \varepsilon$
8	WEIBULL	$h = 1.3 + \beta_0 [1 - e^{(-\beta_1 dbh^{\beta_2})}] + \varepsilon$
9	RICHARDS (1959), CHAPMAN (1961)	$h = 1.3 + \beta_0 [1 - \exp(-\beta_1 dbh)]^{\beta_2} + \varepsilon$
10	CAMPOS ET AL. (1984)	$h = \exp \left(\beta_0 - \left(\frac{\beta_1}{dbh} \right) + (\beta_2 H_0) + (\varepsilon) \right)$

* h: altura total del árbol; DAP: diámetro a la altura del pecho (1,30 m sobre el nivel del suelo); Ho: altura dominante; β0, β1, β2: parámetros del modelo; ε: errores: exp = función exponencial.

Tabla 3. Estadísticas de ajuste y valores de los parámetros para los modelos de altura de los árboles utilizando el diámetro a la altura del pecho (DAP) y la altura dominante como variables predictoras de la regresión. Los modelos están clasificados por su error cuadrático medio (RMSE). También se presenta el criterio de información de Akaike (AIC).

Modelo	RMSE (%)	AIC (10³)	β₀	β₁	β₂
Campos	8,31	39,87	3,02***	6,61***	0,02***
Trorey	10,06	43,40	41,6***	-355,91***	766,07***
Hossfeld2	10,0	43,41	2,24***	8,93***	0,03***
Champman Richards	10,11	43,47	31,27***	0,12***	2,49***
Weibull	10,15	43,55	30,83***	0,02***	1,52***
Hossfeld1	10,28	43,79	48,33***	8,31***	
Henricksen	10,31	43,84	-17,17***	14,19***	
Parabolico	10,31	43,85	-0,21	1,79***	-0,03***
Soares	11,12	45,23	31,28***	-2.011,89***	
Azevedo	12,43	47,27	19,2***	0,01***	

* p<0,05 nivel de significación; ** p<0,01 nivel de significación; *** p<0,005 nivel de significación.

3.3 Dinámica de crecimiento multitemporal y valoración

Se calcularon los incrementos anuales en el DAP y la altura medida de los árboles vivos y muertos en 2019 y para los árboles vivos en 2020 para tener en cuenta el crecimiento anual en tres períodos: i) fecha de plantación a 2019 (t_1); de t_1 a 2020 (t_2); y de t_2 a 2021 (t_3). Las posiciones de los árboles y las fechas de plantación y de los estudios se utilizaron para calcular los incrementos de

crecimiento anuales. Los árboles incluidos en los análisis estaban comprendidos en los años de rotación 2, 5 y entre el 8 y el 13 (ciclo final) y en seis densidades en 2019 que oscilaban entre 207 y 1.306 árboles ha⁻¹, valores que disminuyeron a partir de los valores iniciales de las densidades de la aplicación de las operaciones de raleo comercial y pre-comercial.

Para la evaluación del saldo seguimos un enfoque ascendente para valorar y elevar la valoración a toda la superficie de la plantación: i) se aplicó la distribución de los surtidos (cinco clases basadas en rangos de clases de diámetro) y su valor en pie (\$ por m³) a cada tallo para calcular el valor individual de los árboles en ambos inventarios, ii) se calcularon los valores medios por unidad de gestión y se resumieron por año, densidad de plantación y genotipos para contabilizar el volumen y el valor totales, y estimar el daño financiero del episodio de sequía para toda la plantación. Se utilizó un tipo de interés anual del 6,68% -que coincide con las estimaciones del Índice General de Precios para los años 2019-2021 (IGP-M) para descontar los valores en pie en t₂ y t₃ tanto para los árboles vivos como para los muertos. El coste financiero de la sequía de 2019 se evaluó en pérdidas económicas expresadas en dólares estadounidenses de 2019 (el 17 de marzo de 2021, el dólar estadounidense (\$) por el Real brasileño (R\$) cotiza a 5,69).

3.4 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 árboles de t₁ a t₂ utilizando las observaciones de t₃ para corregir los posibles errores de identificación de la mortalidad de los árboles en los estudios de campo durante t₂ al determinar si un árbol estaba muerto o vivo. Los dos factores y la interacción genotipo×repopulación se utilizaron como efectos aleatorios junto a la edad de rotación de los árboles. Las variables a nivel de árbol, como el DAP o el volumen del árbol, o a nivel de rodal, como la densidad en t₁, el área basal y el volumen del rodal, se probaron como variables predictoras en el componente fijo de los modelos (Tabla 4). Los modelos se construyeron y ajustaron con el software estadístico R utilizando el paquete "lme4" (BATES ET AL., 2015).

Tabla 4. Conjunto de modelos de efectos aleatorios y mixtos utilizados para evaluar la mortalidad de los árboles.

Modelo	Definición	Síntesis	Fórmula
1	Intercepción		$M = (1 Genotipo)$
2	aleatoria con media fija	(1 g)	$M = (1 Stocking)$
3			$M = (1 Age)$
4	Intercepción variable entre g1 y g2 dentro de g1.	(1 g1 / g2)	$M = (1 Genotipo / Stocking)$
5			$M = (1 Genotipo / Age)$
6	Intercepción que varía entre g1 y g2 dentro de la variable fija	x + (1 g1 / g2)	$M = DBH + g + v + DG$ + (1 Stocking / 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 (m²); v es el volumen individual (m³); 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).

3.5 Estudios fotogramétricos con vehículos aéreos no tripulados

La plataforma aérea para la adquisición de imágenes se integró utilizando un UAV estándar DJI Mavic Pro (SZ DJI TECHNOLOGY CO., LTD, Shenzhen, China). Se recogieron un total de 6.392 imágenes en 2020, entre el 10 y el 22 de diciembre. El área de estudio se dividió en 10 proyectos para llevar a cabo los reconocimientos aéreos - la rutina de trayectorias se diseñó y ejecutó con la aplicación Drone Deploy, con una superposición frontal del 80% y lateral del 75%, a una altura de 120 metros sobre el suelo. Las posiciones y los tiempos de adquisición de las imágenes se utilizaron entonces 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. La resolución de las imágenes del ortomosaico fue de 1 metro, mientras que el Modelo Digital de Superficie (MDS) se calculó con una resolución de 10 cm (Figura 5).

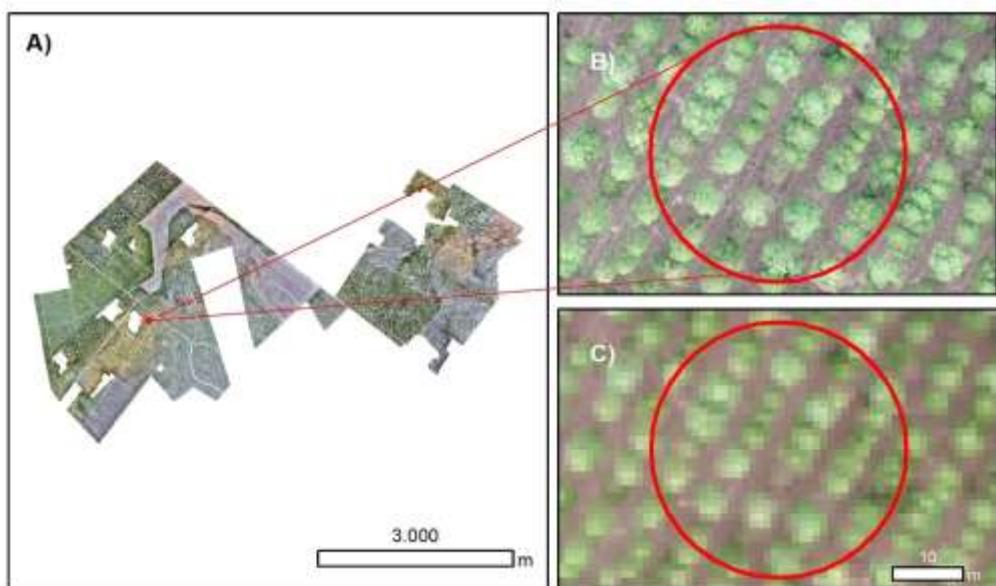


Figura 5. Mosaico de imágenes de la zona de estudio B) Zona ampliada con una resolución de 7 cm/píxel C) Ampliación del mosaico a 1 m/píxel.

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. Se creó un total de 269.386 polígonos de 49,67 m² de tamaño medio.

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 (Tabla 5) y el MDS creado (Tabla 6). El conjunto preliminar comprendía 48 estadísticas: 18 de las imágenes de 3 bandas, 15 índices de vegetación calculados sólo a partir de las imágenes y 15 métricas calculadas a partir del MDS. El valor medio de los índices basados en imágenes (Figura 6) y las estadísticas basadas en el MDS (Figura 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 5. 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 ET AL., 2015)
Visible Atmospherically Resistant	VARI	$\frac{(G - R)}{(G + R - B)}$	(ROUSE ET AL., 1973)
New Green-Red Vegetation	NGRDI	$\frac{(G - R)}{(G + R)}$	(ZHANG ET AL., 2019)
Red-Green Ratio	RGRI	$\frac{R}{G}$	(VERRELST ET AL., 2008)
Excess Green	ExG	$2G - R - B$	(MAO ET AL., 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	RERNDVI	$\frac{(B - R)}{(B + G)}$	(BUSCHMANN AND NAGEL, 1993)
Normalized Vegetation		$\frac{(B - G)}{(R + G)}$	
Red Edge Green	REGNDVI	$\frac{(B - R)}{(B + G)}$	(BARNES ET AL., 2000)
Normalized Vegetation		$\frac{(B - G)}{(R + G)}$	
Red-edge ratio	RERNDVI	$\frac{(B - R)}{(B + G)}$	(BUSCHMANN AND NAGEL, 1993)
Normalized Vegetation		$\frac{(B - G)}{(R + G)}$	
Texture	GLCM _{mean} (Window size of 3×3 pixels and a 45-degree shift)	"mean", "variance", "homogeneity", "contrast", "dissimilarity", "entropy", "Second moment", "correlation"	

Tabla 6. Conjunto de indicadores de banda de imagen calculados a partir de la inferencia y del Modelo Digital de Superficie.

Clase	Variable	Fórmula	Referencia
Slope	SLOPE _{sd}	Slope	(HORN, 1981)
Topographic Position Index	TPI _{mean} TPI _{sd}	$TPI = y - \sum_{i=1}^8 \frac{y_i}{8}$, with y is the altitude of a cell and y_i is the altitude of the i -th adjacent cell	(WILSON ET AL., 2007)
Terrain Ruggedness Index	TRI _{mean} TRI _{sd}	$TRI = \sum_{i=1}^8 \frac{ y_i - y }{8}$, with y is the altitude of a cell and y_i is the altitude of the i -th adjacent cell	
Roughness	ROUGHNESS _{mean} ROUGHNESS _{sd}	Roughness is the difference between the maximum and the minimum value of a cell and its 8 surrounding cells	
Texture	GLCM _{mean} (Window size of 3×3 pixels and a 45-degree shift)	"mean", "variance", "homogeneity", "contrast", "dissimilarity", "entropy", "second moment", "correlation"	

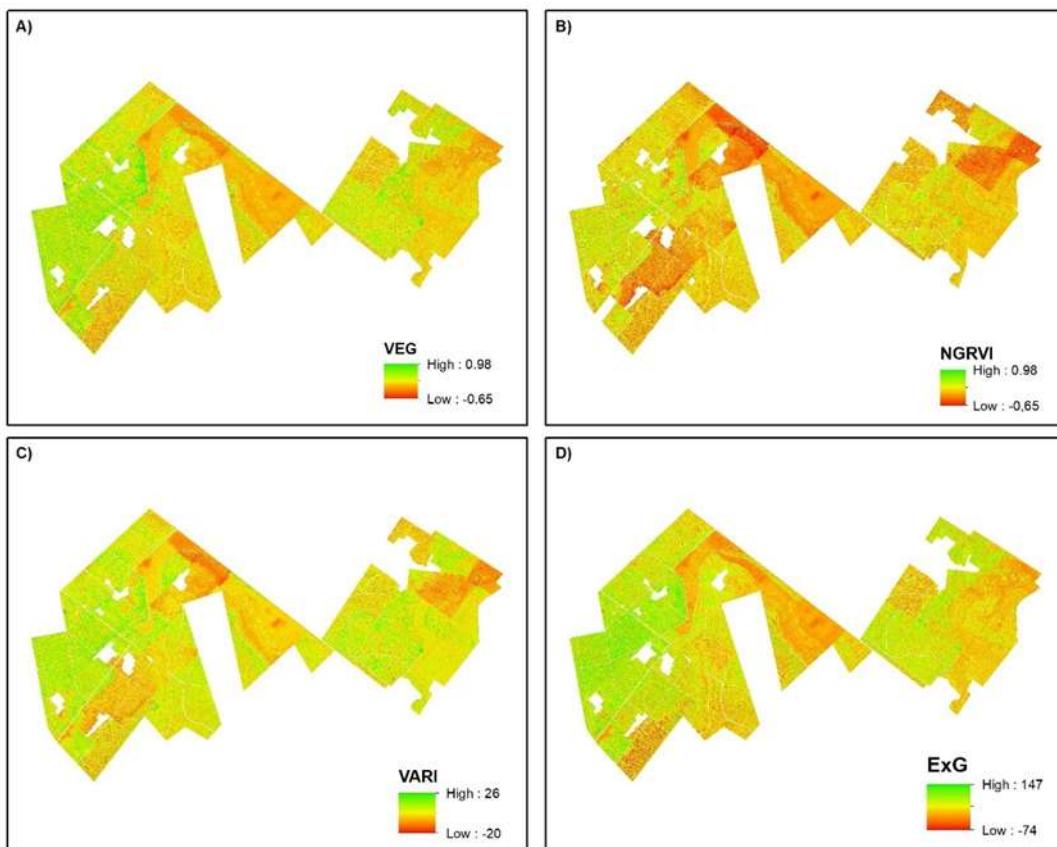


Figura 6. Representación de punta-a-punta de los diferentes índices de vegetación para toda el área de entrenamiento utilizando las imágenes de mosaico de 1 m: A) Vegetative (VEG). B) New Green-Red Vegetation (NGRVI). C) Visible Atmospherically Resistant (VARI), y D) Excess Green (ExG).

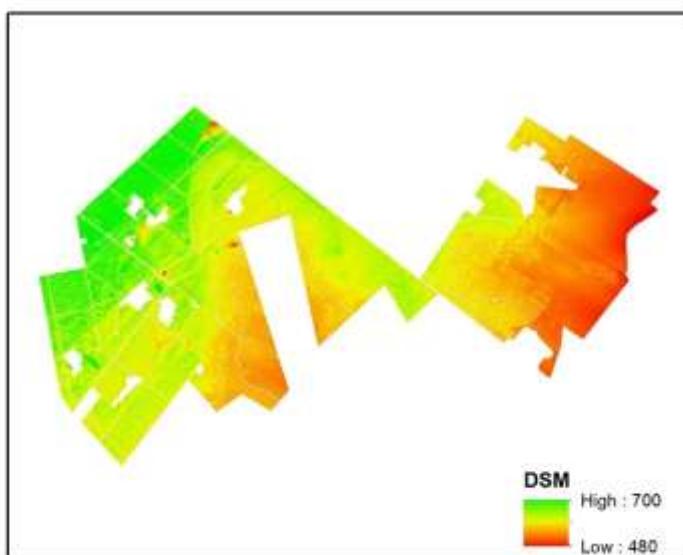


Figura 7. Mosaico de imágenes de la zona de estudio del Modelo Digital de Superficie (MDS) obtenido mediante imágenes estereoscópicas de UAV, con un límite superior de altura de 700 metros y un límite inferior de 480 metros.

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, el flujo de trabajo para la parte de teledetección se presenta en la Figura 8.

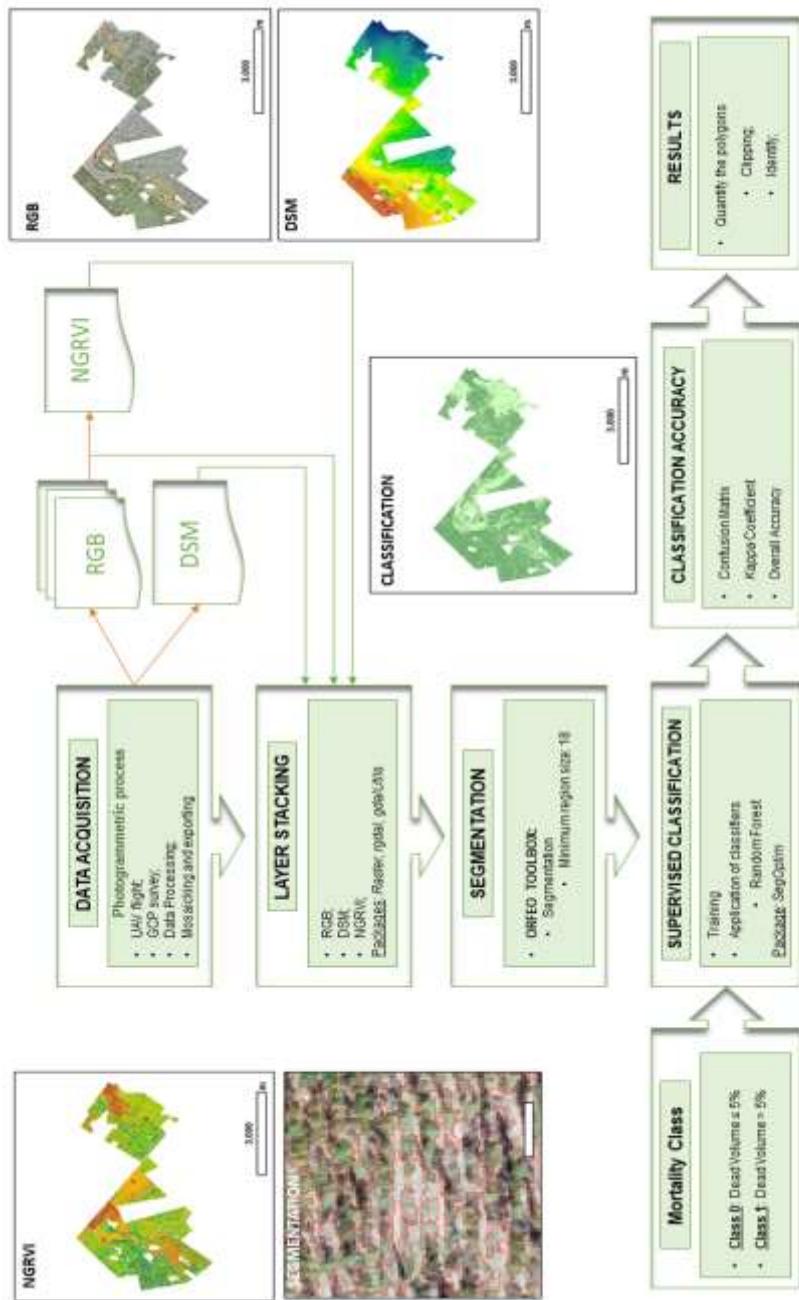


Figura 8. Diagrama de flujo de las tareas realizadas para integrar los datos de fotogrametría en la evaluación de la mortalidad de los árboles mediante la segmentación y la clasificación con Random Forests.

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 inferior. 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 (Figura 9). La interacción entre la población y el material clonal se exploró para la dinámica del DAP. 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. Por ejemplo, el I144 creció a 3,27 cm por año antes de la sequía bajo una media de 1.000-1.250 árboles. Después de la sequía los valores fueron inferiores a 0,65 cm por año. La misma tendencia para H13 que muestra rodales en condiciones de alta densidad; el crecimiento del DAP reducido a la mitad fue la tendencia general en condiciones de menor carga ganadera.

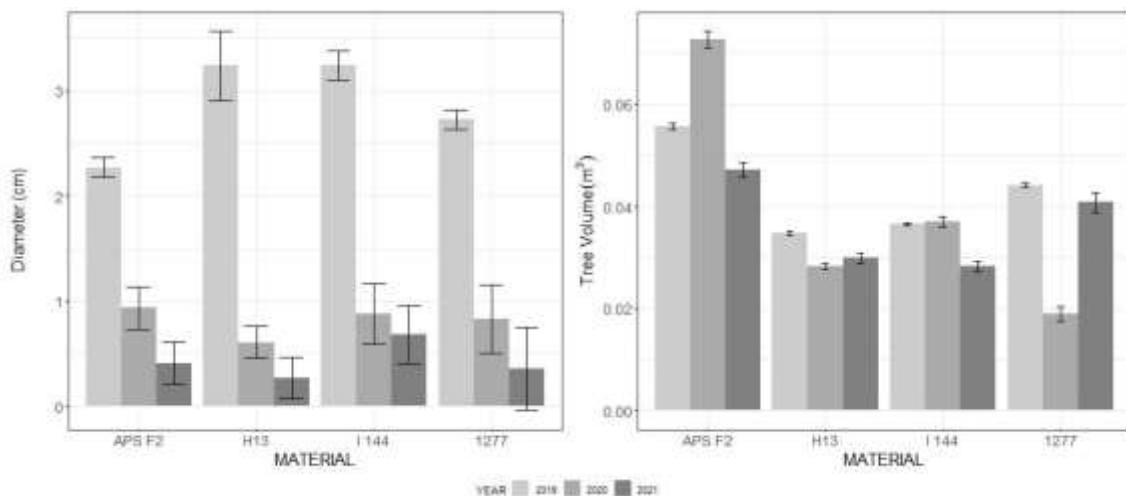


Figura 9. Crecimiento medio anual en diámetro, expresado en cm (izquierda). Incremento del volumen individual de los árboles, expresado en m^3 por árbol (derecha). Las barras representan los valores medios y el rango el error estándar en mm (izquierda) y m^3 (derecha).

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 (Figura 10). 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).

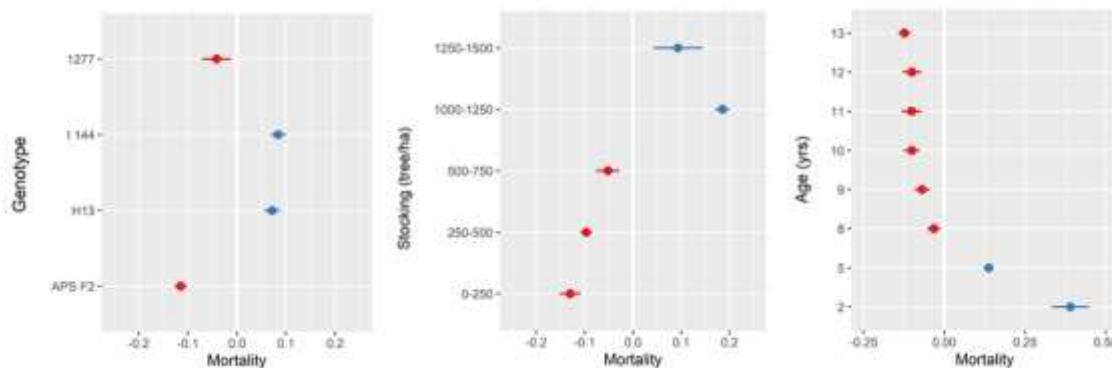


Figura 10. Coeficientes de los modelos de efectos mixtos lineales probados. De izquierda a derecha, se presentan los resultados de los modelos 1 a 3. Los valores representan la diferencia entre la estimación global del modelo y el nivel de efecto aleatorio específico, azul para los valores por encima del global y rojo por debajo.

4.3 Pérdidas económicas y resultados de la valoración

El coste financiero de la sequía de 2019 puede estimarse como la diferencia de volumen (Tabla 7) y valor (Tabla 8) entre los árboles vivos y los muertos. El volumen de árboles muertos se calculó a partir de los árboles que murieron entre los períodos t_1-t_2 y t_2-t_3 . Los cálculos se segmentaron por clase diamétrica según la comercialización de los productos. El volumen en pie de los árboles vivos aumentó alrededor de 11 mil m^3 en t_2 antes de llegar en 22 mil m^3 en la encuesta de 2021. El efecto acumulativo de la sequía sobre la producción se confirmó por la cantidad de volumen muerto, que representaba sólo 1,5 mil m^3 en t_1 pero casi 25 mil m^3 en t_3 . El valor de los árboles muertos en t_1 fue de 588 mil USD, más de 4 millones en t_2 , y se duplicó en t_3 alcanzando los 9,3 millones de USD. La clase de diámetro de 10-20 cm fue la más representativa en cuanto a pérdidas económicas, con 2,84 millones de dólares en t_2 y 6,3 millones de dólares en t_3 . Los valores de mortalidad se multiplicaron casi por 7 entre t_2 y t_1 , y por más de 15 entre t_3 y t_1 .

Tabla 7. Volumen de árboles vivos y muertos encuestados en los años 2019, 2020 y 2021. El volumen se calculó por surtido definido por el rango de diámetro a la altura del pecho.

Volumen (m^3)	2019		2020		2021		
	Clase	Vivo	Muerto	Vivo	Muerto	Vivo	Muerto
Residuo		182,47	5,23	99,82	39,49	68,01	25,31
04 - 10		14.776,41	325,20	9.481,55	2.306,61	5.781,28	2.267,22
10 - 20		100.103,80	1.067,70	90.302,41	7.310,79	65.473,08	16.193,38
20 - 30		67.914,45	183,64	83.165,39	1.415,04	75.510,01	6.412,96
> 30		17.083,53		25.237,82	208,75	27.615,18	541,78
Sub-Total		182.794,66	1.576,54	182.949,35	11.032,44	146.764,37	24.873,56
Total		184.371,21		193.981,79		171.637,93	

Tabla 8. Volumen de distribución del surtido y valor económico bruto de los productos. Los valores se expresan en 2019 en miles de dólares como moneda

USD (\$, 10 ³)	2019		2020		2021		
	Clase	Vivo	Muerto	Vivo	Muerto	Vivo	Muerto
Residuo		48,32	1,38	26,43	10,46	18,01	6,70
04 - 10		4.844,87	106,63	3.108,80	756,29	1.895,56	743,37

10 - 20	38.946,23	415,40	35.132,92	2.844,33	25.472,86	6.300,17
20 - 30	24.405,87	65,99	29.886,48	508,51	27.135,42	2.304,57
> 30	3.849,03		5.686,25	47,03	6.221,88	122,07
Sub-Total	68.196,97	588,02	68.128,19	4.109,12	54.503,84	9.348,12
Total	68.784,99		72.237,32			63.851,96

4.4 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% (Tabla 9). 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.

Tabla 9. 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

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 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 (Figura 11). 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.

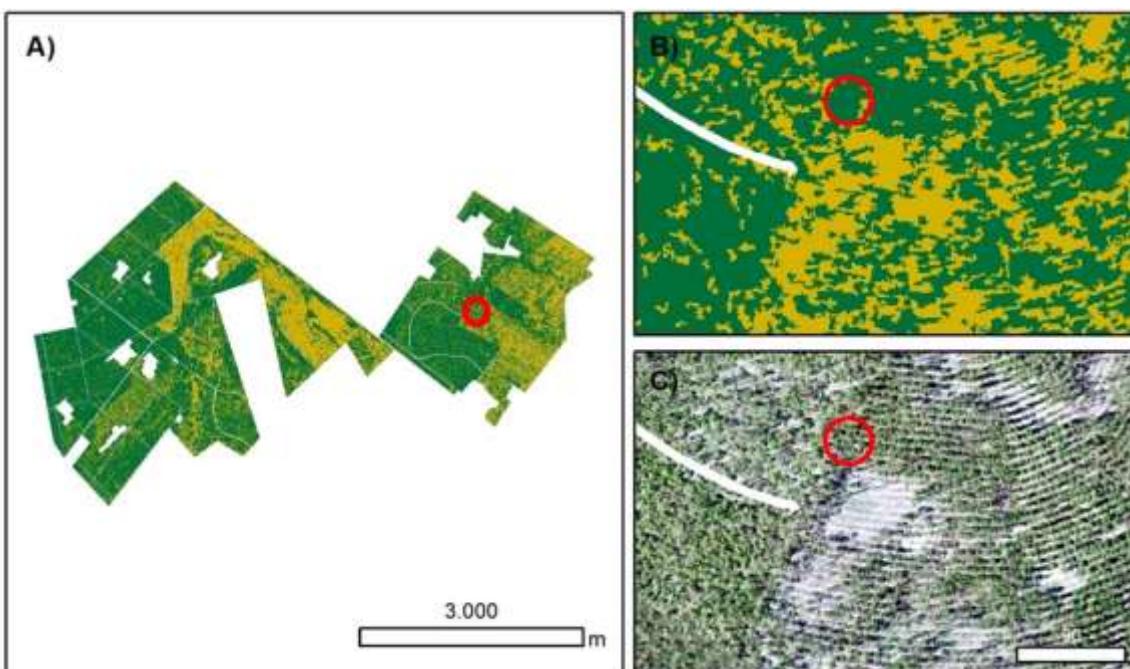


Figura 11. Clasificación de la zona de estudio mediante Random Forest (A) vivo en color verde / muerto en amarillo); (B) zona ampliada con alta mortalidad para resaltar la clasificación, (c) sobre el mosaico de color natura.

5. Discusión

La investigación confirmó el grave impacto de la sequía de 2019 en la silvicultura comercial de eucalipto en nuestra área de estudio. La densidad de plantación de árboles y las interacciones con los clones comerciales explicaron el impacto del episodio de sequía de 2019 en la zona de Tangará da Serra en Brasil y las implicaciones de los factores de gestión. 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 espacialmente continua a una resolución de alta resolución. La investigación reúne el diseño del estudio con UAV, el procesamiento de los datos de las imágenes, las técnicas de segmentación, dos enfoques de modelización diferentes (regresión y clasificación) y mapas espacialmente continuos útiles para los responsables de la toma de decisiones en la silvicultura de eucaliptos.

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.

Las plantaciones con mayor densidad de población pueden enfrentarse a un mayor estrés y riesgo en respuesta a las sequías con una mayor inversión y las plantaciones con menor densidad de población podrían sostener altas tasas de crecimiento al tiempo que aumentan el rendimiento hídrico (GONÇALEZ ET AL., 2014; HAKAMADA ET AL., 2020; WHITE ET AL., 2014). La reducción de los niveles de población a lo largo del ciclo puede hacerse plantando menos en el año cero o aplicando un conjunto más intenso de operaciones de raleo durante los primeros años del ciclo. Plantar menos consumiría menos recursos presupuestarios en términos de insumos de viveros y trabajo de campo, mientras que aumentar el peso del aclareo en los primeros años consumiría más

recursos de gestión. Las acciones pueden priorizar la disponibilidad de agua subterránea y dulce para mejorar las condiciones de humedad del suelo (ENGEL, P.; MORAN, 2013).

La magnitud de los daños fue grave en la zona de estudio. Tras la sequía de 2019, el valor de la madera muerta alcanzó los 4,1 millones de dólares sobre una valoración total de 68,1 millones de dólares de la cartera de 2020. Un año después, en 2021, el volumen de muerte representaba 9,3 millones de dólares sobre un volumen en pie decreciente cuyo valor era de 54,5 millones de dólares. Los aspectos económicos de las pérdidas forestales relacionadas con el cambio climático no están recibiendo actualmente suficiente atención por parte de los gestores acostumbrados a trabajar con los esquemas de producción tradicionales de la región. La realidad es que los efectos del clima pueden tener un impacto inmediato en la valoración de los bosques, la mortalidad y los rendimientos, como hemos demostrado en este estudio. La escala del experimento en lo que respecta a la cantidad de datos disponibles a nivel de árbol en el suelo era bastante amplia en comparación con estudios anteriores que evaluaban la dinámica de crecimiento en plantaciones forestales a pequeña escala y con diseños de muestreo reducidos: analizamos más de 15.000 mediciones de DAP, por ejemplo.

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; TOMAŠTÍK ET AL., 2019). La clasificación de los datos del suelo en diferentes niveles de mortalidad, en función del volumen afectado, fue sencilla, ya que solo se definieron dos categorías: el estado vivo o muerto de las parcelas se estableció por encima/por debajo de un umbral de mortalidad fijo para el volumen en pie afectado (5%). 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. Estudios anteriores mostraron valores de 0,82 para la extracción de información sobre la vegetación basada en imágenes visibles de teledetección (ZHANG ET AL., 2019). De Luca et al., (2019), informaron de valores de kappa de Cohen de al menos 0,847 también al utilizar RF para clasificar diferentes clases de vegetación. Nuestros resultados fueron ligeramente peores en términos de OA y kappa de Cohen que los de estudios anteriores que utilizaban dos clases (muerto vs. vivo) a nivel de árbol (DUARTE ET AL., 2020; NÄSI, 2021).

Las variables MDS confirmaron que las variaciones espaciales de la altura de la superficie reflejan los cambios sobre las dos categorías de estado sanitario en el área de estudio, indicando que una mayor varianza de la estructura vertical aumentaba la probabilidad de que el objeto perteneciera a la clase muerta (GUERRA-HERNÁNDEZ ET AL., 2021). 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. Lógicamente, la estimación de los patrones relacionados con la salud en los paisajes forestales a nivel de árbol se habría beneficiado de un sensor más sofisticado capaz de operar en el infrarrojo cercano (NIR) para captar mejor las condiciones de estrés, por ejemplo. La relación estadística entre la banda NIR y el estado/condiciones de los árboles ha sido ampliamente reportada en la literatura (LAUSCH ET AL., 2018).

Los índices ecológicos como el NDVI u otros que comprendan una gama más amplia del espectro en las formulaciones mejorarían los resultados presentados en este estudio a nivel de árbol. Sin embargo, la pequeña escala de las copas de los árboles y la posibilidad de vincular los datos de las evaluaciones de la salud de las copas a nivel del árbol con los índices de teledetección fue la razón para segmentar áreas en lugar de copas individuales de las imágenes. El uso de escáneres láser LiDAR habría facilitado la detección de árboles y la evaluación de la mortalidad de los mismos a nivel de copas. El problema de los datos láser era la disponibilidad para la investigación, escenario habitual para muchos propietarios privados y de pequeña escala que carecen de recursos para realizar encuestas con tecnología de alta gama, pero la ciencia ya es bastante sólida sobre cómo detectar árboles a partir de nubes de puntos láser 3D de LiDAR y cámaras RGB más sofisticadas diseñadas para la fotogrametría en plantaciones forestales (GUERRA-HERNÁNDEZ ET AL., 2017; LEITE ET AL., 2020; NI ET AL., 2018).

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 los episodios de sequía. El estudio proporciona una evaluación reflexiva de las implicaciones de la sequía de 2019 utilizando estudios multitemporales sobre el terreno y una metodología de valoración detallada apoyada en la fotogrametría de teledetección contemporánea. 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>
- BRADSHAW, C., GIAM, X., & SODHI, N. 2010. Evaluating the relative environmental impact of countries. PLoS ONE, 5(5). <https://doi.org/10.1371/journal.pone.0010440>
- 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>
- DE ARAUJO, M. J., DE PAULA, R. C., CAMPOE, O. C., & CARNEIRO, R. L. 2019. Adaptability and stability of eucalypt clones at different ages across environmental gradients in Brazil.

Forest Ecology and Management, 454(August), 117631.
<https://doi.org/10.1016/j.foreco.2019.117631>

DE LUCA, G., SILVA, J. M. N., CERASOLI, S., ARAÚJO, J., CAMPOS, J., DI FAZIO, S., & MODICA, G. 2019. Object-based land cover classification of cork oak woodlands using UAV imagery and Orfeo Toolbox. *Remote Sensing*, 11(10). <https://doi.org/10.3390/rs11101238>

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>

DUARTE, A., ACEVEDO-MUÑOZ, L., GONÇALVES, C. I., MOTA, L., SARMENTO, A., SILVA, M., FABRES, S., BORRALHO, N., & VALENTE, C. 2020. Detection of longhorned borer attack and assessment in eucalyptus plantations using UAV imagery. *Remote Sensing*, 12(19), 1–20. <https://doi.org/10.3390/rs12193153>

ENGEL, P.; MORAN, N. A. 2013. The gut microbiota of insects—diversity in structure and function. *FEMS Microbiology Reviews*, 37(5), 699–735.

FERRAZ, S. F. B., LIMA, W. DE P., & RODRIGUES, C. B. 2013. Managing forest plantation landscapes for water conservation. *Forest Ecology and Management*, 301, 58–66. <https://doi.org/10.1016/j.foreco.2012.10.015>

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>

GONÇALEZ, J. C., DOS SANTOS, G. L., DA SILVA JUNIOR, F. G., MARTINS, I. S., & COSTA, J. D. A. 2014. Relações entre dimensões de fibras e de densidade da madeira ao longo do tronco de *Eucalyptus urograndis*. *Scientia Forestalis/Forest Sciences*, 42(101), 81–89.

GONÇALVES, J., PÔÇAS, I., MARCOS, B., MÜCHER, 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., & CRESSION, 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., DÍAZ-VARELA, R. A., GONZÁLEZ, J. G. Á., & GONZÁLEZ, P. M. R. 2021. Assessing a novel modelling approach with high resolution UAV imagery for monitoring health status in priority riparian forests. *Forest Ecosystems*.

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>

HAKAMADA, R. E., HUBBARD, R. M., STAPE, J. L., LIMA, W. DE P., MOREIRA, G. G., & FERRAZ, S. F. DE B. 2020. Stocking effects on seasonal tree transpiration and ecosystem water balance in a fast-growing Eucalyptus plantation in Brazil. *Forest Ecology and Management*, 466(April), 118149. <https://doi.org/10.1016/j.foreco.2020.118149>

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>

LAES, D., WARNICK, R., & GOETZ, W. 2006. Lidar Applications for Forestry and Geosciences. *Minerals and Geology Management*.

LAUSCH, A., BORG, E., BUMBERGER, J., DIETRICH, P., HEURICH, M., HUTH, A., JUNG, A., KLENKE, R., KNAPP, S., MOLLENHAUER, H., PAASCHE, H., PAULHEIM, H., PAUSE, M., SCHWEITZER, C., SCHMULIUS, C., SETTELE, J., SKIDMORE, A. K., WEGMANN, M., ZACHARIAS, S., SCHAEPMAN, M. E. 2018. Understanding forest health with remote sensing, Part III: Requirements for a scalable multi-source forest health monitoring network based on data science approaches. *Remote Sensing*, 10(7). <https://doi.org/10.3390/rs10071120>

LEBLANC, S. 2018. Off-the-Shelf Unmanned Aerial Vehicles for 3D Vegetation Mapping. March.

LEITE, R. V., SILVA, C. A., MOHAN, M., CARDIL, A., DE ALMEIDA, D. R. A., E CARVALHO, S. DE P. C., JAAFAR, W. S. W. M., HERNÁNDEZ, J. G., WEISKITTEL, A., HUDAK, A. T., BROADBENT, E. N., PRATA, G., VALBUENA, R., LEITE, H. G., TAQUETTI, M. F., SOARES, A. A. V., SCOLFORO, H. F., DO AMARAL, C. H., CORTE, A. P. D., & KLAUBERG, C. 2020. Individual tree attribute estimation and uniformity assessment in fast-growing eucalyptus spp. *Forest plantations*

using lidar and linear mixed-effects models. *Remote Sensing*, 12(21), 1–20. <https://doi.org/10.3390/rs12213599>

LOARIE, S. R., DUFFY, P. B., HAMILTON, H., ASNER, G. P., FIELD, C. B., & ACKERLY, D. D. 2009. The velocity of climate change. *Nature*, 462(7276), 1052–1055. <https://doi.org/10.1038/nature08649>

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>

NÄSI, R. 2021. Drone-based spectral and 3D remote sensing applications for forestry and agriculture.

NI, W., SUN, G., PANG, Y., ZHANG, Z., LIU, J., YANG, A., WANG, Y., & ZHANG, D. 2018. Mapping Three-Dimensional Structures of Forest Canopy Using UAV Stereo Imagery: Evaluating Impacts of Forward Overlaps and Image Resolutions with LiDAR Data as Reference. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 11(10), 3578–3589. <https://doi.org/10.1109/JSTARS.2018.2867945>

PENA, R. F. 2018. ANÁLISE SILVICULTURAL DE CLONES DE EUCA利PTO E CARACTERÍSTICAS PRODUTIVAS DO PASTO EM SISTEMA SILVIPASTORIL, EM CORONEL PACHECO, MG.

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.

SCHMIDT, G. A., & ARNDT, D. 2020. Annual Global Analysis for 2019. January.

TANG, L., & SHAO, G. 2015. Drone remote sensing for forestry research and practices. *Journal of Forestry Research*, 26(4), 791–797. <https://doi.org/10.1007/s11676-015-0088-y>

TEODORO, A. C., & ARAUJO, R. 2016. Comparison of performance of object-based image analysis techniques available in open source software (Spring and Orfeo Toolbox/Monteverdi) considering very high spatial resolution data. *Journal of Applied Remote Sensing*, 10(1), 016011. <https://doi.org/10.1117/1.jrs.10.016011>

TOMAŠÍK, J., MOKROŠ, M., SUROVÝ, P., GRZNÁROVÁ, A., & MERGANIČ, J. 2019. UAV RTK/PPK method-An optimal solution for mapping inaccessible forested areas? *Remote Sensing*, 11(6). <https://doi.org/10.3390/RS11060721>

TORRES-SÁNCHEZ, J., LÓPEZ-GRANADOS, F., & PEÑA, J. M. 2015. An automatic object-based method for optimal thresholding in UAV images: Application for vegetation detection in herbaceous crops. *Computers and Electronics in Agriculture*, 114, 43–52. <https://doi.org/10.1016/j.compag.2015.03.019>

VAN EEUWIJK, F. A., BUSTOS-KORTS, D. V., & MALOSETTI, M. 2016. What should students in plant breeding know about the statistical aspects of genotype × Environment interactions? *Crop Science*, 56(5), 2119–2140. <https://doi.org/10.2135/cropsci2015.06.0375>
 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>

WHITE, D. A., MCGRATH, J. F., RYAN, M. G., BATTAGLIA, M., MENDHAM, D. S., KINAL, J., DOWNES, G. M., CROMBIE, D. S., & HUNT, M. E. 2014. Managing for water-use efficient wood production in *Eucalyptus globulus* plantations. *Forest Ecology and Management*, 331, 272–280. <https://doi.org/10.1016/j.foreco.2014.08.020>

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>