

**ALÉM DAS ÁRVORES: MAPEANDO A BIOMASSA TOTAL ACIMA  
DO SOLO NO CERRADO BRASILEIRO USANDO DADOS DE  
LIDAR AEROTRANSPORTADO DE ALTA DENSIDADE**

**MÁIRA BEATRIZ TEIXEIRA DA COSTA**

**TESE DE DOUTORADO EM CIÊNCIAS FLORESTAIS  
DEPARTAMENTO DE ENGENHARIA FLORESTAL**

**FACULDADE DE TECNOLOGIA  
UNIVERSIDADE DE BRASÍLIA - UnB**



**UNIVERSIDADE DE BRASÍLIA  
FACULDADE DE TECNOLOGIA  
DEPARTAMENTO DE ENGENHARIA FLORESTAL  
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIAS FLORESTAIS**

**ALÉM DAS ÁRVORES: MAPEANDO A BIOMASSA TOTAL ACIMA  
DO SOLO NO CERRADO BRASILEIRO USANDO DADOS DE  
LIDAR AEROTRANSPORTADO DE ALTA DENSIDADE**

**MÁIRA BEATRIZ TEIXEIRA DA COSTA**

**ORIENTADOR: PROF. DR. ERALDO A. TRONDOLI MATRICARDI**

**COORIENTADOR: CARLOS ALBERTO SILVA**

**TESE DE DOUTORADO EM CIÊNCIAS FLORESTAIS**

**PUBLICAÇÃO: PPGEFL.DM-00/2023**

**BRASÍLIA/ DF: FEVEREIRO - 2023**

**Brasília/DF: 17 de fevereiro de 2023**

UNIVERSIDADE DE BRASÍLIA  
FACULDADE DE TECNOLOGIA  
DEPARTAMENTO DE ENGENHARIA FLORESTAL  
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIAS FLORESTAIS

**ALÉM DAS ÁRVORES: MAPEANDO A BIOMASSA TOTAL ACIMA  
DO SOLO NO CERRADO BRASILEIRO USANDO DADOS DE  
LIDAR AEROTRANSPORTADO DE ALTA DENSIDADE**

**MÁIRA BEATRIZ TEIXEIRA DA COSTA**

TESE DE DOUTORADO SUBMETIDA AO DEPARTAMENTO DE ENGENHARIA FLORESTAL DA FACULDADE DE TECNOLOGIA NA UNIVERSIDADE DE BRASÍLIA COMO PARTE DOS REQUISITOS NECESSÁRIOS À OBTENÇÃO DO GRAU DE DOUTORA EM CIÊNCIAS FLORESTAIS.

APROVADA POR:

---

Prof. Dr. Eraldo A. T. Matricardi (Departamento de Engenharia Florestal – UnB)  
(Orientador)

---

Prof. Dr. Reginaldo Sérgio Pereira (Departamento de Engenharia Florestal – UnB)  
(Examinador Interno)

---

Prof. Dr. Carine Klauberg (Departamento de Engenharia Florestal – UFSJ)  
(Examinador Externo)

---

Prof. Dr. Edson Eyji Sano (Embrapa)  
(Examinador Externo)

**Brasília/DF: 17 de fevereiro de 2023**

Ca Costa, Máira Beatriz Teixeira da  
Além das árvores: mapeando a biomassa total acima do solo no cerrado brasileiro usando dados de Lidar aerotransportado de alta densidade / Máira Beatriz Teixeira da Costa; orientador Eraldo Aparecido Trondoli Matricardi; co-orientador Carlos Alberto SILVA. -- Brasília, 2023.  
77 p.

Tese (Doutorado em Ciências Florestais) -- Universidade de Brasília, 2023.

1. Sensoriamento Remoto. 2. Biomassa. 3. Lidar. 4. Savana Tropical. 5. Cerrado. I. Trondoli Matricardi, Eraldo Aparecido, orient. II. SILVA, Carlos Alberto, co-orient. III. Título.

## REFERÊNCIA BIBLIOGRÁFICA

COSTA, M. B. T. (2023). **Além das árvores: mapeando a biomassa total acima do solo no Cerrado brasileiro usando dados de lidar aerotransportado de alta densidade.** Tese de Doutorado em Ciências Florestais, Publicação. Departamento de Engenharia Florestal, Universidade de Brasília (UNB), Brasília/DF, 77 f.

## CESSÃO DE DIREITOS

AUTORA: Máira Beatriz Teixeira da Costa

TÍTULO: Além das árvores: Mapeando a densidade total de biomassa acima do solo na savana brasileira utilizando dados de lidar aerotransportado de alta densidade.

GRAU: Doutora / ANO: 2023

É concedido à Universidade de Brasília permissão para reproduzir cópias desta Tese de Doutorado e para emprestar ou vender tais cópias somente para propósitos acadêmicos e científicos. O autor reserva outros direitos de publicação e nenhuma parte desta dissertação de mestrado pode ser reproduzida sem autorização por escrito da autora.

---

Máira Beatriz Teixeira  
Departamento de Engenharia Florestal (EFL)-FT Universidade de Brasília (UnB)  
Campus Darcy Ribeiro  
CEP 70919-970  
Brasília - DF- Brasil

## DEDICÁTORIA

*Dedico esse trabalho à minha mãe, Delvânia Quintino Teixeira (in memorian), por ser o incentivo na realização dos meus sonhos e que guia meus caminhos hoje e sempre.*

## AGRADECIMENTOS

A Deus pela vida, por me iluminar e transmitir força para alcançar meus objetivos, mesmo diante de momentos tão difíceis e por permitir vivenciar experiências ímpares junto às pessoas tão especiais.

Ao meu companheiro Marcelo Félix Luiz e ao meu filho Matteo Félix Teixeira, pelo amor e apoio.

À minha família, em especial à minha mãe Delvânia (*in memorian*), minha irmã, meus avós e tios, aos que devo minha formação, pois sempre me incentivaram e proporcionaram a minha chegada até aqui.

Ao meu querido orientador Eraldo Aparecido Trondoli Matricardi, pela orientação, ensinamentos, incentivos e acima de tudo pela compreensão, cuidado, paciência e por sempre acreditar no meu potencial, serei eternamente grata.

Ao meu coorientador Carlos Alberto Silva e a Carine Klauberg, por me permitir fazer parte desse grande projeto, pelo apoio, compreensão, ensinamentos, paciência e ajuda durante a realização desse trabalho.

Aos meus professores por compartilharem conhecimento e incentivo durante o doutorado.

Aos membros da banca examinadora, pelas correções, sugestões e seu tempo dedicado a fim de enriquecer o trabalho.

Aos amigos e colegas que a Pós-Graduação proporcionou conhecer, em especial, Adrianna, Anne Laura, Carlos Magno, Hallefy, Juliano, Kálita, Ilvan, Maísa, Maria Tereza, Myla, Niliane, Paola e Rodrigo Vieira, que contribuíram com meu crescimento profissional e pessoal nessa jornada.

À Universidade de Brasília (UnB) e ao Programa de Pós-graduação em Ciências Florestais, pela oportunidade de fazer o curso de Doutorado e por ter me proporcionado grandes oportunidades.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), pela concessão de bolsa.

**A todos, meu muito obrigado!**

*“Que esta não seja a última conquista;  
Que os sonhos não acabem;  
Que as verdades não sejam absolutas;  
Que o conhecimento ainda seja pouco;  
Que a fé e o respeito prevaleçam;  
E que eu não esqueça minhas origens”*

**Autor Desconhecido**

# SUMÁRIO

<b>LISTA DE FIGURAS .....</b>	<b>x</b>
<b>LISTA DE TABELAS.....</b>	<b>xi</b>
<b>RESUMO GERAL .....</b>	<b>12</b>
<b>GENERAL ABSTRACT .....</b>	<b>13</b>
<b>CAPÍTULO 1 – REFERENCIAL TEÓRICO E ASPECTOS GERAIS DA TESE.....</b>	<b>14</b>
<b>1.1. ASPECTOS GERAIS DESTA TESE.....</b>	<b>14</b>
<b>1.2. REFERENCIAL TEÓRICO.....</b>	<b>15</b>
1.2.1. SAVANAS .....	15
1.2.2. FOGO NO CERRADO .....	16
1.2.3. UNIDADES DE CONSERVAÇÃO NO CERRADO .....	18
1.2.4. COMPORTAMENTO DO FOGO.....	19
1.2.5. BIOMASSA ACIMA DO SOLO NO CERRADO .....	20
1.2.6. LIDAR.....	21
1.3. O PROBLEMA.....	24
1.4. QUESTÕES DE PESQUISA.....	25
1.5. OBJETIVOS.....	25
1.5.1. Objetivo Geral.....	25
1.5.2. Objetivo específicos .....	25
1.6. HIPÓTESE.....	26
<b>CAPÍTULO 2 – ALÉM DAS ÁRVORES: MAPEANDO A BIOMASSA TOTAL ACIMA DO SOLO NO CERRADO BRASILEIRO USANDO DADOS DE LIDAR AEROTRANSPORTADO DE ALTA DENSIDADE.....</b>	<b>27</b>
<b>HIGHLIGHTS.....</b>	<b>28</b>
<b>2.1. INTRODUÇÃO .....</b>	<b>29</b>
<b>2.2. MATERIAL E MÉTODOS.....</b>	<b>32</b>
2.2.1. ÁREA DE ESTUDO.....	32
2.2.2. MENSURAÇÃO NO CAMPO .....	34
2.2.3. UAV-LIDAR.....	37
2.2.4. DESENVOLVIMENTO E AVALIAÇÃO DA MODELAGEM.....	40
2.2.5. MAPEAMENTO DE BIOMASSA ACIMA DO SOLO .....	42
<b>2.3. RESULTADOS.....</b>	<b>44</b>
2.3.1. MÉTRICAS UAV-LIDAR .....	44
2.3.2. AVALIAÇÃO DE DESEMPENHO DO MODELO .....	46
2.3.3. MAPEAMENTO DE BIOMASSA ACIMA DO SOLO .....	49



<b>2.4. DISCUSSÃO</b> .....	<b>51</b>
2.4.1. INCLUINDO VEGETAÇÃO NÃO LENHOSA EM ESTIMATIVAS LIDAR DE BIOMASSA ACIMA DO SOLO.....	51
2.4.2. CONVERGÊNCIA DE MÉTRICAS ENTRE SENSORES, PLATAFORMAS E FORMAÇÕES DE VEGETAÇÃO DA SAVANA .....	53
2.4.3. SUPERANDO DESAFIOS NO MAPEAMENTO DE BIOMASSA TOTAL ACIMA DO SOLO EM ECOSSISTEMAS DE SAVANA TROPICAL.....	54
2.4.4. IMPLICAÇÕES MAIS AMPLAS DE NOSSAS DESCOBERTAS .....	54
<b>2.5. CONCLUSÃO</b> .....	<b>55</b>
<b>2.6. AGRADECIMENTOS</b> .....	<b>56</b>
<b>2.7. REFERÊNCIAS BIBLIOGRÁFICAS</b> .....	<b>56</b>
<b>CAPÍTULO 3 – CONSIDERAÇÕES FINAIS SOBRE A TESE</b> .....	<b>76</b>

## LISTA DE FIGURAS

- Figura 1.** Mapa do modelo de altura do dossel derivado de UAV-lidar dentro da área de estudo no Cerrado brasileiro. Parque Nacional Serra do Cipó (PNSC), Parque Nacional Chapada dos Veadeiros (PNCV), Floresta Nacional de Paraopeba (FNP), e Floresta da Universidade de São João Del-Rei (UFSJ). ..... 34
- Figura 2.** Ilustração da coleta de dados de campo. a) formação do Cerrado, b) desenho de parcelas e subparcelas de campo para medição da biomassa total acima do solo (AGBt), e c) medições de DAP e altura das árvores, d) medição de biomassa superficial..... 35
- Figura 3.** Sistema GatorEye UAV-lidar. a) Sistema GatorEye UFL (Gen 1), com Phoenix Scout Ultra, sensores hiperespectrais e visuais em uma fuselagem DJI M600 Pro; b) Antenas GNSS para navegação (três) e trajetória de sensores (meio); e c) Velodyne Ultra Puck (sistema lidar)..... 39
- Figura 4.** Fluxo de trabalho para o processamento de dados UAV-lidar, AGBt modelagem e mapeamento..... 44
- Figura 5.** Diagrama de correlação (r) de Pearson entre as 17 métricas derivadas de lidar usando um limite  $|r| > 0,9$ . Os valores são classificados usando um gradiente de cores de -1 a 1, onde 0 significa nenhuma correlação e 1 uma forte correlação. Os sinais negativo e positivo indicam relações inversas e diretas entre duas variáveis, respectivamente. .... 45
- Figura 6.** Imagens do solo foram tiradas durante as medições de campo (a-c1). Perspectivas de nuvem de pontos 3-D para parcelas de amostra selecionadas pesquisadas por UAV-lidar e onde diferentes propriedades biofísicas foram medidas (a-c2). Gráficos de densidade de retornos de altura lidar para as três formações principais (a-c3). A letra indica a formação da vegetação e é identificada na ordem como campestre (começando com a letra a), Cerrado (começando com a letra b) e floresta (começando com a letra c). ..... 46
- Figura 7.** Gráfico de dispersão de previsões de validação cruzada versus observações (N = 50) para a biomassa acima do solo total transformada em logaritmo natural (AGBt) usando a validação cruzada leave-one-out (LOOCV). A linha vermelha tracejada indica a relação 1:1, enquanto a linha preta indica o melhor ajuste. Os números entre parênteses são os erros padrão de cada coeficiente. (b) Distribuição de frequência da distribuição estimada e observada do AGBt. A linha tracejada indica o AGBt médio para ambos os conjuntos de dados. .... 48
- Figura 8.** Mapas derivados de UAV-lidar da biomassa total acima do solo (AGBt) para os locais de estudo a1-d1) com resolução espacial de 30 m; camadas de formação de Cerrado a2-d2) e distribuição do AGBt por formação vegetal no Cerrado. .... 50

## LISTA DE TABELAS

<b>Tabela 1.</b> Resumo da biomassa total acima do solo (AGBt) dentro de nossas parcelas de campo e estratificada por formações de Cerrado.....	37
<b>Tabela 2.</b> Métricas derivadas de UAV-lidar.....	39
<b>Tabela 3.</b> Comparação de modelos calibrados usando métricas derivadas de UAV-lidar para estimar a biomassa aérea total (AGBt) no Cerrado.....	47
<b>Tabela 4.</b> Resumo do RMSE absoluto e relativo para o modelo calibrado e previsões LOOCV AGBt estratificadas por formações de vegetação no Cerrado. n= número de observações (parcelas de campo) por formação.....	49
<b>Tabela 5.</b> Resumo da biomassa total acima do solo (AGBt) e estimadores de variância na escala da paisagem nas formações do Cerrado. n = número de observações (células da grade mapeadas).....	51

**ALÉM DAS ÁRVORES: MAPEANDO A BIOMASSA TOTAL ACIMA DO SOLO  
NO CERRADO BRASILEIRO USANDO DADOS DE LIDAR  
AEROTRANSPORTADO DE ALTA DENSIDADE**

**RESUMO GERAL**

Os ecossistemas de savana tropical desempenham um papel importante na sazonalidade do ciclo global do carbono. No entanto, sua capacidade de armazenar e sequestrar carbono é incerta devido aos efeitos combinados e interativos das atividades antropogênicas e das mudanças climáticas, que afetam os regimes de incêndios florestais e a dinâmica da vegetação. Medições precisas da biomassa acima do solo (AGB) na savana tropical em escalas espaciais amplas, são cruciais para alcançar estratégias eficazes de mitigação de emissões de carbono. UAV-lidar é uma nova tecnologia de sensoriamento remoto que pode permitir mapeamento 3-D rápido da estrutura e AGB de ecossistemas de savana tropical. Este estudo teve como objetivo avaliar a capacidade do UAV-lidar de alta densidade para estimar e mapear a biomassa aérea total (árvores, arbustos e camadas superficiais) (AGBt) no Cerrado brasileiro. Cinco modelos ordinários de regressão de mínimos quadrados estimando AGBt foram ajustados, usando uma amostra de 50 parcelas de campo (30x30 m<sup>2</sup>), e foram usados para mapear o AGBt a partir de dados UAV-lidar coletados em mais de 1.854 ha abrangendo as três principais formações de vegetação (floresta, savana e campestre) no Cerrado. O melhor modelo foi selecionado através do Critério de Informação de Akaike, coeficiente de determinação ajustado (adj. R<sup>2</sup>), erro quadrático absoluto e relativo (RMSE). O modelo que usa altura e cobertura da vegetação foi o mais eficaz, com um modelo global com adj-R<sup>2</sup> de 0,79 e um RMSE de validação cruzada de 19,11 Mg/ha (33,40%). A incerteza e os erros de nossas estimativas foram avaliados para cada formação de vegetação separadamente, resultando em RMSEs de 27,08 Mg/ha (25,99%) para florestas, 17,76 Mg/ha (43,96%) para savanas e 7,72 Mg/ha (44,92%) para campestre. Esses resultados comprovam a viabilidade do potencial da tecnologia UAV-lidar no Cerrado, mas também enfatizam a necessidade de aprofundar a estimativa de biomassa em savanas, de grande importância na caracterização do balanço global de carbono e para apoiar atividades integradas de manejo do fogo em ecossistemas de savana tropical. Nossos resultados servem de referência para estudos futuros com o objetivo de gerar mapas precisos de biomassa e fornecer dados de linha de base para o gerenciamento eficiente de incêndios e impactos previstos de mudanças climáticas nos ecossistemas de savana tropical.

**Palavras-chave:** biomassa, vegetação, savana tropical, sensoriamento remoto, Cerrado, mapeamento, GatorEye.

# **BEYOND ÁRVORES: MAPPING TOTAL ABOVEGROUND BIOMASS DENSITY IN THE BRAZILIAN SAVANNA USING HIGH-DENSITY UAV-LIDAR DATA**

## **GENERAL ABSTRACT**

Tropical savanna ecosystems play a major role in the seasonality of the global carbon cycle. However, their ability to store and sequester carbon is uncertain due to combined and intermingling effects of anthropogenic activities and climate change, which impact wildfire regimes and vegetation dynamics. Accurate measurements of tropical savanna vegetation aboveground biomass (AGB) over broad spatial scales are crucial to achieve effective carbon emission mitigation strategies. UAV-lidar is a new remote sensing technology that can enable rapid 3-D mapping of structure and related AGB in tropical savanna ecosystems. This study aimed to assess the capability of high-density UAV-lidar to estimate and map total (árvore, shrubs, and surface layers) aboveground biomass density (AGBt) in the Brazilian Savanna (Cerrado). Five ordinary least square regression models estimating AGBt were adjusted using 50 field sample plots (30 m × 30 m). The best model was selected under Akaike Information Criterion, adjusted coefficient of determination ( $\text{adj.R}^2$ ), absolute and relative root mean square error (RMSE), and used to map AGBt from UAV-lidar data collected over 1,854 ha spanning the three major vegetation formations (forest, savanna, and grassland) in Cerrado. The model using vegetation height and cover was the most effective, with an overall model  $\text{adj.R}^2$  of 0.79 and a leave-one-out cross-validated RMSE of 19.11 Mg/ha (33.40%). The uncertainty and errors of our estimations were assessed for each vegetation formation separately, resulting in RMSEs of 27.08 Mg/ha (25.99%) for forests, 17.76 Mg/ha (43.96%) for savannas, and 7.72 Mg/ha (44.92%) for grasslands. These results prove the feasibility and potential of the UAV-lidar technology in Cerrado but also emphasize the need for further developing the estimation of biomass in grasslands, of high importance in the characterization of the global carbon balance and for supporting integrated fire management activities in tropical savanna ecosystems. Our results serve as a benchmark for future studies aiming to generate accurate biomass maps and provide baseline data for efficient management of fire and predicted climate change impacts on tropical savanna ecosystems.

**Key words:** Biomass, Vegetation, Tropical savana, Remote sensing, Cerrado, Mapping, GatorEye.

## **CAPÍTULO 1 – REFERENCIAL TEÓRICO E ASPECTOS GERAIS DA TESE**

### **1.1. ASPECTOS GERAIS DESTA TESE**

Essa tese faz parte de um projeto de pesquisa mais amplo, aprovado pelo Conselho Nacional de Desenvolvimento Científico e Tecnológico – CNPq 442640/2018-8, CNPQ/Prevfogo-Ibama do (Nº 33/2018).

**CAPÍTULO 1 – REFERENCIAL TEÓRICO:** Este capítulo é composto pelo referencial teórico, justificativas, hipóteses e questões norteadoras desta pesquisa. O objetivo é fornecer a fundamentação teórica utilizada para a construção e análise dos resultados e discussões apresentadas no capítulo seguinte.

**CAPÍTULO 2 – ALÉM DAS ÁRVORES: MAPEANDO A DENSIDADE TOTAL DE BIOMASSA ACIMA DO SOLO NA SAVANA BRASILEIRA USANDO DADOS DE LIDAR AEROTRANSPORTADO DE ALTA DENSIDADE:** Neste capítulo buscamos estimar e mapear biomassa acima do solo total (AGBt), incluindo os seguintes componentes: árvores, arbustos e serapilheira em formações do Cerrado brasileiro: campestre, savana e floresta utilizando dados de LiDAR aerotransportado.

**CAPÍTULO 3 – CONSIDERAÇÕES FINAIS SOBRE A TESE:** Neste capítulo, sintetizamos as principais conclusões desta pesquisa, destacando os principais pontos abordados e revisitando as hipóteses desta pesquisa.

## 1.2. REFERENCIAL TEÓRICO

### 1.2.1. SAVANAS

As savanas são ecossistemas diversos, complexos, globalmente significativos e de grande relevância para a economia (SANKARAN et al., 2005; SCHOLLES; ARCHER, 1997; WHITLEY et al., 2017), ocupam aproximadamente 23 milhões de km<sup>2</sup> (cerca de um quinto da superfície terrestre) e encontram-se distribuídos pela África, Austrália, América do Sul e Ásia (LEHMANN et al., 2014). E, são reconhecidos globalmente por sua riqueza de espécies e biodiversidade endêmica (SIMON et al., 2009).

Esses ecossistemas são caracterizados por uma cobertura arbórea descontínua e um sub-bosque contínuo, que variam de formações campestre abertas e com poucas plantas lenhosas, a bosques ou florestas com uma camada graminosa (HOUSE et al., 2003), promovendo assim um contraste entre árvores e gramíneas ao longo da paisagem (RATNAM et al., 2011).

A disponibilidade de recursos (água, sol, espaço) e regimes de perturbação (fogo, herbicidas) são considerados importantes na regulação da cobertura lenhosa (JELTSCH; WEBER; GRIMM, 2000). Em função de suas características, as savanas tornam-se responsáveis por suportar a maior parte da pecuária mundial, concedendo habitat, lenha e outros produtos (HOUSE et al., 2003; SANKARAN et al., 2004; WHITE et al., 2000).

As savanas tropicais desempenham um papel importante no orçamento global de carbono (POULTER et al., 2014), pois estão fortemente associadas ao seu ciclo, promovendo assimilação e acumulação do carbono a partir de processos naturais ou influenciados por distúrbios antrópicos (PAIVA et al., 2011). No entanto, as taxas de armazenamento e fixação de carbono, principalmente considerando cada tipo de formação, são pouco conhecidas (PUGH et al., 2019; DUVERT et al., 2020).

A savana brasileira é chamada de Cerrado, e representa o segundo maior bioma da América Latina, depois da Amazônia (JESUS et al., 2017), abrange aproximadamente 24% da superfície total do Brasil (IBGE, 2020), com pouco mais de 2 milhões de km<sup>2</sup> (LAHSEN et al., 2016). As diferentes formações fitofisionômicas do Cerrado se desenvolvem sob um clima tropical e traduzem um ecossistema com enormes variações de estrutura e biomassa (DELITTI et al., 2006). Nele tem a flora mais rica do mundo em

diversidade florística, são 12.669 espécies, sendo 33% endêmicas, e são líderes mundiais (FORZZA et al., 2012; KLINK; MCHADO, 2005).

Este bioma está representado por onze fitofisionomias distribuídas entre três tipos de formações: florestais (mata ciliar, mata de galeria, matas secas e cerradão), savânicas (Cerrado sensu stricto, parque de Cerrado, palmeiral e vereda) campestre (campo sujo, limpo e rupestre) que formam um mosaico de elevada biodiversidade (RIBEIRO; WALTER, 2008). Por apresentar alta riqueza em biodiversidade, altos níveis de endemismo e funções ambientais de importância global, como o papel significativo do balanço global de carbono (POULTER et al., 2014), é considerado um dos *hotspots* mundiais para a conservação (STRASSBURG et al., 2017; DANTAS, et al., 2018; GOMES et al., 2018).

Contudo, apesar de sua importância, o bioma vem sofrendo com o aumento da exploração de seus recursos naturais (GOEDERT et al., 1989; MMA, 2011), aumento das atividades antropogênicas e mudanças causadas pelo homem no regime de fogo (DURIGAN e RATTER, 2016).

#### 1.2.2. FOGO NO CERRADO

O fogo é um evento histórico e frequente em ecossistemas terrestres (BOWMAN et al., 2009), é um elemento natural de importância fundamental na preservação, formação e funcionamento dos ecossistemas globais, em especial das savanas, pradarias, ecossistemas mediterrâneos e floresta boreal (MARAVALHAS e VASCONCELOS, 2014). E influencia a distribuição e a dinâmica da vegetação (BEERLING; OSBORNE, 2006; WHITE et al., 2013).

No Cerrado, o fogo está presente há cerca de 4 milhões de anos (SIMON et al., 2009), faz parte do seu ciclo natural e é um fator seletivo importante para a manutenção da estrutura da vegetação, biodiversidade e funcionamento desse ecossistema (SIMON; PENNINGTON, 2012). E, assim como outras savanas no mundo, se tornam especialmente inflamáveis no final da estação seca (DURIGAN e RATTER, 2016), quando as condições meteorológicas favorecem a propagação do fogo na vegetação (COUTINHO, 1990).

As plantas do Cerrado se caracterizam por atributos morfológicos e fisiológicos



que permitem a sobrevivência e aumento no sucesso reprodutivo após fogo, como frutos com paredes espessas e alto teor de água, que isolam e protegem as sementes do calor (CIRNE e MIRANDA, 2008); órgãos subterrâneos (xilopódios) com estoque de água e nutrientes, que junto com os meristemas o estoque permite o rebrotamento após a passagem do fogo; caule com casca espessa que protegem gemas e tecidos internos; e dispersão de sementes induzida pelo fogo (COUTINHO, 1977; PAUSAS, 2015; SIMON et al., 2009).

Mas os regimes naturais de fogo foram alterados por mudanças climáticas ligada ao aumento de temperatura e a intensificação das secas extremas (PIVELLO, 2011; REICHSTEIN et al., 2013; PAUSAS; KEELEY, 2009; ENRIGHT et al., 2015) além do uso antrópico indiscriminado e frequente do fogo, um fator significativo de ignição (PIVELLO, 2011), que vem alterando a naturalidade desses eventos, trazendo grandes consequências, de forma que não podemos prever se todas as espécies conseguirão se adaptar aos atuais regimes de fogo (PAUSAS; KEELEY, 2009).

A frequência natural de fogo no Cerrado ocorre a cada 3 a 9 anos (MIRANDA, 2010), e afeta a vegetação lenhosa. Queimadas frequentes em curto espaço de tempo aumentam a mortalidade das plantas lenhosas (MEDEIROS e MIRANDA, 2005), diminui o sucesso reprodutivo (HOFFMANN, 1998; HOFFMANN et al., 2003) e aumenta a emissão de gases do efeito estufa (GOMES et al., 2020; PIVELLO, 2011). No entanto, a frequência de ocorrência baixa ou mesmo a exclusão do fogo gera acúmulo de biomassa fina, resultando em incêndios severos (FIDELIS et al., 2018; FIDELIS & PIVELLO, 2011), além de adensamento do estrato lenhoso (HONDA e DURIGAN, 2016; ROSAN et al., 2019) e modificação da composição da vegetação (LE STRADIC et al., 2018).

De forma geral, ele é responsável por sérios danos ecológicos, materiais e financeiros em florestas nativas e plantadas (WHITE; RIBEIRO; SOUZA, 2013). Entre 2002 e 2010, foram registrados 545.000 km<sup>2</sup> de área queimada, o que representa aproximadamente 73% da área total queimada no Brasil (ARAÚJO et al., 2012). Em 2022, foram cerca de 250.707 km<sup>2</sup> queimados e 56.885 focos de incêndios, o que corresponde a 28,33% do total de focos no Brasil, em áreas de Unidades de Conservação – Ucs, o número focos em 2019 foi de 63.874 (INPE, 2022).

Atualmente o fogo tem sido objeto de debate, constituindo-se em um dos problemas ambientais mais graves que afetam o bioma (DURIGAN; RATTER, 2016; MIRANDA, 2010), principalmente em áreas destinadas a conservação do bioma Cerrado (DURIGAN; RATTER, 2016).

### 1.2.3. UNIDADES DE CONSERVAÇÃO NO CERRADO

Devido à importância ecológica do Cerrado, as Unidades de Conservação (UCs) foram criadas, com o intuito de proteger as paisagens remanescentes do bioma, e consequentemente auxiliar na conservação da biodiversidade e manutenção dos serviços ecossistêmicos. A manutenção do Cerrado por meio de UCs é extremamente importante do ponto de vista socioambiental e econômico, pois diversas comunidades dependem da sua biodiversidade (SILVA et al., 2022).

Atualmente em todo o bioma há cerca de 310 UCs, dentre estaduais, municipais e federais, totalizando 22.718.160 hectares, ou 11% da área do bioma, distribuídas nos estados de Goiás, Tocantins, Maranhão, Piauí, Bahia, Mato Grosso, Mato Grosso do Sul, Minas Gerais, São Paulo e Distrito Federal (BATISTA, 2019). Entretanto, é o segundo bioma mais afetado por queimadas, cabe salientar que boa parte das áreas afetadas são as Unidades de Conservação (SILVA et al., 2022).

Isso demonstra que as taxas de áreas queimadas no bioma têm sido mais elevadas do que os esforços para sua conservação, tornando-o altamente ameaçado (KLINK; MACHADO, 2005). O ideal para a manutenção do ecossistema é que esses números fossem os menores possíveis, porém a realidade é diferente, e a incidência de focos de incêndio em UCs só aumenta.

Assim, o estoque de carbono global é comprometido, causando desequilíbrio no ciclo do carbono (BACCINI et al., 2017; NOOJIPADY et al., 2017; BONANOMI et al., 2019) e ameaçando a manutenção da biodiversidade, qualidade ambiental e fontes de bens e serviços ecossistêmicos (SKOGEN et al., 2018).

Diante disso, é importante conhecer o comportamento do fogo no Cerrado, pois é partindo desse tipo de informação que se gera subsídios para o Manejo Integrado do Fogo (MIF), e permite que decisões efetivas sejam tomadas como, por exemplo, a execução de queimadas controladas, determinação do perigo de ocorrência de incêndios,

delineamento das áreas de maior risco, e a proposição de estratégias de prevenção e combate aos incêndios (WHITE, 2010; MAGALHÃES et al., 2017). Principalmente em nível de paisagem, melhorando a compreensão da gestão dos incêndios florestais através do desenvolvimento de um manejo preventivo e conseqüentemente protegendo e conservando a biodiversidade do Bioma (WHITE; RIBEIRO; SOUZA, 2013; MAGALHÃES et al., 2017).

#### 1.2.4. COMPORTAMENTO DO FOGO

O comportamento do fogo é a principal característica de um incêndio florestal ou uma queima, e refere-se à maneira como o material entra em combustão (BATISTA; BEUTLING; PEREIRA, 2013), como se desenvolvem as chamas e como o fogo se propaga e apresenta outros fenômenos (BATISTA; BEUTLING; PEREIRA, 2013). É influenciado pelas complexas interações entre a vegetação, clima, topografia e atividades antrópicas ao longo do tempo (TORRES; JÚNIOR; LIMA, 2019).

Entre os fatores diretamente relacionados ao comportamento do fogo e a severidade do incêndio, os principais são as características do material combustível disponível no sistema, ou seja, a proporção da biomassa acima do solo suscetível ao consumo durante um evento de incêndio e sua distribuição espacial (PYNE; ANDREWS; LAVEN, 1996).

Assim, a quantificação da biomassa acima do solo suscetível ao consumo precisa é essencial, pois a partir do mapeamento do material combustível e uso de modelos, é possível simular e prever o comportamento da propagação do fogo na paisagem e os potenciais impactos causados por ele em ambiente computacional, os quais combinam informações acerca dos principais fatores, tais como quantificação do material combustível e sua distribuição espacial (PYNE; ANDREWS; LAVEN, 1996). E, assim possibilita identificar os locais mais susceptíveis a esse fenômeno e gerar estratégias pertinentes ao Manejo Integrado do Fogo (MIF).

Entretanto, os modelos de comportamento do fogo no Cerrado ainda são incipientes (GOMES; MIRANDA; BUSTAMANTE, 2018). E a tipologia vegetal é um fator importante a ser considerado em estudos de comportamento do fogo, principalmente no Cerrado, onde as formações vegetais são muito variadas em termos estruturais, florísticos (RIBEIRO; WALTER, 2008) e microclimáticos (HOFFMANN et al., 2012),

onde cada formação produz uma biomassa distinta quanto à sua carga e estrutura, tornando uns mais susceptíveis ao fogo que outros (MAGALHÃES et al., 2017).

#### 1.2.5. BIOMASSA ACIMA DO SOLO NO CERRADO

As estimativas de biomassa acima do solo são consideradas importantes indicadores de balanço global de carbono, além de servirem de base para previsões e diagnósticos futuros sobre mudanças climáticas (DIXON et al., 1994; KETTERINGS et al., 2001).

Conhecer a distribuição de biomassa acima do solo nas diferentes fitofisionomias do Cerrado é crucial para otimizar as estimativas nacionais de emissões de gases de efeito estufa e consolidar os projetos de Redução de Emissões por Desmatamento e Degradação Florestal (REDD+) no Brasil.

No entanto, poucos estudos de biomassa acima do solo são encontrados no Cerrado. De acordo com uma revisão bibliográfica realizada por Guimarães, (2020), nos estados da área core do Cerrado (DF, GO e TO) foram encontrados apenas 36 trabalhos. Nos estados mais próximos à borda do bioma foram encontrados 32 estudos, já nas “ilhas” de savana na região norte do Brasil foram apenas quatro, nos estados de AM, AP, PA e RR.

Além disso, a maioria dos poucos trabalhos que existem concentram-se na formação florestal, especificamente na fitofisionomia de Cerrado *sensu stricto*, ou seja, não contemplam toda variabilidade fisionômica e ambiental do bioma (CASTRO NEVES, 2007; CASTRO e KAUFFMAN, 1998; OLIVEIRA et al., 2019; OTTMAR et al., 2001; RIBEIRO et al., 2011). Além disso, consideram apenas a vegetação arbórea para estimar a biomassa, excluindo a biomassa dos demais estratos da vegetação, como a superficial, arbustiva e herbácea, que são uma parcela significativa e essenciais para avaliar o potencial máximo desses ecossistemas em sequestrar carbono.

Diante disso, é imprescindível desenvolver trabalhos que estabeleçam metodologias que propiciem a mensuração desses outros componentes (SILVEIRA et al., 2008). Para sanar as incertezas existentes referentes aos estoques da biomassa em cada estrato da vegetação e nas diferentes formações do Cerrado.

Muitas vezes a coleta de dados de campo em ambientes florestais é dificultada

em função do tempo, mão de obra, recursos financeiros disponíveis e obstáculos para acessar as áreas, tornando-a impraticável e cara para aplicar em estudos de grande escala e/ou recorrentes (MOHAN et al., 2017; GOLDBERGS et al., 2018; SILVA et al., 2020).

Existem duas formas de realizar a mensuração da biomassa, o método direto que normalmente depende da coleta destrutiva para a tomada das medidas de biomassa (GOLDBERGS et al., 2018), mas é o caminho mais preciso e direto, porém apresenta restrições por tempo, capital e trabalho, tornando inviável em grandes áreas, além de causar impactos no habitat local e no ecossistema (CASTRO; KAUFFMAN, 1998). O método indireto, por sua vez, quantifica a biomassa através de modelos matemáticos, com a utilização das características mensuradas na floresta (parâmetros estruturais) como altura e diâmetro das plantas (BEUKEMA et al., 1997; QURESHI et al., 2012; RIBEIRO et al., 2011).

Uma alternativa viável é realizar a mensuração em campo, e aliar à utilização de tecnologias de sensoriamento remoto, pois a integração de modelos matemáticos e medições indiretas através de dados de sensoriamento remoto são abordagens complementares para estimar biomassa acima do solo (QURESHI et al., 2012; RIBEIRO et al., 2011), de forma precisa (ROITMAN et al., 2018).

#### 1.2.6. LIDAR

Novas tecnologias de Sensoriamento Remoto têm sido utilizadas com intuito de minimizar problemas de mensuração, gerando informações com níveis de precisão aceitáveis (HOUGHTON, 2012; GONZÁLEZ-JARAMILLO; FRIES; BENDIX, 2019).

Os sensores ativos, aplicadas para o levantamento da biomassa florestal em nível de paisagem são atualmente o que há de melhor, pois, permitem uma estimativa confiável e possibilitam a produção de mapas de carga de combustível.

O Ligth Detection and Ranging (LiDAR) surgiu em 1963, com a combinação de radar + laser = LiDAR (RING, 1963). Três décadas depois, a tecnologia, tornou-se amplamente conhecida (CENTENO; MITISHITA, 2007).

O LiDAR é um sensor remoto ativo capaz de obter informações rápidas de alta resolução, precisas e com alto nível de confiança sobre a estrutura da vegetação (KNAPP

et al., 2020; REX et al., 2020). A coleta dados é feita pela emissão de sua própria luz, ou seja, não depende da presença de uma fonte de luz externa, como os sensores passivos e a análise dos dados não é prejudicada por sombras (WAGNER et al., 2004).

O seu funcionamento consiste na emissão de vários pulsos de laser na direção de uma superfície ou objeto, e ao atingir o alvo, onde parte do sinal emitido é refletido na direção do sensor instalado em uma plataforma fixa ou móvel (veículo automotor, aeronave ou sistema orbital - satélite ou estação espacial) (NASA, 2014; WANG et al., 2019; RAHMAN et al., 2022). O sensor mede a intensidade do sinal de retorno e o tempo decorrido entre a emissão e a captação do retorno, este tempo é utilizado para calcular a distância sensor-objeto (WAGNER et al., 2004). A posição tridimensional do ponto onde o feixe é refletido é determinada com base na distância entre o sensor e a superfície da terra e a orientação do feixe (BALTSAVIAS, 1999).

O sistema LiDAR utiliza ondas de comprimento que variam entre 1  $\mu\text{m}$  a 10 $\mu\text{m}$ , na região do espectro eletromagnético de ondas curtas (GIONGO et al., 2010). O registro contínuo das coordenadas espaciais dos retornos é feito com extrema precisão, e estes retornos constituem os elementos primários para a formação de uma nuvem de pontos que descreve o alvo imageado (GIONGO et al., 2010). Essas nuvens de pontos são de alta densidade (milhares de pontos por  $\text{m}^2$ ) (SAIRAM et al., 2016; RODRIGUEZ - GONZÁLVEZ, et al., 2017) e muito precisas (nível milimétrico) (WANG et al., 2019).

A primeira pesquisa utilizando LiDAR no setor florestal foi a de Nelson et al., (1984) que utilizou o sensor para determinar as características do dossel florestal do estado da Pensilvânia. Desde então vem sendo amplamente utilizado no setor, principalmente na região amazônica para fins de pesquisa e de manejo florestal (LOCKS; MATRICARDI, 2017; REX et al., 2018; QU et al., 2018; PAOLUCCI et al., 2019; D'OLIVEIRA et al., 2021).

Atualmente é utilizado para a estimativa de parâmetros estruturais das florestas, como altura das árvores, dimensões da copa, área basal, volume, composição florística, biomassa acima do solo (AGB) e estoque de carbono (D'OLIVEIRA et al., 2012; ANDERSEN et al., 2014; LOCKS e AMARAL, 2015; KENT et al., 2015; PINAGÉ et al., 2015; ELLIS et al., 2016; GOULAMOUSÈNE, 2017; AFEK, et al., 2017; CARVALHO et al., 2017; HAKKENBEG, 2017; MAO e HOU, 2018; RODIG et al.,

2018; DALAGNOL et al., 2019; OKUDA et al., 2019; PINAGÉ et al., 2019); D'OLIVEIRA et al., 2020; FISHER et al., 2020; GORGENS et al., 2020; PAPA, et al., 2020; REX, et al., 2020; YIN et al., 2020; ALMEIDA et al., 2021; D'OLIVEIRA et al., 2021; MAEDA et al., 2022).

Também tem sido utilizado para o inventário da biomassa florestal (HUDAK et al., 2012; LIM et al., 2004, NAESSET et al., (2008). O Serviço Florestal Norte-Americano vem aplicando essa tecnologia há alguns anos e obtendo bons resultados (HUDAK, et al., 2012; REUTEBUCH et al., 2003).

Alguns estudos utilizaram o LiDAR aerotransportado para estimar biomassa acima do solo (AGB) em florestas temperadas, boreais e tropicais (GIANNICO et al., 2016; MEYER et al., 2018; SHAO, et al., 2018; D'OLIVEIRA e LOCKS, 2019; RODRIGUES-VEIGA et al., 2019; WANG et al., 2019; OLIVEIRA et al., 2020). Pois, quando existem amostras de dados LiDAR disponíveis da mesma área é possível estimar biomassa, e validar com os dados de campo, produzindo, estimativas mais precisas da biomassa florestal do que sensores ópticos (GONZALEZ et al., 2010) e radar (ASNER et al., 2012), sem problemas de saturação (SANTOS et al., 2003).

Apesar da grande utilidade do LiDAR, sua aquisição ainda é cara (BREDE et al., 2017) e limitada em grandes áreas (OLIVEIRA et al., 2020). Porém, com o advento dos veículos aéreos não tripulados (VANT), e na busca por alternativas mais econômicas, esses sensores tornaram-se pequenos e leves o suficiente para serem acoplados em drones (ALMEIDA et al., 2021), se tornando aerotransportados (Airborne LiDAR System – ALS) e desenvolvendo-se no mercado florestal.

O LiDAR transportado por VANT é capaz de produzir nuvens de pontos com densidades altíssimas (100 a 1000 por m<sup>2</sup>), enquanto em LiDAR aéreo varia entre 0,4 e 30 pontos por m<sup>2</sup> (D'OLIVEIRA et al., 2020; PRATA et al., 2020). A alta densidade de pontos aumenta a precisão e exatidão da estimativa de parâmetros estruturais da floresta (ALMEIDA et al., 2019), que permite a individualização das árvores e estimativas diretas de altura e diâmetro (CORTE et al., 2020).

Embora o Lidar aerotransportado não ofereçam cobertura em nível global ou nacional, como os satélites, os benefícios dessas tecnologias incluem baixo custo material e operacional e possibilidade de flexibilizar a resolução espacial e temporal de acordo

com os requisitos estabelecidos pelo usuário (MLAMBO et al., 2017). O uso deles é uma alternativa promissora para estudos em nível de paisagem (< 1000 ha), pois, devido à menor altitude para obtenção dos dados, oferece vantagens em relação ao nível de detalhamento (resolução espacial de 5 a 15 cm) quando comparadas às imagens de satélite (resolução espacial de 2 a 30 metros) (KOH; WICH, 2012; SHIN et al., 2018).

Diante disso, existe o potencial do LiDAR em mapear biomassa acima do solo, em áreas savânicas como as do Cerrado. No entanto, pesquisas relacionadas ao mapeamento de carga de combustível, no Brasil, especialmente no bioma não existem, principalmente utilizando tecnologias de modelagem e sensoriamento remoto (LiDAR), e isso reflete em muitas incertezas, por isso, entender seu funcionamento é essencial e urgente para fornecer subsídios às decisões do Manejo Integrado do Fogo (MIF)

### **1.3. O PROBLEMA**

O Cerrado é um grande estoque de carbono através de sua biomassa, porém vem sendo ameaçado por atividades antrópicas e mudanças no ciclo do fogo. O aumento da frequência e abrangência da ocorrência do fogo no bioma tem causado o aumento dos impactos ambientais e a perda de remanescentes do ecossistema, especialmente dentro de Unidades de Conservação.

A quantificação de biomassa no Cerrado ainda é bastante defasada, e os poucos trabalhos de estimativas existentes no bioma não o considera com toda sua complexidade, pois levam em consideração apenas a biomassa das árvores, negligenciando compartimentos importantes como o arbustivo e o superficial, e as diferentes formações presentes no Cerrado (campestre, savana e floresta), que têm grande influência nos regimes de fogo e ciclos de carbono associados.

Diante disso, estudos voltados para estratégias inovadoras de estimativa de biomassa, são cruciais para desenvolver modelos climáticos precisos que possam apoiar decisões de Manejo Integrado do Fogo e definir estratégias de mercados de carbono e iniciativas de REDD+ globalmente.

Uma alternativa inovadora e viável é a unir dados coletados em campo com os dados de medições indiretas oriundas UAV-LiDAR, que é uma tecnologia que fornece caracterizações detalhadas e precisas da estrutura vegetal, e quando aliados, os dados se



complementam e apresentam potencial para estimar biomassa total acima do solo (AGBt) no Cerrado, e em suas formações.

Portanto, é crucial preencher a lacuna entre os fluxos globais de carbono e as estimativas atuais de biomassa no Cerrado, com o desenvolvimento de modelos que considerem as formações do bioma e também os componentes da biomassa que permanecem não contabilizados.

#### **1.4. QUESTÕES DE PESQUISA**

As seguintes questões de pesquisa nortearam o presente estudo:

1) Qual (is) o melhor (es) modelo(s) baseados em dados LiDAR e de levantamentos em campo para estimar com precisão a biomassa acima do solo (AGB) em UCs?

2) Quais variáveis medidas derivadas do sensor LiDAR apresentam maior correlação com os dados de (AGB) medidos em campo?

3) Quais as relações das variáveis LiDAR com a AGB em diferentes fitofisionomias de vegetação do Cerrado? Qual a precisão na estimativa da AGB a partir de dados LiDAR?

#### **1.5. OBJETIVOS**

##### **1.5.1. Objetivo Geral**

Assim a presente tese teve como objetivo avaliar a capacidade do UAV-lidar de alta densidade para estimar e mapear a biomassa total acima do solo (árvores, arbustos e camadas superficiais) (AGBt) no Cerrado brasileiro.

##### **1.5.2. Objetivo específicos**

Os objetivos específicos deste estudo são:

- Identificar as melhores métricas de UAV-lidar para construir modelos de AGBt;
- Selecionar os melhores modelos para prever AGBt;
- Estimar AGBt em nível de parcela;

- Mapear AGBt em nível de paisagem, avaliando sua distribuição espacial e incerteza nas principais formações vegetais do Cerrado: campestre, savanas e florestas.

## **1.6. HIPÓTESE**

A hipótese testada neste trabalho foi: É possível mapear AGBt no Cerrado com precisão satisfatória.

# CAPÍTULO 2 – ALÉM DAS ÁRVORES: MAPEANDO A BIOMASSA TOTAL ACIMA DO SOLO NO CERRADO BRASILEIRO USANDO DADOS DE LIDAR AEROTRANSPORTADO DE ALTA DENSIDADE

Artigo publicado na revista “Forest Ecology and Management”

<https://doi.org/10.1016/j.foreco.2021.119155>

Forest Ecology and Management 491 (2021) 119155



Contents lists available at ScienceDirect

Forest Ecology and Management

journal homepage: [www.elsevier.com/locate/foreco](http://www.elsevier.com/locate/foreco)



## Beyond trees: Mapping total aboveground biomass density in the Brazilian savanna using high-density UAV-lidar data

Máira Beatriz Teixeira da Costa<sup>a,\*</sup>, Carlos Alberto Silva<sup>b,c</sup>, Eben North Broadbent<sup>d</sup>, Rodrigo Vieira Leite<sup>e</sup>, Midhun Mohan<sup>f</sup>, Veraldo Liesenberg<sup>g</sup>, Jaz Stoddart<sup>h</sup>, Cibele Hummel do Amaral<sup>e</sup>, Danilo Roberti Alves de Almeida<sup>i</sup>, Anne Laura da Silva<sup>j</sup>, Lucas Ruggeri Ré Y. Goya<sup>j</sup>, Victor Almeida Cordeiro<sup>j</sup>, Franciel Rex<sup>k</sup>, Andre Hirsch<sup>j</sup>, Gustavo Eduardo Marcatti<sup>j</sup>, Adrian Cardil<sup>l,m,n</sup>, Bruno Araujo Furtado de Mendonça<sup>o</sup>, Caio Hamamura<sup>p</sup>, Ana Paula Dalla Corte<sup>k</sup>, Eraldo Aparecido Trondoli Matricardi<sup>a</sup>, Andrew T. Hudak<sup>q</sup>, Angelica Maria Almeyda Zambrano<sup>r</sup>, Ruben Valbuena<sup>h</sup>, Bruno Lopes de Faria<sup>s,t</sup>, Celso H.L. Silva Junior<sup>u,v</sup>, Luiz Aragao<sup>u</sup>, Manuel Eduardo Ferreira<sup>w</sup>, Jingjing Liang<sup>x</sup>, Samuel de Pádua Chaves e Carvalho<sup>y</sup>, Carine Klauberg<sup>j</sup>

<sup>a</sup> Department of Forestry, University of Brasília, Campus Darcy Ribeiro, Brasília 70.910-900, Brazil

<sup>b</sup> School of Forest, Fisheries, and Geomatics Sciences, University of Florida, PO Box 110410, Gainesville, FL 32611, USA

<sup>c</sup> Department of Geographical Sciences, University of Maryland, College Park, MD 20740, USA

<sup>d</sup> Spatial Ecology and Conservation (SPEC) Lab, School of Forest, Fisheries, and Geomatics Sciences, University of Florida, Gainesville, FL 32611, USA

<sup>e</sup> Department of Forest Engineering, Federal University of Viçosa (UFV), Viçosa, MG, Brazil

<sup>f</sup> Department of Geography, University of California—Berkeley, Berkeley, CA 94709, USA

<sup>g</sup> Department of Forest Engineering, College of Agriculture and Veterinary, Santa Catarina State University (UDESC), Lages, SC, Brazil

<sup>h</sup> School of Natural Sciences, Bangor University, Bangor LL57 2W, UK

<sup>i</sup> Department of Forest Sciences, “Luís de Queiroz” College of Agriculture, University of São Paulo (USP/ESALQ), Piracicaba, SP, Brazil

<sup>j</sup> Federal University of São João del-Rei – UFSJ, Sete Lagoas, MG 35701-970, Brazil

<sup>k</sup> Department of Forest Engineering, Federal University of Paraná (UFPR), Curitiba, PR, Brazil

<sup>l</sup> Technosylva Inc, La Jolla, CA, USA

<sup>m</sup> Department of Crop and Forest Sciences, University of Lleida, Lleida, Spain

<sup>n</sup> Joint Research Unit CTFC - AGROTECNIO, Solsona, Spain

<sup>o</sup> Departamento de Silvicultura, Universidade Federal Rural do Rio de Janeiro, Rua da Floresta, Seropédica, RJ 23897-005, Brazil

<sup>p</sup> Federal Institute of Education, Science and Technology of São Paulo, SP, 11533-160, Brazil

<sup>q</sup> US Department of Agriculture, Forest Service, Rocky Mountain Research Station, 1221 South Main Street, Moscow, ID 83843, USA

<sup>r</sup> Spatial Ecology and Conservation (SPEC) Lab, Center for Latin American Studies, University of Florida, Gainesville, FL 32611 USA

<sup>s</sup> Federal Institute of Technology North of Minas Gerais (FNMIG), 39100-000, Diamantina, MG, Brazil

<sup>t</sup> Department of Forest Science, Federal University of Vales do Jequitinhonha e Mucuri, (UFVJM) Campus JK, Diamantina, MG, Brazil

<sup>u</sup> National Institute for Space Research (INPE), Earth Observation and Geoinformatics Division, Av. dos Astronautas, 1758, São José dos Campos, SP 12227-010, Brazil

<sup>v</sup> Image Processing and GIS Lab (LAPIG), Universidade Federal de Goiás, 74001-970 Goiânia, GO, Brazil

<sup>w</sup> Universidade Estadual do Maranhão (UEMA), Departamento de Engenharia Agrícola, São Luís, MA 65055-310, Brazil

<sup>x</sup> Department of Forestry and Natural Resources, Purdue University, West Lafayette, IN, USA

<sup>y</sup> College of Forestry, Federal University of Mato Grosso, Av. Fernando Correa da Costa, 2367, Boa Esperança, Cuiabá, MT 78060-900, Brazil

## **HIGHLIGHTS**

- UAV-lidar coleta dados sensíveis à estrutura da vegetação na savana tropical.
- Primeiro estudo para mapear a biomassa aérea total (AGBt) com UAV-lidar no Cerrado.
- Além da biomassa arbórea, o AGBt inclui camadas superficiais de vegetação e arbustos.
- Altura e cobertura do dossel são as métricas UAV-lidar mais eficazes para mapear AGBt no Cerrado.
- A incerteza da AGBt foi menor na floresta e na savana do que nas formações de campestre.
- O estudo é um passo à frente no uso de UAV-lidar para mapeamento de AGBt em ecossistemas de savana tropical.

## 2.1. INTRODUÇÃO

Os ecossistemas de savana tropical ocupam aproximadamente 20% da superfície terrestre da Terra e são reconhecidos globalmente por sua riqueza de espécies e biodiversidade endêmica (SIMON et al., 2009). Esses ecossistemas, são caracterizados por um gradiente de formações vegetais: Campestre, savanas e florestas. Os incêndios florestais são um elemento importante da savana tropical, mas os regimes naturais de fogo foram alterados por atividades antrópicas e mudanças climáticas (PIVELLO, 2011; REICHSTEIN et al., 2013). As savanas tropicais desempenham um papel importante no balanço global de carbono (POULTER et al., 2014), mas sua capacidade de armazenar e sequestrar carbono, bem como os impactos combinados de seus regimes de fogo e a dinâmica da vegetação nos balanços globais de carbono ainda são amplamente desconhecidos (VAN DER WERF et al., 2010; PUGH et al. 2019; DUVERT et al., 2020; LASSLOP et al., 2020).

A savana brasileira, conhecida como Cerrado, é o segundo maior tipo de habitat da América do Sul, depois do bioma Amazônia, abrangendo dois milhões de km<sup>2</sup> (23,3% do território brasileiro) (SILVA e BATES, 2002; BONANOMI et al., 2019). O Cerrado é considerado um hotspot para a biodiversidade e desempenha um papel importante na mitigação das mudanças climáticas e do aquecimento global, armazenando carbono na biomassa local (RIBEIRO et al., 2011). No entanto, o Cerrado está severamente ameaçado pelo aumento das atividades antrópicas e mudanças causadas pelo homem no regime de fogo (DURIGAN e RATTER, 2016). Entre 2002 e 2010, foram queimadas 545.000 km<sup>2</sup> de área no Cerrado, o que representa aproximadamente 73% da área total queimada no Brasil (ARAÚJO et al., 2012). Assim, o fogo molda fortemente a vegetação e os ecótonos nas savanas (HIROTA et al. 2011; STAVER et al. 2011). Ao alterar a estrutura da vegetação, os incêndios também podem induzir efeitos em cascata que alteram a qualidade do habitat para a fauna (LINDENMAYER et al., 2008).

Quase metade do Cerrado foi perdido nas últimas décadas (SOUZA et al., 2020), e as áreas remanescentes enfrentam ameaças ambientais contínuas com o resultado da expansão da produção agrícola para suprir a crescente demanda global de alimentos. Estratégias de monitoramento inovadoras para entender a configuração da paisagem dos estoques de biomassa e suas mudanças são necessárias no Cerrado, para desenvolver dinâmicas preditivas de vegetação e modelos climáticos precisos que possam apoiar decisões e informar os formuladores de políticas para definir estratégias de mercados de carbono e

iniciativas de REDD+ globalmente. Além disso, essas estratégias são cruciais para melhorar as técnicas de manejo de incêndios florestais que podem contribuir para a manutenção dos valores ecológicos em savanas tropicais (RIBEIRO et al., 2011; FRANKE et al., 2018; LEVICK et al., 2018; DURIGAN et al., 2020). Dado o grande gradiente latitudinal e a alta variabilidade ambiental, estrutural e inter e intraespécies dentro do bioma Cerrado, a coleta de dados requer tempo e trabalho de campo intensivo (OTTMAR et al., 2001; GWENZI e LEFSKY, 2016; ROITMAN et al., 2018). Embora os dados de campo forneçam as estimativas mais precisas e diretas, as coletas de dados de campo são limitadas pelo tempo, custo financeiro e mão de obra, tornando-os impraticáveis e caros para aplicar em estudos de grande escala e/ou recorrentes (MOHAN et al., 2017; GOLDBERGS et al., 2018; SILVA et al., 2020). Além disso, a estimativa direta de biomassa requer amostragem destrutiva que causa alguns impactos no habitat e ecossistema local. A integração de modelos matemáticos e medições indiretas usando dados de sensoriamento remoto fornecem abordagens complementares para estimar biomassa e outras variáveis físicas (QURESHI et al., 2012; RIBEIRO et al., 2017).

Entre as tecnologias de sensoriamento remoto disponíveis, a detecção e alcance de luz (lidar) ganhou destaque nas últimas décadas devido à sua capacidade de fornecer caracterizações detalhadas e precisas da estrutura vertical da vegetação em ecossistemas de savana tropical (GWENZI e LEFSKY, 2016; LEVICK et al., 2018; GOLDBERGS et al., 2018; ZIMBRES et al., 2020). Essas avaliações estruturais tridimensionais podem ser realizadas por plataformas espaciais (SLS), aerotransportadas (ALS) ou terrestres de varredura a laser (TLS), embora o último seja limitado pelas pegadas espaciais limitadas e, portanto, não é diretamente aplicável para estudos em larga escala (FERREIRA et al., 2012; RIBEIRO et al., 2017; SILVA et al., 2018; LUCK et al., 2020; VALBUENA et al., 2020; ZIMBRES et al., 2020; SINGH et al., 2021). O advento dos veículos aéreos não tripulados (UAVs) expandiu ainda mais os recursos do lidar aéreo, pois o UAV-lidar é uma solução de fácil implementação e custo-benefício que preenche a lacuna de escala entre as coleções ALS e TLS e melhora a precisão de saídas, como árvores altura, densidade de área foliar e biomassa (WANG et al., 2019; ALMEIDA et al., 2020; DALLA CORTE et al., 2020; HARKEL et al., 2020; SHENDRYK et al., 2020).

Apesar do potencial demonstrado do lidar em estimar biomassa em escalas de paisagem e regional por estudos anteriores (DRAKE et al., 2002; NAESSET e GOBAKKEN, 2008; HUDAK et al., 2020), eles ainda são raramente implementados em

savanas tropicais. Além disso, a maioria dos estudos empreendidos colocou seu foco principal apenas na estimativa de biomassa de árvores, usando ALS e TLS (por exemplo, BISPO et al. 2020; ZIMBRES et al., 2020), ou as recentes missões SLS, como NASA Global Ecosystem Dynamics Investigation (GEDI) (DUBAYAH et al. 2020; MARSELIS et al. 2019; MARSELIS et al. 2020). Os poucos estudos que se aventuraram em estimar componentes individuais da biomassa limitaram seu alcance com a avaliação das contribuições de biomassa de estratos de árvores, como folhas, galhos e caules (GARCÍA et al. 2010; SILVA et al. 2014; HERNANDO et al., 2017; SCARANELLO et al. 2019). No entanto, uma parcela significativa da biomassa total acima do solo na savana tropical é composta de biomassa superficial (serrapilheira, material lenhoso abatido, arbusto e herbáceo), que não são levados em consideração pelos estudos anteriores. Estes, no entanto, têm grande influência nos regimes de fogo e ciclos de carbono associados (PIVELLO, 2011). Portanto, é crucial preencher a lacuna entre os fluxos globais de carbono e as estimativas atuais de sensoriamento remoto de biomassa em ecossistemas terrestres, com o desenvolvimento de modelos que considerem grandes componentes da biomassa do ecossistema que permanecem não contabilizados quando apenas a biomassa de árvores lenhosas é considerada. (DASS et al., 2018).

Embora o lidar tenha se mostrado benéfico para capturar as estruturas tridimensionais da vegetação em ecossistemas de savana (ANDERSON et al., 2018; BISPO et al. 2020; ZIMBRES et al., 2020), há a necessidade de desenvolver uma estrutura para mapeamento de biomassa total acima do solo (AGBt) (superficial, lenhosa e arbustiva) e avaliar a aplicabilidade de UAV-lidar para estimar e mapear AGBt em ecossistemas de savana tropical. Este estudo teve como objetivo avaliar a capacidade do UAV-lidar de alta densidade para estimar e mapear AGBt em formações vegetais estruturalmente complexas do Cerrado no Brasil. Aqui, desenvolvemos uma estrutura para: (i) selecionar as melhores métricas de UAV-lidar para construir modelos de AGBt; (ii) selecionar os melhores modelos para prever AGBt; (iii) estimar AGBt em nível de parcela; e (iv) mapear AGBt em nível de paisagem, avaliando sua distribuição espacial e incerteza nas principais formações vegetais do Cerrado: campestre, savanas e florestas. Dada a precisão do nível de recurso disponível por meio do UAV-lidar de alta densidade (WILKINSON et al., 2019), hipotetizamos que seria possível mapear AGBt no Cerrado em um nível satisfatório de precisão, e esperamos identificar desafios tecnológicos específicos do bioma, que precisam ser enfrentados para aprofundar nossa compreensão nas complexidades existentes no ecossistema e no avanço

dos paradigmas de gerenciamento de carbono. Como não existem outros estudos baseados em UAV lidar sobre estimativas de densidades totais de AGB para o bioma Cerrado, este trabalho pretende servir como referência para estudos futuros e deve ajudar a gerar mapas AGBt consistentes, mesmo quando o clima e o ambiente mudarem.

## **2.2. MATERIAL E MÉTODOS**

### **2.2.1. ÁREA DE ESTUDO**

Nossos locais de estudo estão localizados no Parque Nacional da Serra do Cipó (PNSC), Parque Nacional da Chapada dos Veadeiros (PNCV), Floresta Nacional de Paraopeba (FNP), e Floresta da Universidade São João Del-Rei (UFSJ) (Figura 1).

O PNSC (19°12'-34'S,43°27'-38'O) está localizada na porção sudeste do bioma Cerrado, estado de Minas Gerais. O clima da região é mesotérmico, Cwb (subtropical de altitude) segundo a classificação de Köppen (ALVARES et al., 2013), com invernos secos e verões chuvosos, e a média anual de precipitação acumulada é de 1.400 mm, com estação chuvosa ocorrendo entre outubro e março, e precipitação mensal variando de 75 a 340 milímetros (ALVARADO et al., 2017). A temperatura média anual varia de 17,0° a 18,5°C. A topografia do local de estudo é acidentada e predominantemente montanhosa, com elevações variando de 750 a 1.670 m acima do nível do mar (RIBEIRO e FIGUEIRA, 2017). A vegetação no PNSC varia e compreende diferentes fisionomias, desde campos abertos (“Campo Limpo”) em altitudes abaixo de 1.000 m até formações de savana com diferentes proporções de cobertura lenhosa (“Campo Sujo”, “Campo Cerrado” e “Cerrado sensu stricto”) e formações florestais (“Cerradão”), todas classificadas como parte do Cerrado sensu lato (OLIVEIRA-FILHO e RATTER, 2002); acima de 1.000 m encontram-se os campos rupestres (BENITES et al., 2003). Os solos são diversos e variam de acordo com as formações vegetais, sendo determinados pela topografia local e aspectos microambientais; na savana e floresta, existem latossolos e cambissolos, enquanto nos campos rupestres ocorrem neossolos litólicos e espodossolos (SCHAEFER et al., 2016).

O PNCV (13°51'-14°10'S, 47°25'-42'W) abrange cinco municípios do Estado de Goiás, Brasil. Dentro de uma região montanhosa, a altitude no PNCV varia de 620 a 1.700 m de altitude, e o clima é caracterizado como tropical e subúmido (Aw) (ALVARES et al., 2013). As temperaturas médias variam a partir de 20° a 26°C (SILVA et al., 2001). A



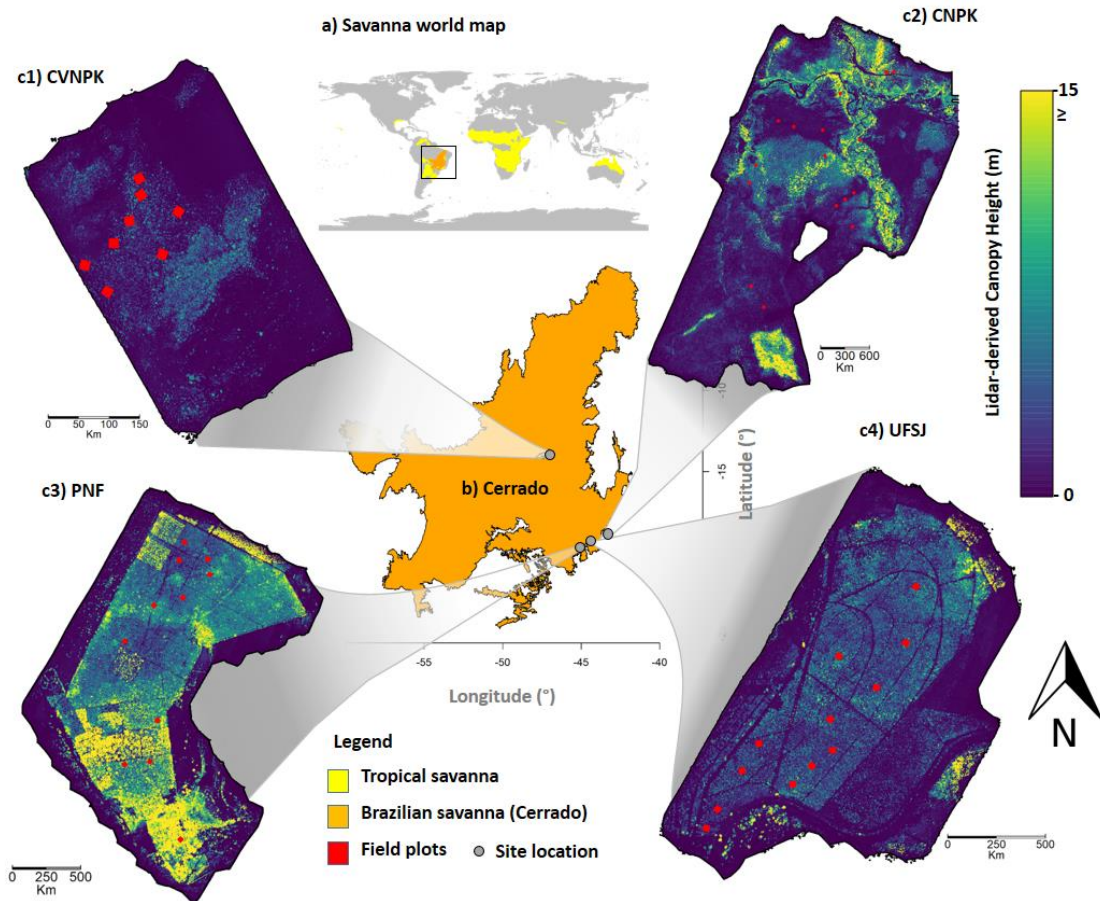
paisagem é formada por mosaicos de diferentes tipos de vegetação (RIBEIRO e WALTER, 2008) caracterizada pela predominância de savanas nas cotas altas e formação florestal nas cotas baixas (FELFILI et al. 2007). Formações campestres secas e úmidas e as savanas cobrem a maior parte da paisagem e ocorrem entre os riachos. Florestas decíduas secas são encontradas na borda noroeste do parque, enquanto as florestas perenes ribeirinhas são mais comum na borda sudoeste (FLORES et al., 2020). No total, o PNCV apresenta 77% de formação de savana, e cerca de 10% correspondem aos fragmentos florestais (PORTO et al., 2011). Cambissolos e neossolos litólicos ocupam a maior área do parque (IBAMA, 1998).

A FNP (19° 20'S e 44° 20'W) está localizada no município de Paraopeba, estado de Minas Gerais, Brasil. Possui 150 hectares remanescentes de vegetação de Cerrado, incluindo tanto Cerrado (por exemplo, Cerrado sensu stricto) e formações florestais (por exemplo, Cerradão) (NERI et al., 2013). A altitude em FN varia de 734 a 750 m de altitude, e o clima é caracterizado pelo tipo subtropical úmido (Cfa) (ÁLVAREZ et al. 2013), com um verão chuvoso de janeiro a março e uma estação seca ocorre de abril a setembro, atingindo uma precipitação média anual de 1.236 mm (BALDWIN et al., 2005). Os solos variam de Latossolos (vermelho, vermelho-amarelo e amarelo) a Cambissolos e Neossolos Flúvicos (NERI et al., 2013).

A floresta da UFSJ (19°28'S, 44°11'W) está localizada no município de Sete Lagoas, estado de Minas Gerais, Brasil, a uma altitude que varia de 742 a 815 m. O clima local é considerado tropical de altitude (Cwa) (ALVARES et al., 2013), com inverno seco bem definido e verão chuvoso. A temperatura média anual é de 21,73°C e a precipitação média anual é de 1.330 mm (GUIMARÃES e RIOS, 2010). O tipo de vegetação predominante é o Cerrado sensu stricto caracterizada pela dominância de árvores com arbustos dispersos e sub-bosque de grama. O clima é do tipo subtropical úmido, com inverno seco e verão moderadamente quente (ALVARES et al., 2013). Os solos são predominantemente Latossolos (Latossolos Vermelhos e Latossolos Vermelho-Amarelos).

Ao todo, nossos quatro locais de estudo compreendem várias fisionomias de vegetação de Cerrado que representam uma ampla variedade em estruturas florestais verticais e horizontais, e também em diversidade de espécies e procedentes. Classificamos a vegetação de nossos locais de estudo em três grandes formações de acordo com Ribeiro e Walter (2008) e definidos como: (i) Campestre, predominantemente representadas por uma camada arbustivo-herbácea com ausência ou com indivíduos arbustivos esparsos aleatórios;

(ii) savanas, que apresentam uma camada arbustivo-herbácea contínua e uma camada arbórea descontínua que varia em densidade e nunca fecha completamente; e (iii) florestas, principalmente representado por uma camada contínua de árvores, mas também estruturalmente diversa como resultado da divisão das comunidades de espécies em diferentes condições ambientais (Figura 1).



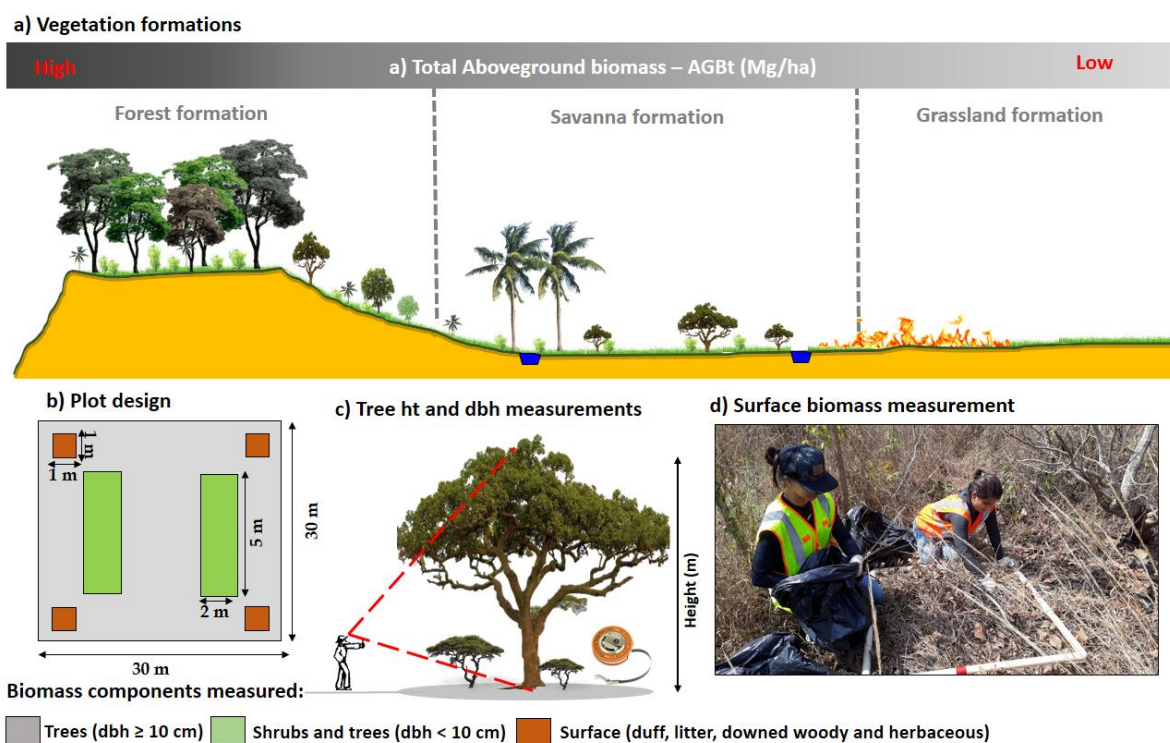
**Figura 1.** Mapa do modelo de altura do dossel derivado de UAV-lidar dentro da área de estudo no Cerrado brasileiro. Parque Nacional Serra do Cipó (PNSC), Parque Nacional Chapada dos Veadeiros (PNCV), Floresta Nacional de Paraopeba (FNP), e Floresta da Universidade de São João Del-Rei (UFSJ).

### 2.2.2. MENSURAÇÃO NO CAMPO

Parcelas de campo de  $30 \times 30$  m ( $900 \text{ m}^2$ ) cobrindo todas as formações de Cerrado (Fig. 2) foram estabelecidas entre junho e julho de 2019 para medir a biomassa aérea total da vegetação (AGBt). Os cantos das parcelas foram registrados usando um Sistema de Satélite de Navegação Global Diferencial (DGNSS). A densidade da biomassa acima do solo das árvores (AGB árvores, em  $\text{Mg}/\text{ha}$ ) foi determinado a partir de medições de todas as árvores individuais dentro da parcela com diâmetro à altura do peito (DAP, em cm)  $\geq 10$  cm.

Cada árvore foi identificada taxonomicamente, e suas alturas (ht, em m) e DAP foram medidas usando um clinômetro e trena, respectivamente.

Dentro de cada parcela foram estabelecidas duas subparcelas de  $2 \times 5$  m para determinar a biomassa acima do solo de arbustos e pequenas árvores (DAP < 10 cm) (AGB arbustiva, em Mg/ha). Para cada parcela, quatro subparcelas de  $1 \times 1$  m foram estabelecidas para determinar a biomassa acima do solo da vegetação superficial (AGB superficial, em Mg/ha). O AGBt foi calculado como a soma dos componentes de densidade de biomassa (em Mg/ha) medidos dentro cada parcela e sub-parcelas, tendo cada componente sido transformado em densidades totais de biomassa (em Mg/ha) usando seus correspondentes fatores de expansão de hectares (HEF).



**Figura 2.** Ilustração da coleta de dados de campo. a) formação do Cerrado, b) desenho de parcelas e subparcelas de campo para medição da biomassa total acima do solo (AGBt), e c) medições de DAP e altura das árvores, d) medição de biomassa superficial.

A biomassa seca individual da árvore foi estimada usando a equação de alometria publicada calibrada (Eq. 1) com base em DAP, ht e informações de densidade da madeira ( $\rho$ ) (CHAVE et al., 2014). A densidade total de biomassa seca das árvores (AGB<sub>árvores</sub>, em Mg/ha) foi calculado somando a biomassa individual da árvore ao nível da parcela (Eq. 2):

$$AGB_{\text{árvores}_i} = 0.0673 \times (\rho \times dbh_i^2 \times ht_i)^{0.976} \quad (\text{Eq.1})$$

$$AGB_{\text{árvores}} = \sum_{i=1}^n AGB_{\text{árvores}_i} \times HEF_{\text{árvores}} \quad (\text{Eq.2})$$

Onde: dbh está em cm, ht está em m e  $\rho$  está em  $\text{g.cm}^{-3}$ .  $AGB_{\text{Árvores}}$  representa a densidade total de biomassa seca de árvores no nível da parcela,  $AGB_{\text{árvores}_i}$  representa biomassa seca (em kg) por árvore  $i$ , e  $n$  representa o número de árvores para cada gráfico  $i$ , e  $HEF_{\text{Árvores}} = 0,011$ . Os valores de densidade da madeira  $\rho$  foram derivados de Zanne et al. (2009).

Para medir o estoque de AGB arbustiva nas subparcelas de arbustos de  $2 \text{ m} \times 5 \text{ m}$ , colhemos todos os arbustos e pequenas árvores e os pesamos em uma balança de precisão de 10 g. Foram retiradas três amostras de  $\cong 500 \text{ g}$  por subparcela contendo os componentes arbustivo e arbóreo (caules, galhos e folhas) que foram enviados ao laboratório para medir os pesos de biomassa úmida (BU, em g) e biomassa seca (BS, em g). Os valores médios de BU e BS foram usados para calcular o teor de umidade ( $MC_i$ , em %) para cada subparcela, de acordo com Eq. (3).

A densidade total de arbustos secos e árvores pequenas ( $AGB_{\text{arbustiva}}$ , em Mg/ ha) foi então calculado como:

$$MC_i = \frac{BU_i - BS_i}{BU_i} \quad (\text{Eq.3})$$

$$AGB_{\text{arbustiva}} = \sum_{i=1}^n AGB_{\text{arbustiva}_i} \times HEF_{\text{arbustiva}} \times (1 - MC_i) \quad (\text{Eq.4})$$

Onde:  $AGB_{\text{arbustiva}}$  é a densidade de biomassa de arbustos secos e árvores pequenas na parcela,  $AGB_{\text{arbustiva}_i}$  é a biomassa de arbustos úmidos e pequenas árvores para a subparcela  $i$  (em kg),  $MC_i$  é o teor de umidade calculado para cada subparcela, e  $HEF_{\text{arbustiva}} = 1$ .

Para calcular a AGB superficial no nível da parcela, no campo, coletamos e pesamos a biomassa (duff, serapilheira, material lenhoso derrubado e material herbáceo) encontrado dentro das subparcelas de  $1 \text{ m} \times 1 \text{ m}$ . Novamente, três amostras de  $\cong 500 \text{ gramas}$  também foram coletadas e encaminhadas ao laboratório para o cálculo do  $MC_i$  para a biomassa de superfície (Eq. 3). A densidade total de biomassa da superfície seca ( $AGB_{\text{superficial}}$ , em Mg/ha) foi então calculado como:

$$AGB_{\text{superficial}} = \sum_{i=1}^n AGB_{\text{superficial } i} \times HEF_{\text{superficial}} \times (1-MC_i) \quad (\text{Eq. 5})$$

Onde:  $AGB_{\text{superficial}}$  é a biomassa da superfície seca no nível da parcela, e  $AGB_{\text{superficial}-i}$  é a biomassa da superfície úmida para a subparcela  $i$  (em kg),  $MC_i$  é o teor de umidade calculado para cada subparcela, e  $HEFSB_{\text{superficial}} = 2,5$ .

Finalmente, a densidade total de biomassa seca acima do solo ( $AGB_t$ , em Mg/ha) no nível da parcela foi então calculado pela soma do  $AGB$  árvores,  $AGB$  arbustiva e medições de  $AGB$  superficial (Eq. 6).

$$AGB_t = AGB_{\text{árvores}} + AGB_{\text{arbustiva}} + AGB_{\text{superficial}} \quad (\text{Eq.6})$$

O resumo de  $AGB_t$  dentro de todas as parcelas de campo e estratificado pelas formações de Cerrado são apresentadas na Tabela 1.

**Tabela 1.** Resumo da densidade total de biomassa total acima do solo ( $AGB_t$ ) dentro de nossas parcelas de campo e estratificada por formações de Cerrado.

Formação de Cerrado	Número de parcelas	AGBt (Mg/ha)			
		min	máximo	média	SD
Campestre	5	11,65	25,86	17,19	7,30
Savana	30	13,32	100,22	40,39	23,55
Floresta	15	43,68	187,94	104,21	42,39

### 2.2.3. UAV-LIDAR

Nossos locais de estudo foram escaneados usando o GatorEye UAV-lidar sistema (Fig. 3) (ALMEIDA et al., 2020; PRATA et al., 2020; DALLA CORTE et al., 2020) durante duas semanas no mês de julho de 2019, quase simultaneamente com a coleta de dados de campo. O GatorEye usa o Planform DJI M600 Pro montado com um Phoenix Scout Ultranúcleo para integrar lidar com uma unidade de movimento inercial (Novatel STIM

300), e diferencial de precisão cm Sistema GNSS, que têm um peso combinado de aproximadamente 4,5 kg.


O sensor LiDAR, que foi usado exclusivamente neste estudo, foi um Velodyne VLP-32c scanner a laser de retorno duplo que possui um total de 32 lasers separados, cada um com um campo de visão vertical de 360° (FOV) e que são distribuídos para permitir uma visão instantânea de 40° ao longo da trilha. O conjunto de laser emite um total de 600.000 pulsos por segundo e um número de retorno teórico de 1.200.000 por segundo, que durante o voo com um FOV transversal de 120° cria aproximadamente 350.000 retornos por segundo, com o restante saindo do alcance.

Um receptor GNSS da estação base terrestre X900S-OPUS coletou dados GNSS estáticos, que foram usados para calcular uma trajetória de voo PPK (cinemática pós-processada) usando o Novatel software Inercial Explorador. A precisão do ponto absoluto foi testada usando pontos de controles DGNSS com levantamento terrestre, e foi aceito quando apresentou erro quadrático médio (RMSE; eq. 10) abaixo de 5 cm (WILKINSON et al., 2019). Informações detalhadas e downloads de dados podem ser encontrados no site GatorEye ([www.gatoreye.org](http://www.gatoreye.org)) (BROADBENT et al., 2020; OLIVEIRA et al., (2020)).

O voo autônomo foi programado para pesquisa a uma velocidade média de 14 m/s em torno 100 m acima do nível do solo, com linhas de voo espaçadas de 100 m de distância. No total, nos quatro locais de estudo, voamos aproximadamente 600 km de linhas de voo cobrindo 1.854 hectares, que, até onde sabemos, é a maior área de UAV-lidar usada em uma publicação (até 16/12/20). As nuvens de pontos finais mescladas tinham cerca de 100 GB de tamanho total e uma densidade muito alta de aproximadamente 450 pontos/m<sup>2</sup> em todos os locais de estudo.

Os dados de nuvem de pontos 3-D UAV-lidar foram processados usando o fluxo de trabalho de pós-processamento multiescalar GatorEye, seguido de alinhamento adicional da linha de voo usando o software Bayes StripAlign, conforme descrito em detalhes em Broadbent et al. (2020). As nuvens de pontos elípticas finais mescladas foram posteriormente processadas usando Lastools (ISENBURG, 2020). Primeiramente, os arquivos las foram divididos em ladrilhos de 200 m para classificação dos retornos do terreno via lasground (pico: 1 m, protuberância: 0,5 m, degrau: 10 m, deslocamento: 0,05 m). Modelos digitais de terreno (DTM) foram criados com uma resolução espacial de 1 m via o

blast2dem e usado para normalizar a nuvem de pontos 3-D para altura. A ferramenta Lasclip foi usada para recortar a nuvem de pontos dentro das parcelas de campo, e a ferramenta lascanopy foi aplicada para calcular um conjunto de métricas lidar por parcela e para toda a cobertura lidar como as camadas de grade com uma resolução espacial de 30 m (ver Tabela 2).



**Figura 3.** Sistema GatorEye UAV-lidar. a) Sistema GatorEye UFL (Gen 1), com Phoenix Scout Ultra, sensores hiperespectrais e visuais em uma fuselagem DJI M600 Pro; b) Antenas GNSS para navegação (três) e trajetória de sensores (meio); e c) Velodyne Ultra Puck (sistema lidar).

**Tabela 2.** Métricas derivadas de UAV-lidar.

Classe	Métricas	Descrição
Altura	HMEAN	Altura média
	HMAX	Altura máxima
	HSD	Desvio padrão de altura
	HKUR	Curtose Altura
	HSCE	Altura distorcida
	CASA	Altura da Energia Mediana
	H25TH	Altura percentil 25
	H50TH	Altura percentil 50
	H70TH	Altura percentil 70

	H75TH	Altura percentil 75
	H80TH	Altura percentil 80
	H85TH	Altura percentil 85
	H90TH	Altura percentil 90
	H95TH	Altura percentil 95
	H98TH	Altura percentil 98
	H99TH	Altura percentil 99
<b>cobertura</b>	COV	Cobertura

#### 2.2.4. DESENVOLVIMENTO E AVALIAÇÃO DA MODELAGEM

Nossa estrutura de modelagem foi baseada em modelos de regressão linear (Eq. 7) e foram ajustados usando o estimador de mínimos quadrados ordinários (OLS) (Eq. 8). Em que, uma família de cinco modelos foi desenvolvida em duas etapas, primeiro removendo as métricas altamente correlacionadas e, em segundo selecionando os melhores modelos usando os subconjuntos de preditores (HUDAK et al., 2006; SILVA et al., 2014).

Inicialmente, a correlação de Pearson ( $r$ ) foi usada para identificar e excluir variáveis altamente correlacionadas usando um limiar de  $\pm 0,9$ . Posteriormente, aplicamos um algoritmo exaustivo de seleção de variáveis para encontrar os melhores modelos lineares com até seis preditores usando a função `regsubsets` do pacote R (HUDAK et al., 2006; LUMLEY, 2020). Os modelos lineares foram ajustados usando a transformação de logaritmo natural da AGBt como resposta e as métricas derivadas de lidar não correlacionadas como variáveis preditoras. A heterocedasticidade e a normalidade dos resíduos do modelo foram testadas com o Breusch-Pagan (BREUSCH e PAGAN, 1979) e SHAPIRO-WILK (SHAPIRO e WILK, 1965) ao nível de significância de 0,05.

$$Y_S = X_S\beta + \varepsilon_S \quad (\text{Eq. 7})$$

Onde:  $Y_S$  é o vetor de coluna de comprimento da variável de resposta AGBt na amostra  $S$ ;  $X_S$  é uma matriz  $n \times (p + 1)$  das métricas lidar usadas como preditores e um vetor unitário como primeira coluna;  $\beta$  é um vetor coluna de parâmetros do modelo de comprimento  $(p + 1)$ ;  $\varepsilon_S$  é o vetor coluna de comprimento  $n$  de erros aleatórios com  $E(\varepsilon_S) = 0$  e  $e\varepsilon_i \sim N(0, \sigma^2\varepsilon)$ .



Usando a amostra S de  $n = 50$  parcelas, o vetor de parâmetros do modelo foi estimado para cada modelo como:

$$\hat{\beta}_S = (X_S^T X_S)^{-1} X_S^T Y_S \quad (\text{Eq. 8})$$

Onde:  $\beta_S$  é um vetor de coluna de interceptação de modelo estimado e parâmetros com comprimento  $(p + 1)$ , e  $p$  é o número de preditores.

Calculamos o coeficiente de determinação ajustado ( $adjR^2$ ) e o erro quadrático médio absoluto e relativo (RMSE e %RMSE, respectivamente), e as diferenças médias absolutas e relativas (%MD), entre os valores AGBt estimados e observados (Eqs. 9–13) para avaliar o desempenho dos modelos. Os modelos foram classificados usando o critério de Akaike corrigido (AICc, Eq. 14) (SUGIURA, 1978; HUDAK e outros, 2006). O AICc pode ser aplicado quando o número de observações é relativamente pequeno ( $n/p < 40$ ) e calcula uma penalização adicional para o número de parâmetros do AIC (AKAIKE, 1979).

$$adjR^2 = 1 - \frac{(1 - R^2)(n-1)}{n - p - 1} \quad (\text{Eq. 9})$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (\hat{Y}_i - Y_i)^2}{n}} \quad (\text{Eq. 10})$$

$$\%RMSE = \frac{RMSE}{\underline{Y}} \times 100 \quad (\text{Eq. 11})$$

$$MD = \frac{\sum_{i=1}^n (\hat{Y}_i - Y_i)}{n} \quad (\text{Eq. 12})$$

$$\%MD = \frac{MD}{\underline{Y}} \times 100 \quad (\text{Eq. 13})$$

$$AICc = AIC + 2p \frac{(p+1)}{(n-p-1)} \quad (\text{Eq. 14})$$

Onde:  $\hat{Y}_i$  é o AGBt estimado;  $Y_i$  é o AGBt observado;  $\underline{Y}$  é a média amostral de AGBt observado;  $n$  é o número de observações, e  $p$  é o número de preditores.

Todas as avaliações de desempenho foram realizadas com o AGBt em sua escala original. A transformação reversa foi conduzida aplicando o logaritmo natural inverso aos

valores de AGBt. Os valores estimados foram ainda multiplicados por um fator de correção (Eq. 15) para reduzir MD relacionado com a transformação logarítmica (SMITH 1993, HUDAK et al. 2006).

$$cf = e^{(0.5 \times MSE)}, \quad (\text{Eq. 15})$$

Onde: MSE é o erro quadrático médio dos resíduos.

Os desempenhos do modelo também foram estimados para as diferentes formações do Cerrado (campestre, savanas e florestas). O melhor modelo classificado foi ainda avaliado com validação cruzada leave-one-out (LOOCV) e  $R^2$ , RMSE absoluto e relativo e MD também foram calculados com base nos valores de AGBt observados e estimados derivados do procedimento LOOCV dentro de cada formação vegetal. O teste Wilcoxon on-Mann-Whitney rank-sum (W) (WILCOXON, 1945) foi aplicado para avaliar se o AGBt estimado e observado difere ao nível de significância de 0,05.

#### 2.2.5. MAPEAMENTO DE BIOMASSA ACIMA DO SOLO

O melhor modelo linear foi implementado em toda a paisagem, para mapear o AGBt no local de estudo. Nesta etapa, as métricas derivadas do lidar usadas como preditores foram calculadas para uma grade espacialmente contínua de  $30 \times 30$  m, e o modelo foi aplicado a cada célula da grade em todos os locais de estudo. As formações do Cerrado foram delineadas com base na interpretação visual de alta resolução espacial GatorEye UAV RGB e imagens Planet's (EQUIPE PLANETA, 2017), conduzidas por um experiente fotointérprete local.

Levar em consideração a incerteza das estimativas é importante ao combinar dados de inventário e sensoriamento remoto para mapear os atributos da floresta (PERSSON e STAHL, 2020). Contabilizamos a incerteza para cada formação do Cerrado calculando a variância do estimador ( $V[\widehat{E}(\mu)_i]$ ) estimado usando inferência baseada em modelo padrão (SAARELA et al. 2016, STAHL et al. 2016, PULITI et al. 2018). Nesta abordagem, a amostra S usada para desenvolver os modelos na seção 2.4 foi considerada um sorteio de uma população maior U. O  $U_i$  representa a população finita da i-ésima formação do Cerrado com células de grade de  $N_i$ . Considerando os parâmetros estimados por OLSS  $\hat{\beta}_S$  (Eq. 8), o

valor médio esperado ( $\widehat{E(\mu)}_i$ ) e  $V[\widehat{E(\mu)}_i]$  para a i-ésima formação Cerrado pode ser estimada com a Eq. 16 e Eq. 17.

$$\widehat{E(\mu)}_i = \iota_{Ui}^T X_{Ui} \hat{\beta}_S, \quad (\text{Eq. 16})$$

Onde:  $\iota_{Ui}$  é o vetor coluna de comprimento de  $N_i$  com valores  $1/N_i$  para as células da grade de  $N_i$  da população  $U_i$  do i-ésimo tipo de vegetação;  $X_{Ui}$  é um  $N_i \times (p + 1)$  matriz das métricas lidar usadas como preditores e um vetor unitário como a primeira coluna.

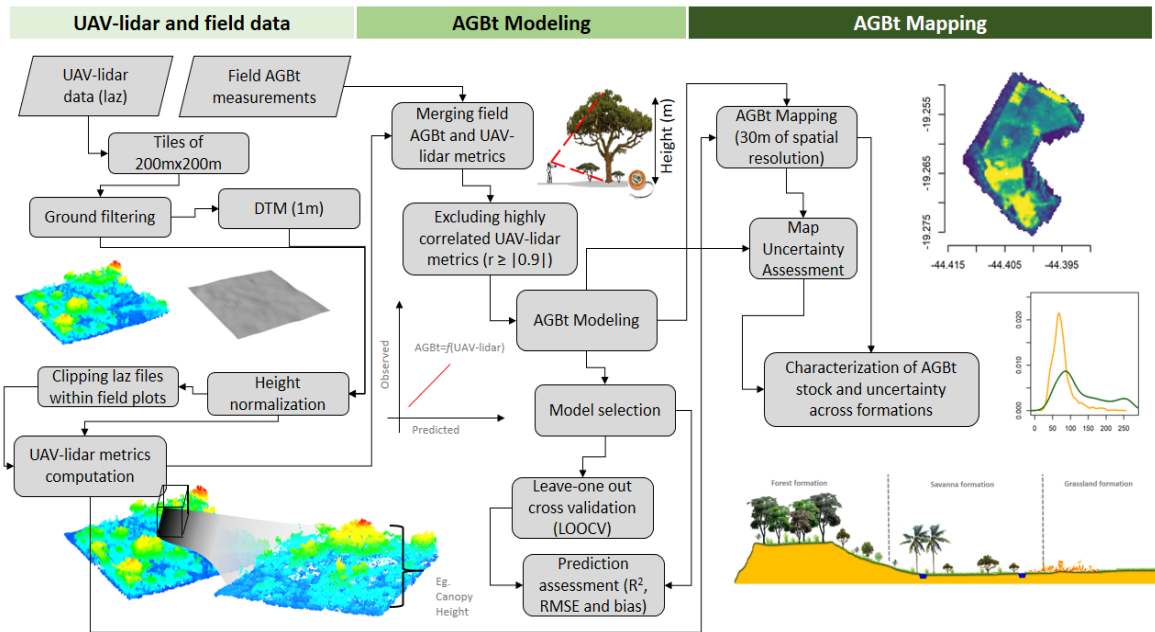
$$V[\widehat{E(\mu)}_i] = \iota_{Ui}^T X_{Ui} \text{Cov}(\hat{\beta}_S) X_S^T \iota_{Ui}, \quad (\text{Eq. 17})$$

Onde:  $\text{Cov}(\hat{\beta}_S)$  é a matriz de covariância dos parâmetros do modelo  $\beta_S$ . Assumindo que os erros estimados são homocedásticos, o  $\text{Cov}(\hat{\beta}_S)$  calculado pela Eq. 18.

$$\text{Cov}(\hat{\beta}_S) = \frac{\hat{\epsilon}_S^T \hat{\epsilon}_S}{n-p-1} (X_S^T X_S)^{-1}, \quad (\text{Eq. 18})$$

Onde:  $\hat{\epsilon}_S$  é o vetor dos resíduos estimados para o modelo desenvolvido com a amostra S (Eq. 16).

O erro padrão  $\widehat{SE}_i$  é posteriormente estimado como  $\sqrt{V[\widehat{E(\mu)}_i]}$  e o %  $\widehat{SE}_i$  como uma porcentagem do AGBt médio estimado.




**Figura 4.** Fluxo de trabalho para o processamento de dados UAV-lidar, AGBt modelagem e mapeamento.

## 2.3. RESULTADOS

### 2.3.1. MÉTRICAS UAV-LIDAR

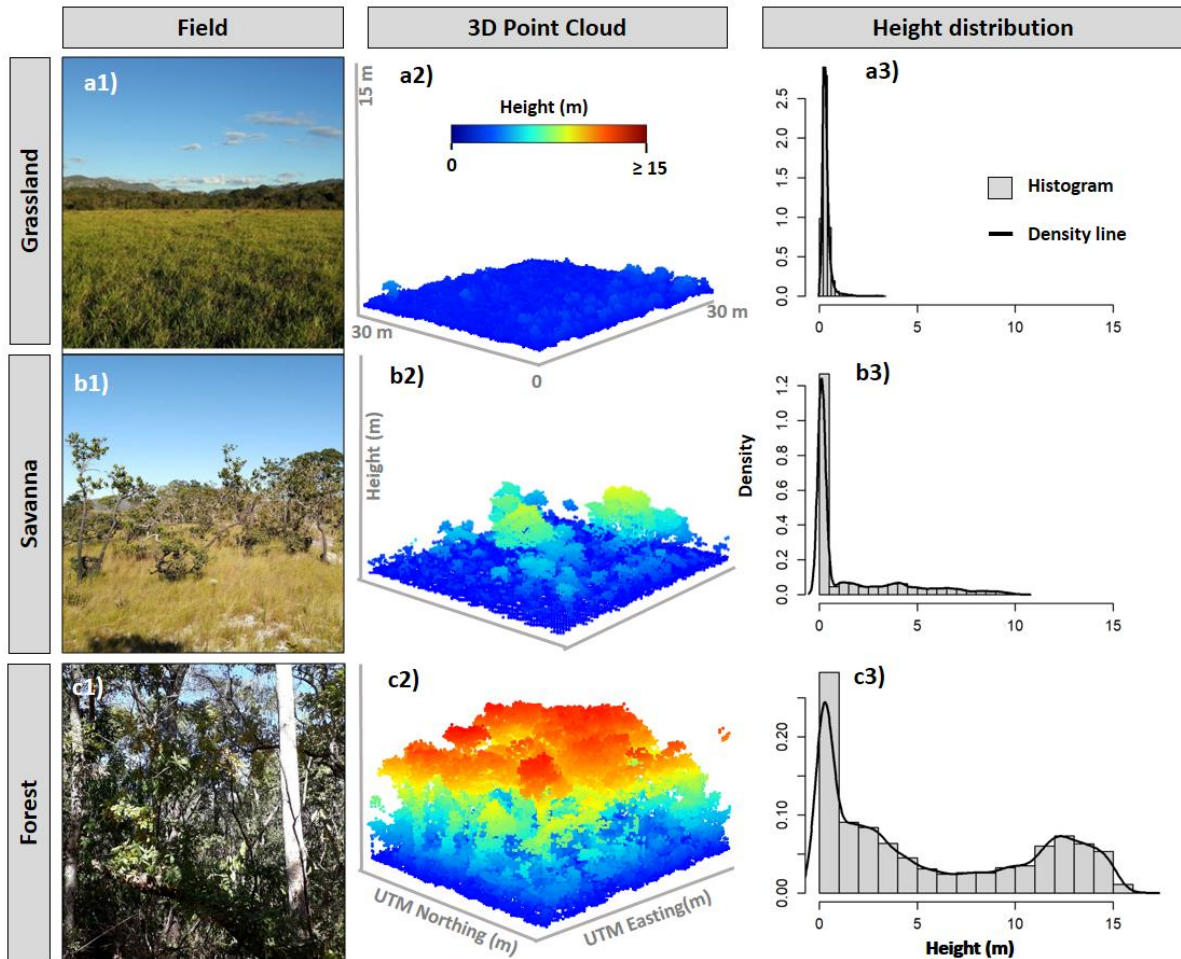
A figura 5 mostra o teste de correlação de Pearson ( $r$ ) entre as 17 métricas derivadas do lidar de UAV (Tabela 2). Em geral, 12 métricas foram altamente correlacionadas ( $|r| > 0,9$ ) entre si, portanto, foram excluídos de uma análise mais aprofundada sob os critérios de limite adotados (Fig. 5). Mantivemos uma das métricas altamente correlacionadas (H98TH) e junto com as quatro métricas restantes (ou seja, COV, H50TH, HKUR e HSKE), construímos os modelos prospectivos para estimar o AGBt. Três variáveis foram correlacionadas positivamente, como H98TH, COV e H50TH, enquanto outras duas foram correlacionadas negativamente, como HKUR e HSKE (FIG. 4). Embora o número de métricas tenha sido reduzido para cinco, as métricas derivadas do lidar acima mencionadas ainda representavam atributos importantes da vegetação, como a altura dominante (por exemplo, H98TH), a cobertura do dossel (por exemplo, COV) e a assimetria da altura da vegetação (por exemplo, HSKE).



**Figura 5.** Diagrama de correlação (r) de Pearson entre as 17 métricas derivadas de lidar usando um limite  $|r| > 0,9$ . Os valores são classificados usando um gradiente de cores de -1 a 1, onde 0 significa nenhuma correlação e 1 uma forte correlação. Os sinais negativo e positivo indicam relações inversas e diretas entre duas variáveis, respectivamente.

Nas formações campestres, os retornos lidar foram mais concentrados perto do solo (Fig. 6.a1-a3) por causa da estrutura da vegetação mais baixa e variabilidade encontrada nesta formação. Isso é claramente ilustrado pela inspeção da perspectiva de visão 3-D da nuvem de pontos lidar para os tipos de formação no Cerrado (Fig. 6.a1-a3). As formações campestres observadas nas quatro áreas de estudo selecionadas foram geralmente encontradas e dispostas em pequenas manchas entre florestas e savanas. Além disso, apresentaram uma distribuição de altura predominantemente regular sobre a paisagem e mostraram uma densidade muito alta de plantas herbáceas por unidade de área, o que dificulta a penetração dos retornos lidar. Nas formações de savana, a altura da vegetação UAV-lidar ultrapassou 10 m e apresentou maior variabilidade estrutural do que campestre (Fig. 6.b1-6.c1). Os retornos de altura lidar foram esparsamente e distribuídos aleatoriamente

em arbustos e árvores isoladas (Fig. 6.b3). Nas florestas, os retornos de altura lidar foram mais distribuídos entre os estratos de altura mais baixos e mais altos mostrando dois a três estratos de dossel bem definidos (Fig. 6.c3).



**Figura 6.** Imagens do solo foram tiradas durante as medições de campo (a-c1). Perspectivas de nuvem de pontos 3-D para parcelas de amostra selecionadas pesquisadas por UAV-lidar e onde diferentes propriedades biofísicas foram medidas (a-c2). Gráficos de densidade de retornos de altura lidar para as três formações principais (a-c3). A letra indica a formação da vegetação e é identificada na ordem como campo (começando com a letra a), Cerrado (começando com a letra b) e floresta (começando com a letra c).

### 2.3.2. AVALIAÇÃO DE DESEMPENHO DO MODELO

A Tabela 3 mostra cinco modelos testados neste estudo com base no uso das cinco métricas lidar selecionadas (H98TH, COV, H50TH, HKUR e HSKE). O primeiro modelo contém apenas a métrica H98TH, enquanto para os outros modelos aumentamos o número de variáveis adicionando o restante das métricas lidar, apenas uma por modelo, com base na seleção exaustiva de variáveis aproximação.

O melhor modelo para estimar AGBt usou apenas H98TH e COV, pois eles foram os melhores preditores entre o conjunto de métricas lidar (Tabela 3). Este modelo produziu o menor AICc e satisfaz a normalidade residual e suposições de homocedasticidade baseadas no Shapiro-Wilk ( $W = 0,95$  e valor  $p = 0,07$ ) e Breusch-Pagan ( $BP > 1,47$  e valor  $p > 0,48$ ) testes.

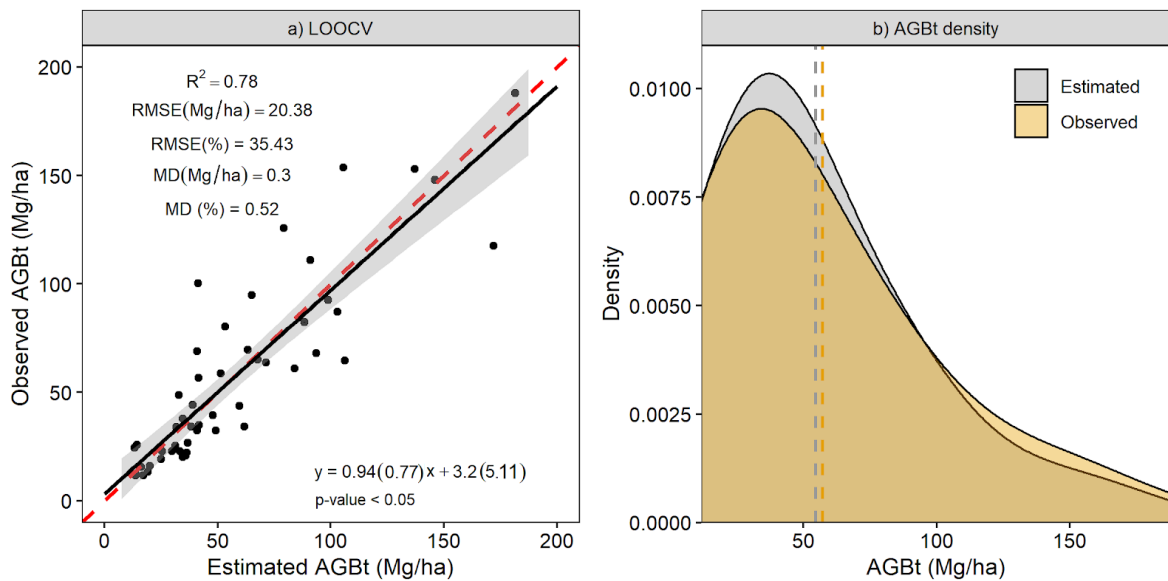
**Tabela 3.** Comparação de modelos calibrados usando métricas derivadas de UAV-lidar para estimar a biomassa aérea total (AGBt) no Cerrado.

A descrição das métricas derivadas do UAV-lidar é mostrada na Tabela 2.

Preditores	adj <sup>2</sup>	RMSE (Mg/ha)	RMSE (%)	MD (Mg/ha)	MD (%)	AICc
H98TH	0,74	24h30	42,46	-1,79	-3,12	44,11
H98TH, COV	0,79	19.11	33,40	-0,26	-0,46	36,49
H98TH, COV, H50TH	0,77	20.25	35,40	-0,70	-1,23	42,59
H98TH, COV, H50TH, HKUR	0,77	19.88	34,75	-0,59	-1,02	51,71
H98TH, COV, H50TH, HKUR, HSKE	0,76	20.14	35.21	-0,60	-1,05	63.13

Nota: Coeficiente de determinação ajustado (Aj  $R^2$ ), absoluto (Mg/ha) e relativa (%) raiz quadrada média do erro (RMSE) e diferenças médias (MD); Critério de informação de Akaike corrigido para um tamanho de amostra pequeno (AICc).

A Fig. 7a mostra o desempenho do melhor modelo usando o H98TH e preditores COV com o procedimento LOOCV. A Fig. 7b mostra a distribuição do AGBt estimado vs. observado derivado do LOOCV. Com base nos resultados LOOCV para o melhor modelo (Fig. 7a-b), o modelo subestimou ligeiramente o AGBt em intervalos mais baixos, e ocorreu leve superestimação do AGBt em intervalos maiores. No entanto, apesar das pequenas diferenças, a precisão do modelo avaliada pelo procedimento LOOCV mostrou estimativas com um MD inferior a 1 Mg/ha (< 1%), o que revela a robustez do modelo selecionado. De acordo com o teste de soma de postos de Wilcoxon, as estimativas de AGBt derivadas do LOOCV não diferiram significativamente dos valores observados ( $p$ -valor = 0,6918).



**Figura 7.** Gráfico de dispersão de previsões de validação cruzada versus observações (N = 50) para a biomassa acima do solo total transformada em logaritmo natural (AGBt) usando a validação cruzada leave-one-out (LOOCV). A linha vermelha tracejada indica a relação 1:1, enquanto a linha preta indica o melhor ajuste. Os números entre parênteses são os erros padrão de cada coeficiente. (b) Distribuição de frequência da distribuição estimada e observada do AGBt. A linha tracejada indica o AGBt médio para ambos os conjuntos de dados.

A Tabela 4 mostra a precisão das estimativas de AGBt dos procedimentos de calibração e LOOCV, aplicando o melhor modelo resumido pelas formações do Cerrado. Em geral, a precisão estimada do modelo calibrado e LOOCV mostraram tendências semelhantes, embora, como esperado, a validação cruzada tenha um desempenho ligeiramente pior com base no RMSE relativo e MD relativos. Talvez devido ao tamanho da amostra (n), o modelo da formação campestre apresentou a menor precisão (%RMSE) exatidão (%MD) em comparação com os modelos de savana e floresta. O modelo de floresta foi mais preciso (menor %RMSE), enquanto o modelo de savana foi menos preciso (menor %MD).



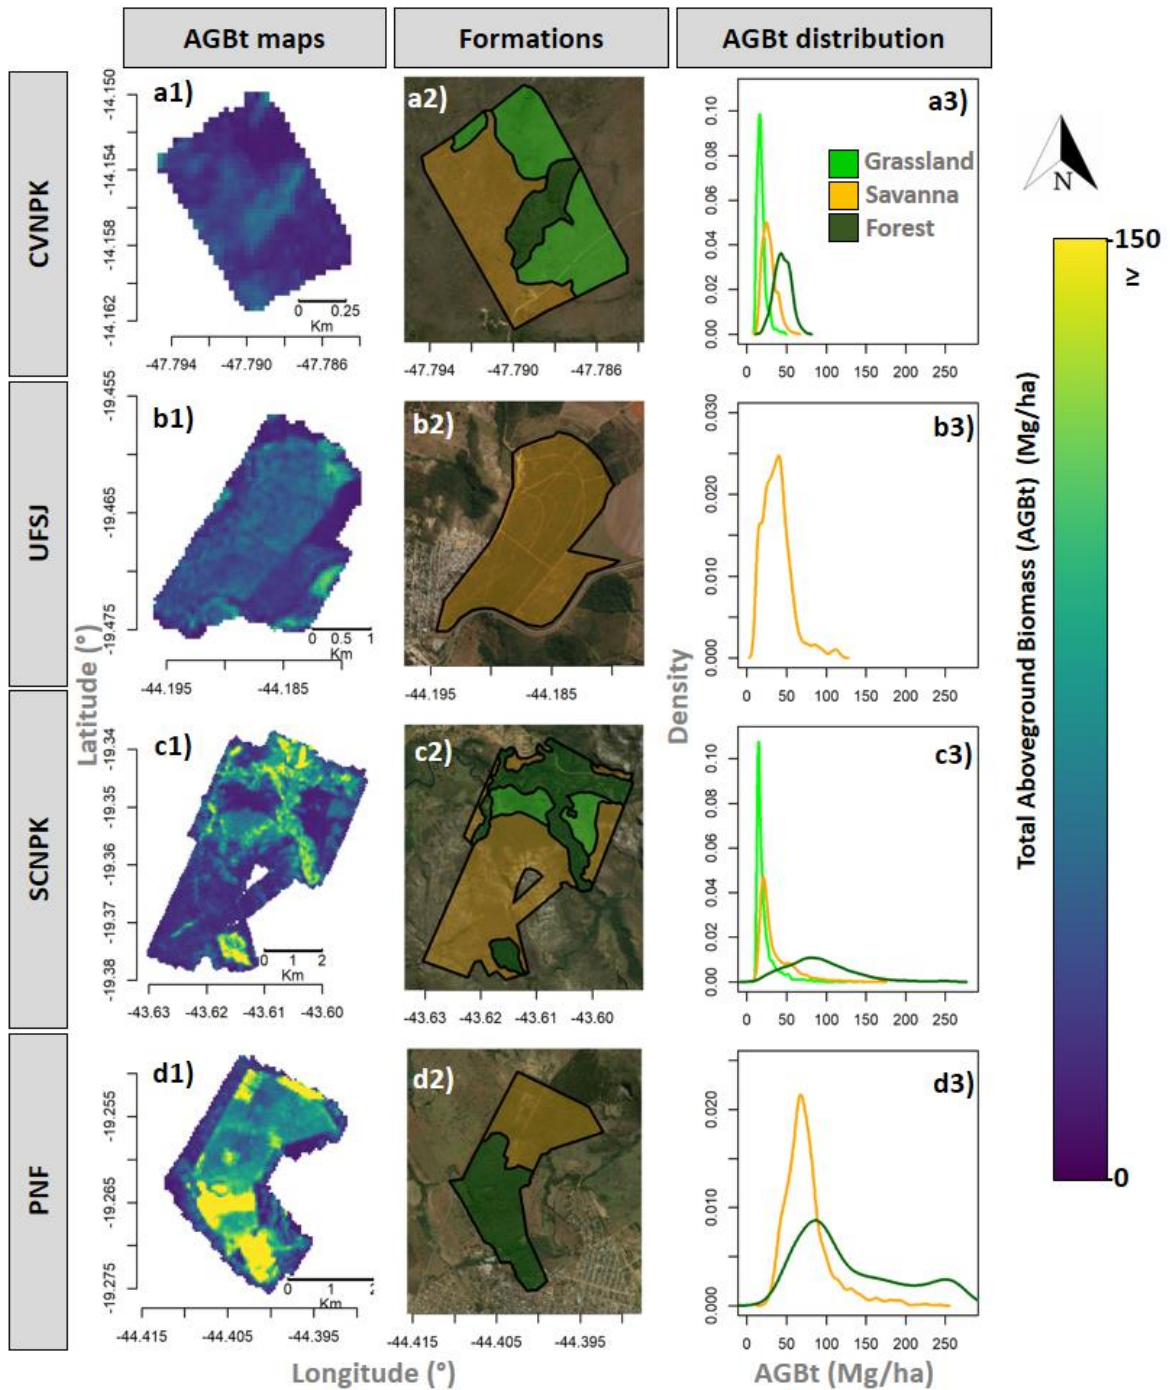
**Tabela 4.** Resumo do RMSE absoluto e relativo para o modelo calibrado com LOOCV e previsões AGBt estratificadas por formações de vegetação no Cerrado. n= número de observações (parcelas de campo) por formação.

Modelo	Formação	RMSE		MD		n
		Mg/ha	%	Mg/ha	%	
Modelo de calibração	Campestre	7.16	41,63	2.52	14.65	5
	Savana	17.24	42,69	-0,17	-0,43	30
	Floresta	24.61	23.62	-1,37	-1,32	15
LOOCV	Campestre	7.72	44,92	2.71	15.74	5
	Savana	17.76	43,96	-0,28	-0,68	30
	Floresta	27.08	25,99	-1,34	-1,29	15

### 2.3.3. MAPEAMENTO DE BIOMASSA ACIMA DO SOLO

O melhor modelo foi aplicado em toda a paisagem para mapear a AGBt para as quatro áreas de estudo selecionadas (Fig 8 a1-d1). No nível da paisagem e de acordo com a formação da vegetação dada, a média estimada e o erro padrão das estimativas AGBt variaram de 21.28 a 99,35 Mg/ha e 9,03 a 25,39 Mg/ha, respectivamente (Tabela 5). A savana e formações florestais armazenaram 48,09% (19,72 Mg/ha) e 78,58% (78,07 Mg/ha) mais AGBt do que campestre em nossos locais de estudo. A incerteza associada com a média estimada do AGBt foi maior na formação campestre do que na savana ou na formação florestal (Tabela 5). Em termos de abrangência espacial, a formação savânica foi a formação mais predominante nas quatro áreas de estudo, que abrangeu 59,8% da área total, seguida por florestas (30,7%) e formações campestres (9,5%).

O uso de dados de alta resolução espacial de imagens GatorEye UAV-RGB e PlanetScope permitiu o delineamento da distribuição espacial de cada formação de Cerrado para as quatro áreas de estudo selecionadas (Fig.8). Dois locais mostraram todas as três formações de vegetação (Fig. 8a2 e c2), enquanto um local mostrou formações de savana e floresta (Fig. 8d2) e um local apenas savana (Fig. 8c2). Os histogramas resultantes mostram as proporções de AGBt para cada local de estudo e cada formação do Cerrado (Fig. 8 a3-d3).



**Figura 8.** Mapas derivados de UAV-lidar da biomassa total acima do solo (AGBt) para os locais de estudo a1-d1) com resolução espacial de 30 m; camadas de formação de Cerrado a2-d2) e distribuição do AGBt por formação vegetal no Cerrado.

**Tabela 5.** Resumo da biomassa total acima do solo (AGBt) e estimadores de variância na escala da paisagem nas formações do Cerrado. n = número de observações (células da grade mapeadas).

<b>Formação Cerrado</b>	<b>E(<math>\mu</math>)</b>	<b>V [E(<math>\mu</math>)]</b>	<b>SE</b>	<b>%SE</b>	<b>n</b>
Campestre	21.28	25.39	5.04	23.68	1.578
Savana	41,00	9.03	3,00	7.33	10.044
Floresta	99,35	15.64	3,95	3,98	5.160

## 2.4. DISCUSSÃO

O Cerrado é a segunda maior fonte de emissões de carbono no Brasil (METZGER et al., 2019), e, portanto, medições precisas de AGBt são cruciais para impulsionar a gestão de carbono da vegetação, conservação e iniciativas de restauração (BISPO et al., 2020). Nosso estudo demonstra, pela primeira vez, o potencial dos sensores lidar UAV de alta densidade e as nuvens de pontos 3-D resultantes para capturar com precisão a estrutura altamente heterogênea da savana tropical no Brasil, que se caracteriza pela presença de várias formações vegetais, incluindo campestre, savana e floresta. Desta forma, é possível modelar o AGBt, que também contabiliza a contribuição de pequenas árvores, arbustos e vegetação de superfície para a biomassa total, em oposição à maioria dos estudos que se concentraram totalmente no AGB lenhoso do dossel (BISPO et al., 2020; ZIMBRES et al., 2020).

### 2.4.1. INCLUINDO VEGETAÇÃO NÃO LENHOSA EM ESTIMATIVAS LIDAR DE BIOMASSA ACIMA DO SOLO

A estimativa de biomassa da vegetação não lenhosa é relativamente negligenciada na literatura científica, apesar de sua grande contribuição proporcional ao fluxo global de carbono da queima de biomassa (VAN DER WERF et al., 2010; POULTER et al., 2014; PEELE e outros. 2019; DUVERT et al., 2020; LASSLOP et al., 2020). Embora existam inúmeros estudos sobre o uso de lidar para estimar e monitorar a estrutura da floresta e AGB em uma variedade de biomas e tipos de vegetação (CLARK et al., 2011; HUDAK et al. 2012; ANDERSEN et al., 2013; ASNER e MASCARO, 2014; SILVA et al., 2017), há escassez de estudos que contemplem toda a gama de formações vegetais encontrados no bioma Cerrado. Nossos resultados não são verdadeiramente comparáveis aos desempenhos de modelos obtidos por outros estudos usando lidar para mapeamento de biomassa em

ecossistemas de savana tropical, porque esses normalmente visam apenas AGB lenhoso (BISPO et al., 2020; ZIMBRES et al., 2020) ao contrário da estimativa AGBt feita em nosso estudo. Por exemplo, Levick et al. (2019), usando ALS para avaliar a estrutura do habitat e a resposta do carbono lenhoso acima do solo (AGC) a regimes de fogo alterados na savana tropical na Austrália, foram capazes de calibrar modelos e mapear AGC para todo o local experimental com desempenho do modelo resultando em um  $R^2$  de 0,82 e RMSE de 7,35 Mg/ha, o RMSE absoluto (Mg/ha) com aproximadamente o dobro em termos de AGB. Bispo et al. (2020) usando também as métricas alturas e a cobertura do dossel derivado de ALS para estimar apenas o AGB lenhosa apresentou bom desempenho do modelo, com  $R^2$  de 0,93 e RMSE de 6,74 Mg/ha (13,0%).

Almeida et al. (2019) usou o mesmo Sistema GatorEye UAV-lidar apresentado neste estudo, mas em um ambiente de floresta tropical e foram capazes de mapear o AGB em diferentes estágios de sucessão florestal com desempenho do modelo  $R^2$  de 0,80 e RMSE de 24,9 Mg/ha (9,0%), respectivamente. O fato de que o desempenho de nossos modelos terem sido um pouco pior do que os apresentados por esses autores pode ser explicado pela nossa abordagem incluir vegetação não lenhosa em nossa estimativa de AGBt, e não apenas AGB armazenado em árvores; embora o lidar seja sensível à estrutura do dossel lenhoso, sua sensibilidade ao sub-bosque e aos componentes de combustível da superfície, particularmente a camada de serapilheira no nível do solo, é menor, contribuindo assim para maiores erros de estimativa. Bispo et al., (2020) não incluiu dados de formações campestre em seu gradiente de Cerrado, que é o tipo de formação de vegetação que normalmente produz maiores erros em estudos que concordam com nossos resultados (WANG et al. 2017; MARSELIS et al., 2018; ZHANG et al., 2018; MADSEN et al., 2020). Se arbustos e vegetação de superfície não forem incluídos na amostra, os modelos resultantes não podem ser extrapolados para mapear AGB em direção a áreas de campestre, que podem ser uma proporção bastante representativa da terra em ecossistemas de savana como o Cerrado (Fig. 8). Por sua vez, nossos resultados demonstram que a estimativa de AGBt é possível com um nível de certeza comparável à estimativa de AGB apenas de árvores, o que compensa o esforço extra no protocolo de amostragem em relação ao ganho obtido ao incluir um componente proporcionalmente relevante da vegetação total biomassa. Dada a alta importância da estimativa de formação campestre no Cerrado (SIMON e outros, 2009) e sua importância para os balanços globais de carbono (VAN DER WERF et al., 2010; POULTER et al., 2014; PEELE et al., 2019; DUVERT et al., 2020; LASSLOP et al., 2020), é crucial

que mais pesquisas sobre estimativas de biomassa por lidar incluam formações de vegetação não lenhosa tanto na modelagem para AGBt quanto nos projetos de amostragem.

#### 2.4.2. CONVERGÊNCIA DE MÉTRICAS ENTRE SENSORES, PLATAFORMAS E FORMAÇÕES DE VEGETAÇÃO DA SAVANA

Conseguimos identificar as melhores métricas derivadas do UAV-lidar para produzir modelos que podem estimar com precisão a distribuição de AGBt nas diferentes formações de vegetação, estimar AGB total em nível de parcela e produzir mapas em nível de paisagem para diferentes regiões do Cerrado. O melhor modelo derivado do algoritmo exaustivo de seleção de variáveis usa métricas que representam a altura e a cobertura do dossel (por exemplo, H98TH e COV), o que concorda com outros resultados para estimativa de AGB em ecossistemas tropicais, incluindo Cerrado (LEVICK et al. 2019; BISPO et al., 2020; ZIMBRES et al., 2020). Por exemplo, Levick et al. 2019, foram capazes de mapear com precisão o carbono lenhoso acima do solo (AGC) na savana tropical da Austrália, usando apenas a altura do dossel e métricas de cobertura derivada do lidar. Bispo et al., (2020) usou ALS para mapeamento de AGB lenhoso no Cerrado e descobriram que os modelos calibrados com altura e cobertura do dossel resultou em melhor desempenho. Além disso, as métricas de altura e cobertura do dossel superior derivadas de lidar mostraram ser estáveis em densidades de pulso reduzidas (HENSEN et al., 2015; SILVA et al., 2017), o que permite a comparabilidade de diferentes pesquisas e, portanto, o uso de séries temporais lidar (BATER et al., 2011; HUDAK et al. 2012; CAO et al., 2016; ZHAO et al., 2018; HU et al., 2019). A literatura científica está claramente convergindo para o uso dessas métricas e, portanto, elas já são consideradas como características morfológicas padrão do ecossistema para medir em vários biomas e fontes de dados (VALBUENA et al., 2020). Nossos resultados mostram que estes também são relevantes em gradientes, incluindo florestas e ecossistemas de campestre, o que tem grandes implicações globais (SIMON et al., 2009). Essa convergência está permitindo meta-análises comparativas em diferentes tipos de métodos de sensoriamento remoto 3-D, para avaliar adequadamente diferentes paisagens de forma consistente (VALBUENA et al., 2020). Assim, a vegetação florestal (ASNER e MASCARO, 2014) e a campestre (TANG et al., 2019) são tão relevantes para uso na estimativa de biomassa em biomas dominados por formações campestre quanto por florestas.

#### 2.4.3. SUPERANDO DESAFIOS NO MAPEAMENTO DE BIOMASSA TOTAL ACIMA DO SOLO EM ECOSISTEMAS DE SAVANA TROPICAL

A complexa fisionomia dos ecossistemas encontrados em áreas como o Cerrado cria desafios específicos para mapear as distribuições de biomassa usando sensoriamento remoto. Por esta razão, existe apenas literatura limitada sobre o uso de sensoriamento remoto para estimar AGBt, em comparação com a estimativa de AGB lenhosa em savanas (LEVICK et al., 2019; BISPO et al., 2020; ZIMBRES et al., 2020). Mapas precisos de AGBt podem, no entanto, ajudar a identificar as distribuições das diferentes formações de vegetação ao longo da paisagem e suas incertezas associadas. Nosso estudo, portanto, serve como referência para futuras coletas de dados adicionais e pode permitir a disponibilidade em larga escala de dados sobre a estrutura do bioma Cerrado. A precisão da estimativa de AGBt variou entre diferentes formações de vegetação, com uma maior incerteza observada em formações campestres. Este resultado pode estar associado ao menor tamanho amostral para a formação campestre e também as limitações do lidar (não apenas plataformas UAV) na captura da estrutura 3-D nesta formação. A alta densidade de vegetação baixa na formação campestre, reduz a penetração dos pulsos lidar e pode afetar negativamente a capacidade de diferenciar retornos de vegetação e de solo (HOPKINSON et al., 2004; STREUTKER et al., 2006), introduzindo mais erros e aumentando a incerteza. Tais complicações provavelmente contribuem para a aparente escassez de literatura sobre o estudo de vegetação campestre com LiDAR (HUDAK et al., 2016). Pesquisas futuras devem se concentrar mais incluir as áreas de campestre com uma distribuição estratificada (ADNAN et al. 2021), uma vez que áreas de campestre são caracterizadas por valores baixos de AGBt que podem ser subamostrados em projetos de estudo.

#### 2.4.4. IMPLICAÇÕES MAIS AMPLAS DE NOSSAS DESCOBERTAS

As conclusões deste estudo, juntamente com outras pesquisas sobre o tema, podem auxiliar no desenvolvimento de monitoramento de carbono mais preciso e atividades integradas de manejo de combustíveis e queimadas no Cerrado. Por exemplo, ao desenvolver mapas de ampla cobertura, o UAV-lidar pode fornecer dados para calibração e validação de mapas de biomassa baseados em satélite, que são cada vez mais amplamente utilizados devido à proliferação de plataformas de código aberto. Outra aplicabilidade crítica e em tempo real dos mapas UAV-lidar AGB, é para validar produtos de satélite, como os das missões GEDI e ICESat-2 (Ice, Cloud e Land Elevation Satellite 2) da NASA (SILVA et al.,

2021). Consequentemente, o UAV-lidar apresenta o conveniente de ser uma solução de custo relativamente baixo para coletar dados com uma densidade de pontos extremamente alta, capturando e descrevendo assim diferenças estruturais no Cerrado. Em conjunto, eles permitem a geração de estimativas localmente e altamente precisas de AGBt para cada formação de Cerrado. A necessidade de avaliações de alta resolução para calibrar e validar mapas de biomassa baseados em satélites é crucial diante da enorme pressão que as mudanças globais estão exercendo sobre o Cerrado. Por exemplo, empregando mapas com maior incerteza em vegetação campestre pode limitar ou dificultar a capacidade preditiva das estratégias de manejo do fogo em andamento no Cerrado e merece atenção urgente em termos de suas implicações para aplicações práticas. Atualmente, no entanto, não há alternativa melhor em termos de velocidade e custo para estimativa em larga escala de AGBt no Cerrado e, portanto, os maiores erros por dados UAV-lidar em comparação com as medições de campo compensem uma incerteza ligeiramente maior nas previsões, especialmente em formações campestres.

## **2.5. CONCLUSÃO**

Neste estudo, o uso do UAV-lidar nos permitiu derivar com precisão diferentes métricas de vegetação de nuvens de pontos 3-D para modelar e estimar a biomassa total acima do solo na escala da paisagem nas formações do Cerrado em resolução moderada. Nossa abordagem metodológica pode ser expandida para áreas maiores com sucesso, pois abrange os principais tipos de vegetação do bioma, consistindo de um gradiente que varia de formação campestre para savanas e florestas. Nossa análise de modelagem identificou as melhores métricas derivadas do lidar para serem usadas para estimar a biomassa total acima do solo, onde a altura da vegetação dominante e a cobertura do dossel foram as variáveis que mostraram o melhor desempenho do modelo. O mapa de biomassa e a estrutura apresentadas neste documento podem complementar as avaliações de campo, treinar e validar outros métodos para estimar a biomassa total acima do solo com base em dados de satélite, como o GEDI. Nesse sentido, os usuários podem potencialmente melhorar a resolução espacial e temporal do monitoramento de biomassa acima do solo em uma região que desempenha um papel fundamental no ciclo global do carbono e onde a distribuição da biomassa ainda não está quantificada. Os resultados do estudo podem apoiar novos sistemas de decisão com base no monitoramento preciso da biomassa acima do solo com o objetivo de informar e melhorar as respostas da política florestal em questões de degradação florestal, emissões de carbono e função do ecossistema. Além disso, ajuda a entender melhor as

interações clima-fogo e as mudanças dinâmicas nos regimes de fogo decorrentes das mudanças nos reservatórios de biomassa.

## 2.6. AGRADECIMENTOS

Este projeto foi apoiado pela bolsa do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) 442640/2018-8 (CNPq/Prevfogo-Ibama Nº 33/2018). D.R.A.A. foi financiado pela Fundação de Amparo à Pesquisa do Estado de São Paulo (nº 2018/21338-3). E, financiado em parte pelo MCTIC/CNPqMULHERES 28/2018 (#408785/2018-7; #438875/2018-4), CNPq MULHERES 09/2018 (#302891/2018-8) e pela Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES).

Agradecemos aos seguintes alunos de graduação e pós-graduação envolvidos na campanha de trabalho de campo: Alberto A. Gontijo e Silva, Alexandre S. C. Filho, André Felipe C. Lima, Bernardo dos S. de Almeida, Carlos Magno M. de Oliveira, Gilberto do A. Pacheco; Gustavo R. Lattanzi, Iago Henrique F. da Silva, Irene M. Barbosa, Ivo S. Moreira, Jacson A. A. Machado, Jean Victor N. Paiva, Junia S. M. Macedo, Leandra Dietrich, Lídia A. de Aguiar, Matheus Gunther M. Soares, Nelson Amaral, Nivaldo R. J. Junior, Reginaldo Arthur G. Marcelino, Thiago Trajano.

Além disso, agradecemos aos gestores do parque: Edward Elias Junior, Celso Lago-Paiva e Leandro Chagas do Parque Nacional Serra do Cipó, Maria Carolina A. Camargos do Parque Nacional da Chapada dos Veadeiros e Renato Diniz Dumont da Floresta Nacional de Paraopeba. A coleta e o processamento de dados do GatorEye foram apoiados em parte pelo programa McIntire-Stennis do USDA, e pela Escola de Conservação e Recursos Florestais e Centro de Estudos da América Latina da UFL.

## 2.7. REFERÊNCIAS BIBLIOGRÁFICAS

ADNAN, S.; MALTAMO, M.; PACKALEN, P.; MEHTATALO, L.; AMMATURO, N.; VALBUENA, R. Determining maximum entropy in 3D remote sensing height distributions and using it to improve aboveground biomass modelling via stratification. **Remote Sensing of Environment**, v. 260, n.1, p. 112464, 2021. <https://doi.org/10.1016/j.rse.2021.112464>.

AFFEK, A. N.; ZACHWATOWICZ, M.; SOSNOWSKA, A.; GERLÉE, A.; KISZKA, K. Impacts of Modern Mechanised Skidding on the Natural and Cultural Heritage of the Polish Carpathian Mountains. **Forest Ecology and Management**, v. 405, p. 391-403, 2017. <https://doi.org/10.1016/j.foreco.2017.09.047>



AKAIKE, H. A Bayesian extension of the minimum AIC procedure of autoregressive model fitting. **Biometrika**, v. 66, n. 2, p. 237-242, 1979. <https://doi.org/10.1093/biomet/66.2.237>.

ALMEIDA, D. R. A.; BROADBENT, E. N.; ZAMBRANO, A. M. A.; WILKINSON, B. E.; FERREIRA, M. E.; CHAZDON, R.; MELIA, P.; GORGENSE, E. B.; SILVA, C. A.; STARKG, S. C.; VALBUENA, R.; PAPA, D. A.; BRANCALION, P. H. S. Monitoring the structure of forest restoration plantations with a drone-lidar system. **International Journal of Applied Earth Observation and Geoinformation**, v. 79, n. 1, p. 192-198, 2019. <https://doi.org/10.1016/j.jag.2019.03.014>

ALMEIDA, D. R. A.; ALMEYDA ZAMBRANO, A. M.; BROADBENT, E. N.; WENDT, A. L.; FOSTER, P.; WILKINSON, B. E.; SALK, C.; PAPA, D. A.; STARK, S. C.; VALBUENA, R.; GORGENSE, E. B.; SILVA, C. A.; BRANCALION, P. H. S.; FAGAN, M.; MELI, P.; CHAZDON, R. Detecting successional changes in tropical forest structure using GatorEye drone-borne lidar. **Biotropica**, v. 52, n. 6, p. 1156-1168, 2020. <https://doi.org/10.1111/btp.12814>

ALMEIDA, D. R. A.; BROADBENT, E. N.; FERREIRA, M. P.; MELI, P.; ZAMBRANO, A. M. A.; GORGENSE, E. B.; ... & BRANCALION, P. H. Monitoring restored tropical forest diversity and structure through UAV-borne hyperspectral and lidar fusion. **Remote Sensing of Environment**, v. 264, n.1, p. 112582, 2021. <https://doi.org/10.1016/j.rse.2021.112582>

ALVARADO, S. T.; FORNAZARI, T.; CÓSTOLA, A.; MORELLATO, L. P. C.; SILVA, T. S. F. Drivers of fire occurrence in a mountainous Brazilian Cerrado savanna: Tracking long-term fire regimes using remote sensing. **Ecological Indicators**, v. 78, n. 1, p. 270-281, 2017. <https://doi.org/10.1016/j.ecolind.2017.02.037>

ALVARES, C. A.; STAPE, J. L.; SENTELHAS, P. C.; DE MORAES GONÇALVES, J. L.; SPAROVEK, G. Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, n. 6, p. 711-728, 2013.

ANDERSEN, H.; REUTEBUCH, S. E.; MCGAUCHEY, R. J.; D'OLIVEIRA, M. V. N.; KELLER, M. Monitoring selective logging in western Amazonia with repeat LiDAR flights. **Remote Sensing of Environment**, v. 151, n. 1, p. 157-165, 2014. <https://doi.org/10.1016/j.rse.2013.08.049>

ANDERSON, K. E.; GLENN, N. F.; SPAETE, L. P.; SHINNEMAN, D. J.; PILLIOD, D. S.; ARKLE, R. S.; MCLLOY, S. K.; DERRYBERRY, D. R. Estimating vegetation biomass and cover across large plots in shrub and grass dominated drylands using terrestrial lidar and machine learning. **Ecological Indicators**, v. 84, n. 1, p. 793-802, 2018. <https://doi.org/10.1016/j.ecolind.2017.09.034>

ARAÚJO, F. M.; FERREIRA, L. G.; ARANTES, A. E. Distribution patterns of burned areas in the Brazilian Biomes: An analysis based on satellite data for the 2002-2010 period. **Remote Sensing**, v. 4, n. 7, p. 1929-1946, 2012. <https://doi.org/10.3390/rs4071929>

ASNER, G. P.; MASCARO, J. Mapping tropical forest carbon: Calibrating plot estimates to a simple LiDAR metric. **Remote Sensing of Environment**, v. 140, n.1, p. 614-624, 2014. <https://doi.org/10.1016/j.rse.2013.09.023>

BACCINI, A.; WALKER, W.; CARVALHO, L.; FARINA, M.; SULLA-MENASHE, D.; HOUGHTON, R. A. Tropical forests are a net carbon source based on aboveground measurements of gain and loss. **Science**, v. 358, n. 6360, p. 230-234, 2017. <https://www.science.org/doi/10.1126/science.aam5962>

BALDUINO, A. P. D. C.; SOUZA, A. L. D.; MEIRA NETO, J. A. A.; SILVA, A. F. D.; SILVA JÚNIOR, M. C. D. Phytosociological composition and floristic comparison of Cerrado of Paraopeba

flora-MG. **Revista Árvore**, v. 29, n. 1, p. 25-34, 2005. <https://doi.org/10.1590/S0100-67622005000100004>

BALTSAVIAS, E. P. A. A comparison between photogrammetry and laser scanning. **ISPRS Journal of Photogrammetry and Remote Sensing**, v.54, n 2/3, p. 83-94, 1999. [https://doi.org/10.1016/S0924-2716\(99\)00014-3](https://doi.org/10.1016/S0924-2716(99)00014-3)

BATER, C. W.; WULDER, M. A.; COOPS, N. C.; NELSON, R. F.; HILKER, T.; NAESSET, E. Stability of sample-based scanning-lidar-derived vegetation metrics for forest monitoring. **IEEE Transactions on Geoscience and Remote Sensing**, v. 49, n. 6, p. 2385-2392, 2011. <https://doi.org/10.1109/TGRS.2010.2099232>

BATISTA, F. R. D. Q. **Manejo e monitoramento de impactos sobre o ecossistema em áreas protegidas de Cerrado: estrutura da vegetação, gramíneas exóticas e incêndios**. 165 f. Tese de Doutorado (Ciências Ambientais). Universidade Federal de Goiás, GO, 2019.

BATISTA, A. C.; BEUTLING, A.; PEREIRA, J. F. Estimativa do comportamento do fogo em queimas experimentais sob povoamentos de *Pinus elliottii*. **Revista Arvore**, v. 37, n. 5, p. 779–787, 2013.

BEERLING, D. J.; OSBORNE, C. P. The origin of the savanna biome. **Global Change Biology**, v. 12, n. 11, p. 2023–2031, 2006.

BENITES, V. M.; CAIAFA, A. N.; MENDONÇA, E. S.; SCHAEFER, C. E. G. R.; KER, J. C. Solos e vegetação nos Complexos Rupestres de Altitude da Mantiqueira e do Espinhaço. **Floresta e Ambiente**, v. 10, n. 1, p. 76-85, 2003.

BEUKEMA, S. J.; GREENOUGH, J. A.; ROBINSON, C. E.; KURTZ, W. A.; REINHARDT, E. D.; CROOKSTON, N. L.; ... & STAGE, A. R. An introduction to the fire and fuels extension to FVS. In: TECK, M. M.; ADAMS, J. (Eds.). **Proceedings of the Forest Vegetation Simulator Conference**. 1. ed. Ogden, UT. U.S.: Intermountain Research Station, 1997. 191–195p.

BISPO, P. C.; RODRÍGUEZ-VEIGA, P.; ZIMBRES, B.; DO COUTO DE MIRANDA, S.; CEZARE, C. H. G.; FLEMING, S.; BADALCCHINO, F.; LOUIS, V.; RAINS, D. GARCIA, M.; ESPIRITO SANTO, M. F. D. B.; ROITMAN, I.; PACHECO-PASCAGAZA, AM.; GOU, Y.; ROBERTS, J. B. K.; FERREIRA, L. G.; SHIMBO, J. Z.; ALENCAR, A.; BUSTAMANETE, M.; WOODHOUSE, L. H.; SANO, E. E.; OMETTO, J. P.; TANSEY, K.; BALZTER, H. Woody aboveground biomass mapping of the brazilian savanna with a multi-sensor and machine learning approach. **Remote Sensing**, v. 12, n. 17, p. 2685, 2020. <https://doi.org/10.3390/rs12172685>

BONANOMI, J., TORTATO, F. R.; RAPHAEL DE SOUZA, R. G.; PENHA, J. M.; BUENO, A. S.; PERES, C. A. Protecting forests at the expense of native grasslands: Land-use policy encourages open-habitat loss in the Brazilian Cerrado biome. **Perspectives in ecology and conservation**, v, 17, n. 1, p. 26-31, 2019. <https://doi.org/10.1016/j.pecon.2018.12.002>

BOWMAN, D. M.; BALCH, J. K.; ARTAXO, P.; BOND, W. J.; CARLSON, J. M.; COCHRANE, M. A.; ... & PYNE, S. J. Fire in the earth system. **Science**, v. 324, n. 5926, p. 481–484, 2009.

BREDE, B.; LAU, A.; BARTHOULOMEUS, H. M.; KOOISTRA, L. Comparing RIEGL RiCOPTER UAV LiDAR derived canopy heigth and DBH with terrestrial LiDAR. **Sensors**, v. 17, n. 10, p. 2371, 2017. <https://doi.org/10.3390/s17102371>

BREUSCH, T. S.; PAGAN, A. R. A. Simple Test for Heteroscedasticity and Random Coefficient Variation. *Econometrica*: **Journal of the Econometric Society**, v. 47, n. 1, p. 1287-1294, 1979. <https://doi.org/10.2307/1911963>

BROADBENT, E. N.; ZAMBRANO, A. M. A.; OMANS, G.; ADLER, A.; ALONSO, P.; NAYLOR, D.; CHENEVERT, G.; MURTHA, T.; VOGEL, J.; ALMEIDA, D. R. A.; DALLA CORTE, A. P.; SILVA, C. A.; PRATA, G. A.; MERRICK, T.; D'OLIVEIRA, M. V. N.; DETTO, M.; FERREIRA, M. P.; WILKINSON, B. E.; FERREIRA, M. E.; MULLER-LANDAU, H. C. 2020. **The GatorEye Unmanned Flying Laboratory**: sensor fusion for 4D ecological analysis through custom hardware and algorithm integration. Disponível em: <<http://www.gatoreye.org>>. Acesso em: 17 nov. 2021.

CAO, L.; COOPS, N. C.; INNES, J. L.; SHEPPARD, S. R.; FU, L.; RUAN, H.; SHE, G. Estimation of forest biomass dynamics in subtropical forests using multi-temporal airborne LiDAR data. **Remote Sensing of Environment**, v. 178, n. 1, p. 158–171, 2016. <https://doi.org/10.1016/j.rse.2016.03.012>

CARVALHO, A. L. DE; D'OLIVEIRA, M. V. N.; PUTZ, F. E.; OLIVEIRA, L. C. DE. Natural Regeneration of Tress in Selectively Logged Forest in Western Amazonia. **Forest Ecology and Management**, v. 392, n. 1, p. 36-44, 2017. <https://doi.org/10.1016/j.foreco.2017.02.049>.

CASTRO, E. A. D. E.; KAUFFMAN, J. B. Ecosystem structure in the Brazilian Cerrado: a vegetation gradient of aboveground biomass , root mass and consumption by re Ecosystem structure in the Brazilian Cerrado : a vegetation gradient of aboveground biomass , root mass a. **Journal of Tropical Ecology**, v. 14, n. 3, p. 263– 283, 1998. <https://doi.org/10.1017/S0266467498000212>

CASTRO-NEVES, B. M. DE. **Efeito de Queimadas em áreas de Cerrado Stricto Sensu e na biomassa de raízes finas**. 2007. 82f. Tese (Ecologia). Universidade de Brasília, Brasília, DF, 2007.

CENTENO, J. A. S.; MITISHITA, E. A. Laser scanner aerotransportado no estudo de áreas urbanas: A experiência da UFPR. In: **Simpósio Brasileiro de Sensoriamento Remoto**, v. 13, 2007, Florianópolis. Anais... São José dos Campos: INPE, p. 3645-3652. 2007.

CHAVE, J.; RÉJOU-MÉCHAIN, M.; BÚRQUEZ, A.; CHIDUMAYO, E.; COLGAN, M. S.; DELITTI, W. B. C.; DUQUE, A.; EID, T.; FEARNSIDE, P. M.; GOODMAN, R. C.; HENRY, M.; MARTÍNEZ-YRÍZAR, A.; MUGASHA, W. A.; MULLER-LANDAU, H. C.; MENCUCCINI, M.; NELSON, B. W.; NGOMANDA, A.; NOGUEIRA, E. M.; ORTIZ-MALAVASSI, E.; PÉLISSIER, R.; PLOTON, P.; RYAN, C. M.; SALDARRIAGA, J. G.; VIEILLEDENT, G. Improved allometric models to estimate the aboveground biomass of tropical árvores. **Global Change Biology**, v. 20, n. 10, p. 3177–3190, 2014. <https://doi.org/10.1111/gcb.12629>

CIRNE, P.; MIRANDA H. S. Effects of prescribed fires on the survival and release of seeds of *Kielmeyera coriacea* (Spr.) Mart. (Clusiaceae) in savannas of Central Brazil. **Brazilian Journal of Plant Physiology**, v. 20, n. 3, p. 197–204, 2008. <https://doi.org/10.1590/S1677-04202008000300004>

CLARK, M. L.; ROBERTS, D. A.; EWEL, J. J.; CLARK, D. B. Remote Sensing of Environment Estimation of tropical rain forest aboveground biomass with small-footprint lidar and hyperspectral sensors. **Remote Sensing of Environment**, v. 115, 11, p. 2931–2942, 2011. <https://doi.org/10.1016/j.rse.2010.08.029>

COUTINHO, L. M. 1990. **Fire in the Ecology of the Brazilian Cerrado** (JG Goldammer, Ed.). in: Fire in the Tropical Biota: Ecosystem processes and global challenges. Springer Verlag, Berlin, 82-105p.

COUTINHO, L. M. 1977. **Ecological aspects of fire in the Cerrado**. II – Fire and seed dispersion in some anemochoric species of the herbaceous layer. *Boletim de Botânica da Universidade de São Paulo*, 57-63p.

DALLA CORTE, A. P.; SOUZA, D. V.; REX, F. E.; SANQUETTA, C. R.; MOHAN, M.; SILVA, C. A.; ZAMBRANO, A. M. A.; PRATA, G.; ALMEIDA, D. R. A.; TRAUTENMULLER, J. W.; KLAUBERG, C.; MPRAES, A.; SANQUETTA, M. N.; WILKINSON, B.; BROADBENT, E. N. Forest inventory with high-density UAV-Lidar: Machine learning approaches for predicting individual árvore attributes. *Computers and Electronics in Agriculture*, v. 179, n. 1, p. 105815, 2020. <https://doi.org/10.1016/j.compag.2020.105815>

DALAGNOL, R.; PHILLIPS, O. L.; GLOOR, E.; GALVÃO, L. S.; WAGNER, F. H.; LOCKS, C. J.; ARAGÃO, L. E. O. C. Quantifying Canopy Árvore Loss and Gap Recovery in Tropical Forests under Low-Intensity Logging Using VHR Satellite Imagery and Airbone LiDAR. *Remote Sens.* v. 11, n. 7, p. 817, 2019. <https://doi.org/10.3390/rs11070817>.

DANTAS, D.; SOUZA, M. J.; VIEIRA, A.; PEREIRA, I.; MACHADO, E.; ... & ROCHA, W. Soil influences on árvore species distribution in a rupestrian Cerrado área. *Floresta e Ambiente*, v. 25, n. 4, p. 2-9, 2018. <https://doi.org/10.1590/2179-8087.060517>

DASS, P.; HOULTON, B. Z.; WANG, Y.; WARLIND, D. Grasslands may be more reliable carbon sinks than forests in California. *Environmental Research Letters*, v. 13, n. 7, p. 074027, 2018. <https://doi.org/10.1088/1748-9326/aacb39>

DELITTI, W. B. C.; MEGURO, M.; PAUSAS, J. G. Biomass and mineralmass estimates in a “Cerrado” ecosystem. *Revista Brasileira de Botânica*, v. 29, n. 4, p. 531-540, 2006. <https://doi.org/10.1590/S0100-84042006000400003>

DIXON, R. K.; BROWN, S.; HOUGHTON, R. A.; SOLOMON, A. M.; TREXLER, M. C.; WISNIEWSKI, J. Carbon pools and flux of global forest ecosystems. *Science*, v. 263, n. 5144, p. 185–190, 1994. <https://www.science.org/doi/10.1126/science.263.5144.185>

D'OLIVEIRA, M. V. N.; REUTEBUCH, S. E.; MCGAUGHEY, R. J.; ANDERSEN, H. E. Estimating forest biomass and identifying low-intensity logging áreas using airborne scanning LiDAR in Antimary State Forest, Acre State, Western Brazilian Amazon. *Remote Sensing of Environment*, v. 124, n.1, p. 479-491, 2012. <https://doi.org/10.1016/j.rse.2012.05.014>.

D'OLIVEIRA, M. V. N.; LOCKS, C. J. Potencial do Uso de Sar Aerotransportado para Modelagem do Terreno e da Biomassa Acima do Solo em Região de Floresta Tropical. p. 1855-1858, 2019.

D'OLIVEIRA, M. V. N.; BROADBENT, E. N.; OLIVEIRA, L. C.; ALMEIDA, D. R. A.; PAPA, D. A.; FERREIRA, M. E.; ZAMBRANO, A. M. A.; SILVA, C. A.; AVINO, F. S.; PRATA, G. A.; MELLO, R. A.; FIGUEIREDO, E. O.; JORGE, L. A. C.; JUNIOR, L.; ALBUQUERQUE, R. W.; BRANCALION, P. H. S.; WILKINSON, B.; OLIVEIRA-DA-COSTA, M. Aboveground Biomass Estimation in Amazonian Tropical Forests: a Comparison of Aircraft- and GatorEye UAV-borne LiDAR Data in the Chico Mendes Extractive Reserve in Acre, Brazil. *Remote Sensing*, v. 12, n. 11, p. 1754, 2020. <https://doi.org/10.3390/rs12111754>

D'OLIVEIRA, M. V. N.; FIGUEIREDO, E. O.; DE ALMEIDA; D. R. A.; OLIVEIRA, L. C.; SILVA, C. A., NELSON, B. W.; DA CUNHA, R. M.; DE ALMEIDA PAPA, D.; STARK S. C.; VALBUENA, R. Impacts of selective logging on Amazon forest canopy structure and biomass with a LiDAR and photogrammetric survey sequence. *Forest Ecology and Management* **500**, 2021. <https://doi.org/10.1026/j.foreco.2021.119648>.

DRAKE, J. B.; DUBAYAH, R. O.; CLARK, D. B.; KNOX, R. G.; BLAIR, J. B.; HOFTON, M. A.; PRINCE, S. Estimation of tropical forest structural characteristics using large-footprint coping.

**Remote Sensing of Environment**, v. 79, n. 2-3, p. 305-319, 2002. [https://doi.org/10.1016/S0034-4257\(01\)00281-4](https://doi.org/10.1016/S0034-4257(01)00281-4)

DUBAYAH, R.; BLAIR, J. B.; GOETZ, S.; FATOYINBO, L.; HANSEN, M.; HEALEY, S.; HOTFON, M.; HURTT, G.; KELLNER, J.; LUTHCKE, S.; ARMSTON, J.; TANG, H.; DUNCANSON, L.; HANCOCK, S.; JANTZ, P.; MARSELIS, S.; PATTERSON, P. L.; WENLU, Q.; SILVA, C. The Global Ecosystem Dynamics Investigation: High-resolution laser ranging of the Earth's forests and topography. **Science of Remote Sensing**, v. 1, n.1, p. 100002, 2020. <https://doi.org/10.1016/j.srs.2020.100002>

DURIGAN, G., RATTER, J. A. The need for a consistent fire policy for Cerrado conservation. **Journal of Applied Ecology**, v. 53, n. 1, p. 11–15, 2016. <https://doi.org/10.1111/1365-2664.12559>

DURIGAN, G.; PILON, N. A. L.; ABREU, R. C. R.; HOFFMANN, W. A.; MARTINS, M.; FIORILLO, B. F.; ANTUNES, A. Z.; CARMIGNOTTO, A. P.; MARAVALTHAS, J. B.; VIEIRA, J.; VASCONCELOS, H. L. No Net Loss of Species Diversity After Prescribed Fires in the Brazilian Savanna. **Frontiers in Forests and Global Change**, v. 3, n. 13, p. 1-15, 2020. <https://doi.org/10.3389/ffgc.2020.00013>

DUVERT, C.; HUTLEY, L. B.; BERINGER, J.; BIRD, M. I.; BIRKEL, C.; MAHER, D. T.; NORTHWOOD, M.; RUDGE, M.; SETTERFIELD, S. A.; WYNN, J. G. Balanço líquido de carbono da paisagem de uma savana tropical: importância relativa do fogo e da exportação aquática na compensação da produção terrestre. **Global Change Biology**, v. 26, n. 10, p. 5899-5913, 2020. <https://doi.org/10.1111/gcb.15287>

ELLIS, P.; GRISCOM, B.; WALKER, W.; GONÇALVES, F.; CORMIER, T. Mapping selective logging impacts in Borneo with GPS and airborne LiDAR. **Forest Ecology and Management**, v. 365, n. 1, p. 184-196, 2016. <https://doi.org/10.1016/j.foreco.2016.01.020>.

ENRIGHT, N. J.; FONTAINE, J. B.; BOWMAN, D. M.; BRADSTOCK, R. A.; & WILLIAMS, R. J. Interval squeeze: Altered fire regimes and demographic responses interact to threaten woody species persistence as climate changes. **Frontiers in Ecology and the Environment**, v. 13, n. 5, p. 265–272, 2015. <https://doi.org/10.1890/140231>

FELFILI, J. M. (2007). **Biogeografia do Bioma Cerrado: vegetação e solos da Chapada dos Veadeiros**. (1ª ed.). UnB: Finatec.

FERREIRA, V., MATEUS, L., AGUIAR, J. 2012. **Site recording using automatic image based three dimensional reconstruction techniques**. Proceedings of the International Conference on Computer Applications & Quantitative Methods in Archaeology, CAA, 308p.

FIDELIS, A.; ALVARADO, S. T.; BARRADAS, A. C. S.; PIVELLO, V. R. The year 2017: Megafires and management in the Cerrado. **Fire**, v. 1, n. 3, p. 49, 2018. <https://doi.org/10.3390/fire1030049>

FISHER, A.; ARMSTON, J.; GOODWIN, N.; SCARTH, P. Modelling canopy gap probability, foliage projective cover and crown projective cover from airborne LiDAR metrics in Australian forests and woodlands. **Remote Sensing of Environment**, v. 237, n. 1, p. 511, 2020. <https://doi.org/10.1016/j.rse.2019.111520>

FLORES, B. M.; DE SÁ DECHOUM, M.; SCHMIDT, I. B.; HIROTA, M.; ABRAHÃO, A.; VERONA, L.; ... & PAMPLONA, M. B. Tropical riparian forests in danger from large savanna wildfires. **Journal of Applied Ecology**, v. 1, n. 1, p. 419-430, 2020. <https://doi.org/10.1111/1365-2664.13794>

- FRANKE, J.; BARRADAS, A. C. S.; BORGES, M. A.; MENEZES COSTA, M.; DIAS, P. A.; HOFFMANN, A. A.; OROZCO FILHO, J. C.; MELCHIORI, A. E.; SIEGERT, F. Fuel load mapping in the Brazilian Cerrado in support of integrated fire management. **Remote Sensing of Environment**, v. 217, n. 1, p. 221–232, 2018. <https://doi.org/10.1016/j.rse.2018.08.018>
- FORZZA, R. C.; BAUMGRATZ, J. F. A.; BICUDO, C. E. M.; CANHOS, D. A.; CARVALHO, J. R. A. A.; COELHO, M. A. N.; ... & ZAPPI, D. C. New Brazilian floristic list highlights conservation challenges. **BioScience**, v. 62, n. 1, p. 39-45, 2012. <https://doi.org/10.1525/bio.2012.62.1.8>
- GARCÍA, M.; RIAÑO, D.; CHUVIECO, E.; DANSON, F. M. Estimating biomass carbon stocks for a Mediterranean forest in central Spain using LiDAR height and intensity data. **Remote Sensing of Environment**, v. 114, n. 4, p. 816-830, 2010. <https://doi.org/10.1016/j.rse.2009.11.021>
- GIANNICO, V.; LAFORTEZZA R.; JOHN, R.; SANESI, G.; PESOLA, L.; CHEN, J. Estimating Stand Volume and Above-Ground Biomass of Urban Forests Using LiDAR. **Remote Sensing**, v.8, n. 4, p. 339, 2016. <https://doi.org/10.3390/rs8040339>
- GIONGO, M.; KOEHLER, H. S.; MACHADO, S. D. A.; KIRCHNER, F. F.; MARCHETTI, M. LiDAR: princípios e aplicações florestais. **Pesquisa Florestal Brasileira**, Colombo, v. 30, n. 63, p. 231-244, 2010. <https://doi.org/10.4336/2010.pfb.30.63.231>
- GOEDERT, W. Cerrado region: agricultural potential and policy for its development. **Pesquisa Agropecuária Brasileira**, v. 24, p. 1-17, 1989.
- GOLDBERGS, G.; LEVICK, SR.; LAWES, M.; EDWARDS, A. Hierarchical integration of individual árvore and area-based approaches for savanna biomass uncertainty estimation from airborne LiDAR. **Remote sensing of environment**, v. 205, n. 1, p. 141-150, 2018. <https://doi.org/10.1016/j.rse.2017.11.010>
- GOMES, L.; MIRANDA, H.; BUSTAMANTE, M. M. C. How can we advance the knowledge on the behavior and effects of fire in the Cerrado biome? **Forest Ecology and Management**, v. 417, n. 1, p. 281–290, 2018. <https://doi.org/10.1016/j.foreco.2018.02.032>
- GOMES, L.; MIRANDA, H. S.; SOARES-FILHO, B.; RODRIGUES, L.; OLIVEIRA, U.; BUSTAMANTE, M. M. Responses of plant biomass in the Brazilian savanna to frequent fires. **Frontiers in Forests and Global Change**, v. 3, n. 1, p. 507710, 2020. <https://doi.org/10.3389/ffgc.2020.507710>
- GONZÁLEZ-JARAMILLO, V.; FRIES, A.; BENDIX, J. AGB estimation in a tropical mountain forest (TMF) by means of RGB and multispectral images using an unmanned aerial vehicle (UAV). **Remote Sensing**, v. 11, n. 12, p. 1413, 2019. <https://doi.org/10.3390/rs11121413>
- GONZALEZ, P.; ASNER, G. P.; BATTLES, J. J.; LEFSKY, M. A.; WARING, K. M.; PALACE, M. Forest carbon densities and uncertainties from LiDAR, QuickBird, and fieldmeasurements in California. **Remote Sensing of Environment**, v. 114, n.1, p. 1561-1575, 2010. <https://doi.org/10.1016/j.rse.2010.02.011>
- GORGENS, E. B.; MUND, J. P.; CREMER, T.; DE CONTO, T.; KRAUSE, S.; VALBUENA, R.; RODRIGUEZ, L. C. E. Automated operational logging plan considering multi-criteria optimization. **Computers and Electronics in Agriculture**, v. 170, n. 1, p. 105253, 2020. <https://doi.org/10.1016/j.compag.2020.105253>
- GOULAMOUSSENE, Y.; BEDEAU, C.; DESCROIX, L.; LINGUET, L.; HÉRAULT, B. Environmental control of natural gap size distribution in tropical forests. **Biogeosciences**, v. 14, n. 353-364, 2017. <https://doi.org/10.5194/bg-14-353-2017>

GUIMARÃES, J. R. C.; RIOS, P. R. Martensite start temperature and the austenite grain-size. **Journal of materials science**, v. 45, n. 4, p. 1074-1077, 2010. <https://doi.org/10.1007/s10853-009-4044-0>

GWENZI, D.; LEFSKY, M. A. Spatial modeling of Lidar-derived woody biomass estimates collected along transects in a heterogeneous savanna landscape. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 10, 1, p. 372-384, 2016. <https://doi.org/10.1109/JSTARS.2016.2582148>

HANSEN, E. H.; GOBAKKEN, T.; NAESSET, E. Effects of Pulse Density on Digital Terrain Models and Canopy Metrics Using Airborne Laser Scanning in a Tropical Rainforest. **Remote Sensing**, v. 7, n. 1, p. 8453-8468, 2015.

HARKEL, J. T.; BARTHOLOMEUS, H.; KOOISTRA, L. Biomass and crop height estimation of different crops using UAV-based LiDAR. **Remote Sensing**, v. 12, n. 1, p. 17, 2020. <https://doi.org/10.3390/rs12010017>

HERNANDO, A.; VELÁZQUEZ, J.; VALBUENA, R.; LEGRAND, M.; GARCÍA-ABRIL, A. Influence of the resolution of forest cover maps in evaluating fragmentation and connectivity to assess habitat conservation status. **Ecological Indicators**, v. 79, n. 1, p. 295-302, 2017. <https://doi.org/10.1016/j.ecolind.2017.04.031>

HIROTA, M.; HOLMGREN, M.; VAN NES, E. H.; SCHEFFER, M. Global resilience of tropical forest and savanna to critical transitions. **Science**, v. 334, n. 6053, p. 232-235, 2011. <https://doi.org/10.1126/science.1210657>

HAKKENBERG, C.; R. PEET, R.; K. URBAN, D.; L. SONG, C. Modeling plant composition as community continua in a forest landscape with LiDAR and hyperspectral remote sensing. **Ecological Applications**, v. 28, n. 1, p. 177-190, 2018. <https://doi.org/10.1002/eap.1638>.

HOFFMANN, W. A. Post-burn reproduction of woody plants in a neotropical savanna: the relative importance of sexual and vegetative reproduction. **Journal of applied ecology**, v. 35, n. 3, p. 422-433, 1998. <https://doi.org/10.1046/j.1365-2664.1998.00321.x>

HOFFMANN, W. A.; ORTHEN, B.; DO NASCIMENTO, P. K. V. Comparative fire ecology of tropical savanna and forest árvores. **Functional Ecology**, v. 17, n. 1, p. 720-726, 2003. <https://doi.org/10.1111/j.1365-2435.2003.00796.x>

HOFFMANN, W. A.; JACONIS, S. Y.; MCKINLEY, K. L.; GEIGER, E. L.; GOTSCH, S. G.; FRANCO, A. C. Fuels or microclimate? Understanding the drivers of fire feedbacks at savanna-forest boundaries. **Austral Ecology**, v. 37, n. 6, p. 634-643, 2012. <https://doi.org/10.1111/j.1442-9993.2011.02324.x>

HONDA, E. A.; DURIGAN, G. Woody encroachment and its consequences on hydrological processes in the savannah. **Philosophical Transactions of the Royal Society B: Biological Sciences**, v. 371, n. 1703, p. 20150313, 2016. <https://doi.org/10.1098/rstb.2015.0313>

HOPKINSON, C.; CHASMER, L. E.; ZSIGOVICS, G.; CREED, I. F.; SITAR, M.; TREITZ, P.; MAHER, R. V. Errors in LiDAR ground elevation and wetland vegetation height estimates. *International Archives of Photogrammetry, Remote Sensing, and Spatial Information Sciences*, v. 36, n. 8, p. 108-113, 2004.

HOUGHTON, R. A. Balancing the global carbon budget. *Annual Review of Earth and Planetary Sciences*, v. 35, n. 1, p. 313-347, 2007. <https://doi.org/10.1146/annurev.earth.35.031306.140057>

HOUSE, J. I.; ARCHER, S.; BRESHEARS, D. D.; SCHOLES, R. J. & NCEAS *Árvore–Grass Interactions* Participants. Conundrums in mixed woody–herbaceous plant systems. **Journal of Biogeography**, v. 30, n. 11, p. 1763-1777, 2003. <https://doi.org/10.1046/j.1365-2699.2003.00873.x>

HU, T.; MA, Q.; SU, Y.; BATTLES, J. J.; COLLINS, B. M.; STEPHENS, S. L.; KELLY, M.; GUO, Q. A simple and integrated approach for fire severity assessment using bi-temporal airborne LiDAR data. **International Journal of Applied Earth Observation and Geoinformation**, p. 78, n. 1, p. 25-38, 2019. <https://doi.org/10.1016/j.jag.2019.01.007>

HUDAK, A. T.; FEKETY, P. A.; KANE, V. R.; KENNEDY, R. E.; FILIPPELLI, S. K.; FALKOWSKI, M. J.; TINKHAM, W. T.; SMITH, A. M. S.; CROOKSTON, N. L.; DOMKE, G. M. A carbon monitoring system for mapping regional, annual aboveground biomass across the northwestern USA. **Environmental Research Letters**, v. 15, n. 9, p. 095003, 2020. <https://doi.org/10.1088/1748-9326/ab93f9>.

HUDAK, A. T.; DICKINSON, M. B.; BRIGHT, B. C.; KREMENS, R. L.; LOUDERMILK, E. L.; O'BRIEN, J. J.; OTTMAR, R. D. Measurements relating fire radiative energy density and surface fuel consumption—RxCADRE 2011 and 2012. **International Journal of Wildland Fire**, v. 25, n. 1, p. 25-37, 2016. <https://doi.org/10.1071/WF14159>.

HUDAK, A. T.; STRAND, E. K.; VIERLING, L. A.; BYRNE, J. C.; EITEL, J. U. H.; MARTINUZZI, S.; FALKOWSKI, M. J. Quantifying aboveground forest carbon pools and fluxes from repeat LiDAR surveys. **Remote Sensing of Environment**, v. 123 n. 1, 25–40, 2012. <https://doi.org/10.1016/j.rse.2012.02.023>

HUDAK, A. T.; CROOKSTON, N. L.; EVANS, J. S.; FALKOWSKI, M. J.; SMITH, A. M.; GESSLER, P. E.; MORGAN, P. Regression modeling and mapping of coniferous forest basal area and *árvore* density from discrete-return lidar and multispectral satellite data. **Canadian Journal of Remote Sensing**, v. 32, n. 2, p. 126-138, 2006. <https://doi.org/10.5589/m06-007>

IBAMA. 1998. **Parque Nacional da Chapada dos Veadeiros: Plano de manejo – Fase 3. 1ª ed.** IBAMA, Brasília, DF.

IBGE. Mapas de Solos do Brasil. Disponível em: <<https://portaldemapas.ibge.gov.br/portal.php#homepage>>. Acesso em: 19 jun. 2022.

ICMBIO. **Unidades de Conservação**. Disponível em: <<https://www.gov.br/icmbio/pt-br>>. Acesso em: 9 jan. 2023.

INPE. **Área Queimada – Programa Queimadas**. Disponível em: <<https://queimadas.dgi.inpe.br/queimadas/aq1km/>>. Acesso em: 18 jan. 23.

INPE. **Monitoramento dos focos ativos por estado, região ou bioma**. Disponível em: <[https://queimadas.dgi.inpe.br/queimadas/portal-static/estatisticas\\_estados/](https://queimadas.dgi.inpe.br/queimadas/portal-static/estatisticas_estados/)>. Acesso em: 19 jan. 23.

INPE. **Boletins diários das áreas protegidas e territórios Indígenas com focos ativos**. Disponível em: <https://queimadas.dgi.inpe.br/queimadas/aq1km/>. Acesso em: 18 jan. 23.

ISENBURG, M. 2020. **LAStools—Efficient Tools for Lidar Processing**. Disponível em: <<http://www.cs.unc.edu/~isenburg/lastools/>>. Acesso em 16 dez. 2020.

JELTSCH, F.; WEBER, G. E.; GRIMM, V. Ecological buffering mechanisms in savannas: a unifying theory of long-term *árvore*-grass coexistence. **Plant Ecology**, v. 150, n. 1, p. 161-171, 2000. <https://doi.org/10.1023/A:1026590806682>



JESUS, T. C. L.; SENNA, M. C. A.; CATALDI, M.; PAIVA, C. M.; FRANZ, B. Impacto do aumento da concentração atmosférica de CO<sub>2</sub> no balanço hídrico climatológico do Cerrado. **Revista Brasileira de Climatologia**, v. 21, n.1, p. 313-326, 2017. <http://dx.doi.org/10.5380/abclima.v21i0.46432>

KENT, R.; LINDSELL, J.; LAURIN, G.; VALENTINI, R.; COOMES, D. Airborne LiDAR detects selectively logged tropical forest even in an advanced stage of recovery. **Remote Sensing**, v. 7, n. 7, p. 8348-8367, 2015. <https://doi.org/10.3390/rs70708348>

KETTERINGS, Q. M.; COE, R.; NOORDWIJK, M. VAN; AMBAGAU', Y.; PALM, C. A. Reducing uncertainty in the use of allometric biomass equations for predicting aboveground árvore biomass in mixed secondary forests. **Forest Ecology and Management**, v. 146, n. 1–3, p. 199–209, 2001. [https://doi.org/10.1016/S0378-1127\(00\)00460-6](https://doi.org/10.1016/S0378-1127(00)00460-6)

KNAPP, N.; Knapp, N.; Fischer, R.; Cazcarra-Bes, V.; Huth, A. Structure metrics to generalize biomass estimation from lidar across forest types from different continents. **Remote Sensing of Environment**, v. 237, n. 1, p. 111597, 2020. <https://doi.org/10.1016/j.rse.2019.111597>

KLINK, C. A.; MACHADO, R. B. Conservation of the Brazilian Cerrado. **Conservation Biology**, v. 19, n. 3, p. 707–713, 2005. <https://doi.org/10.1111/j.1523-1739.2005.00702.x>

KOH, L. P.; WICH, S. A. Dawn of drone ecology: low-cost autonomous aerial vehicles for conservation. **Tropical Conservation Science**, v. 5, n. 2, p. 121-132, 2012. <https://doi.org/10.1177/194008291200500202>

LAHSEN, M.; BUSTAMANTE, M. M. C.; DALLA-NORA, E. L. Undervaluing and overexploiting the Brazilian Cerrado at our peril. **Environment: Science and Policy for Sustainable Development**, v. 58, n. 6, p. 4-15, 2016. <https://doi.org/10.1080/00139157.2016.1229537>

LASSLOP, G.; HANTSON, S.; HARRISON, S. P.; BACHELET, D.; BURTON, C.; FORKEL, M.; FORREST, M.; LI, F.; MELTON, J. R.; YUE, C.; ARCHIBALD, S.; SCHEITER, S.; ARNETH, A.; HICKLER, T.; SITCH, S. Global ecosystems and fire: Multi-model assessment of fire-induced árvore-cover and carbon storage reduction. **Global Change Biology**, v. 26, n.1, p. 5027-5041, 2020.

LEVICK, S. R.; RICHARDS, A. E.; COOK, G. D.; SCHATZ, J.; GUDERLE, M.; WILLIAMS, R. J.; SUBEDI, P.; TRUMBORE, S. E.; ANDERSEN, A. N. Rapid response of habitat structure and above-ground carbon storage to altered fire regimes in tropical savanna. **Biogeosciences**, v. 16, p. 7, p. 1493–1503, 2019. <https://doi.org/10.5194/bg-16-1493-2019>

LEVICK, S. R.; SHENDRYK, Y.; SETTERFIELD, S.; ROSSITER-RACHOR, N. 2018. **Evaluation of satellite remote sensing pathways for mapping and monitoring of gamba grass for the Savanna Fire Management Methodology**. 1<sup>a</sup> ed. Environmental Research Portal CSIRO and Charles Darwin University, Northern Australia, 27p.

LE STRADIC, S.; HERNANDEZ, P.; FERNANDES, G.W.; BUISSON, E. Regeneration after fire in campo rupestre: Short- and long-term vegetation dynamics. **Flora**, v. 238, n. 1, p. 191–200, 2018. <https://doi.org/10.1016/j.flora.2016.12.001>

LEHMANN, C. E.; ANDERSON, T. M.; SANKARAN, M.; HIGGINS, S. I.; ARCHIBALD, S., HOFFMANN, W. A.; ... & BOND, W. J. Savanna vegetation-fire-climate relationships differ among continents. **Science**, v. 343, n. 6170, p. 548-552, 2014. <https://doi.org/10.1126/science.1247355>

LIM, K. S.; TREITZ, P. M. Estimation of above ground forest biomass from airborne discrete return laser scanner data using canopy-based quantile estimators. **Scandinavian Journal of Forest Research**, v. 19, n. 6, p. 558–570, 2004. <https://doi.org/10.1080/02827580410019490>

LINDENMAYER, D. B.; WOOD, J. T.; CUNNINGHAM, R. B.; MACGREGOR, C.; CRANE, M.; MICHAEL, D.; MONTAGUE-DRAKE, R.; BROWN, D.; MUNTZ, R.; GILL, A. M. Testing hypotheses associated with bird responses to wildfire. **Ecological Applications**, v. 18, n. 8, p. 1967-1983, 2008. <https://doi.org/10.1890/07-1943.1>

LOCKS, C. J.; AMARAL, L. G. C. Análise multitemporal de dados LiDAR para avaliação da recuperação no sub-bosque florestal em concessões florestais. In. **Simpósio Brasileiro de Sensoriamento Remoto, XVII**, 2015, João Pessoa-PB. Anais... p. 1494-1501. Disponível em: ><https://www.dsr.inpe.br/sbsr2015/files/p0277.pdf><. Acesso em 19 jan. 2023.

LOCKS, C. J.; MATRICARDI, E. A. Estimativa de impactos da extração seletiva de madeiras na Amazônia utilizando dados LiDAR. **Ciência Florestal**, v. 29, n.2, p. 481-495, 2019. <https://doi.org/10.5902/1980509826007>

LUCK, L.; HUTLEY, L. B.; CALDERS, K.; LEVICK, S. R. Exploring the Variability of Tropical Savanna Árvore Structural Allometry with Terrestrial Laser Scanning. **Remote Sensing**, v, 12, n. 23, p. 3893, 2020. <https://doi.org/10.3390/rs12233893>

LUMLEY, T. 2020. **Leaps**: Regression Subset Selection. Thomas Lumley based on Fortran code by Alan Miller. R package version 3.1. Disponível em: <<https://CRAN.R-project.org/package=leaps> accessed>. Acesso em 16 dez 2020.

MADSEN, B.; TREIER, U. A.; ZLINSZKY, A.; LUCIEER, A.; NORMAND, S. Detecting shrub encroachment in seminatural grasslands using UAS LiDAR. **Ecology and Evolution**, v. 10, n. 11, p. 4876-4902, 2020. <https://doi.org/10.1002/ece3.6240>

MAEDA, E. E.; NUNES, M. H.; CALDERS, K.; DE MOURA, Y. M.; RAUMONEN, P.; TUOMISTO, H., ... & CAMARGO, J. L. Shifts in structural diversity of Amazonian forest edges detected using terrestrial laser scanning. **Remote Sensing of Environment**, v. 271, n. 1, p. 112895, 2022. <https://doi.org/10.1016/j.rse.2022.112895>.

MAGALHÃES, S. R. D.; RIBEIRO, C. A. A. S.; CASTRO, J. M. C. D. S. F. D.; FERNANDES, P. A. M.; SILVA, C. A. R. L. D.; PINHEIRO, H. M. P.; & AZEVEDO, J. C. M. D. Comportamento do fogo em diferentes períodos e configurações 38 de uma paisagem no nordeste de Portugal. **Ciência Florestal**, v. 27, n. 2, p. 457–469, 2017. <https://doi.org/10.5902/1980509827728>

MARAVALHAS J.; VASCONCELOS, H. L. Revisiting the pyrodiversity-biodiversity hypothesis: Longterm fire regimes and the structure of ant communities in a Neotropical savanna hotspot. **Journal of Applied Ecology**, v. 51, n. 6, p. 1661–1668, 2014. <https://doi.org/10.1111/1365-2664.12338>

MARSELIS, S. M.; ABERNETHY, K.; ALONSO, A.; ARMSTON, J.; BAKER, T. R.; BASTIN, J. F.; BOGAERT, J.; BOYD, D. S.; BOECKX, P.; BURSLEM, DFRP.; CHAZDON, R.; CLARK, D. B.; COOMES, D.; DUNCANSON, L.; HANCOCK, S.; HILL, R.; HOPKINSON, C.; KEARSLEY, E.; KELLNER, J. R.; KENFACK, D.; LABRIÈRE, N.; LEWIS, S. L.; MINOR, D.; MEMIAGHE, H.; MONTEAGUDO, A.; NILUS, R.; O'BRIEN, M.; PHILLIPS, O. L.; POULSEN, J.; TANG, H.; VERBEECK, H.; DUBAYAH, R. Evaluating the potential of full-waveform lidar for mapping pan-tropical árvore species richness. **Global Ecology and Biogeography**, v. 29, n. 10, p. 1799-1816, 2020. <https://doi.org/10.1111/geb.13158>

MAO, X.; HOU, J. Object-based forest gaps classification using airborne LiDAR data. **Journal of Forestry Research**, v. 30, n. 1, p. 617-627, 2018. <https://doi.org/10.1007/s11676-018-0652-3>.

MARSELIS, S. M.; TANG, H.; ARMSTON, J.; ABERNETHY, K.; ALONSO, A.; BARBIER, N.; BISSIENGOU, P.; JEFFERY, K.; KENFACK, D.; LABRIÈRE, N. Exploring the relation between remotely sensed vertical canopy structure and árvore species diversity in Gabon. **Environmental Research Letters**, v. 14, n. 9, p. 094013, 2019. <https://doi.org/10.1088/1748-9326/ab2dcd>

MARSELIS, S. M.; TANG, H.; ARMSTON, J. D.; CALDERS, K.; LABRIÈRE, N.; DUBAYAH, R. Distinguishing vegetation types with airborne waveform lidar data in a tropical forest-savanna mosaic: A case study in Lopé National Park, Gabon. **Remote sensing of environment**, v. 216, n. 1, p. 626-634, 2018. <https://doi.org/10.1016/j.rse.2018.07.023>

MEDEIROS, M.; MIRANDA, H. Mortalidade pós-fogo em espécies lenhosas de campo sujo submetido a três queimadas prescritas anuais. **Acta Botanica**, v. 19, n. 1, p. 493-500, 2005. <https://doi.org/10.1590/S0102-33062005000300009>

METZGER, J. P.; BUSTAMANTE, M. M.; FERREIRA, J.; FERNANDES, G. W.; LIBRÁN-EMID, F.; PILLAR, V. D.; PRIST, P. R.; RODRIGUES, R. R.; VIEIRA, I. C. G.; OVERBECK, G. E. Why Brazil needs its Legal Reserves. **Perspectives in Ecology and Conservation**, v. 17, n. 3, p. 91-103, 2019. <https://doi.org/10.1016/j.pecon.2019.07.002>

MIRANDA, H. S. 2010. **Efeitos do regime do fogo sobre a estrutura de comunidades de Cerrado: Resultados do projeto Fogo**. 1ª ed. IBAMA, Brasília-DF, 145p.

MEYR, V.; SAATCHI, S.; CLARK, D. B.; KELLER, M.; VINCENT, G.; FERRAZ, A.; ... & CHAVE, J. Canopy area of large árvores explains aboveground biomass variations across neotropical forest landscapes. **Biogeosciences**, v. 15, n. 11, p. 3377-3390, 2018. <https://doi.org/10.5194/bg-15-3377-2018>

MLAMBO, R.; WOODHOUSE, I. H.; GERARD, F.; ANDERSON, K. Structure from motion (SfM) photogrammetry with drone data: A low cost method for monitoring greenhouse gas emissions from forests in developing countries. **Forests**, v. 8, n. 3, p. 68, 2017. <https://doi.org/10.3390/f8030068>

MMA. **Plano de ação para prevenção e controle do desmameamento e das queimadas: Cerrado**. Brasília: MMA, 2011.

MOHAN, M.; SILVA CA.; KLAUBERG, C.; JAT, P.; CATTS, G.; CARDIL A.; HUDAK A.; DIA, M. Individual Árvore Detection from Unmanned Aerial Vehicle (UAV) Derived Canopy Height Model in an Open Canopy Mixed Conifer Forest. **Forests**, v. 8, n. 9, p. 340, 2017. <https://doi.org/10.3390/rs11101161>

NAESSET, E., GOBAKKEN, T. Estimation of above-and below-ground biomass across regions of the boreal forest zone using airborne laser. **Remote Sensing of Environment**, v. 112, n. 6, p. 3079-3090, 2008. <https://doi.org/10.1016/j.rse.2008.03.004>

NASA. New NASA Probe Will Study Earth's Forests in 3-D. Disponível em: <<http://www.nasa.gov/content/goddard/new-nasa-probe-will-study-earth-s-forests-in-3d/>>. Acesso em: 24 out. 2022

NELSON, R.; KRABILL, W.; MACLEAN, G. Determining forest canopy characteristics using airborne laser data. **Remote Sensing of Environment**, v. 15, n. 3, p. 201-212, 1984. [https://doi.org/10.1016/0034-4257\(84\)90031-2](https://doi.org/10.1016/0034-4257(84)90031-2)

NERI, A. V.; SCHAEFER, C. E. G. R.; SOUZA, A. L.; FERREIRA-JUNIOR, W. G.; MEIRANETO, J. A. A. Pedology and plant physiognomies in the Cerrado, Brazil. **Anais da Academia**

**Brasileira de Ciências**, v. 85, n. 1, p. 87-102, 2013. <https://doi.org/10.1590/S0001-37652013000100007>.

NOOJIPADY, P.; MORTON, C. D.; MACEDO, N. M.; VICTORIA, C. D.; HUANG, C.; GIBBS, K. H.; & BOLFE, L. E. Forest carbon emissions from cropland expansion in the Brazilian Cerrado biome. **Environmental Research Letters**, v. 12, n. 2, p. 025004, 2017. <https://doi.org/10.1088/1748-9326/aa5986>

OKUDA, T.; YAMADA, T.; HOSAKA, T.; MIYASAKU, N.; HASHIM, M. Forest Ecology and Management Canopy height recovery after selective logging in a lowland tropical rain forest. **Forest Ecology and Management**. v. 442, n.1, p. 117-123, 2019. <https://doi.org/10.1016/j.foreco.2019.03.045>.

OLIVEIRA, C. P. DE.; FRANCELINO, M. R.; DAHER, M. DE.; ARAÚJO, E. J. G. D. S.; SANCHES, L. DE.; ANDRADE, KAUANNA DOMINGUES CABRAL DE. CAMPOS, J. S. N. Estimation of the aboveground biomass and carbon stocks in open Brazilian Savannah developed on sandy soils. **Carbon Balance and Management**, v. 14, n. 1, p. 1–10, 2019. <https://doi.org/10.1186/s13021-019-0121-0>

OLIVEIRA-FILHO, A. T.; RATTER, J. 2002. **Vegetation physiognomies and woody flora of the Cerrado biome**. In OLIVEIRA, P. S.; MARQUIS, T. J. (Eds.), *The Cerrados of Brazil: Ecology and natural history of a neotropical savanna*. Columbia University Press. 91–120p.

OTTMAR, R. D.; VIHMANEK, R. E.; MIRANDA, H. S.; SATA, M. N.; ANDRADE, S. M. Stereo photo series for quantifying Cerrado fuels in central Brazil. In: Volume I. (Eds.), United States Department of Agriculture, **Forest Service**, v. 519, p. 1-87, 2011.

PAIVA, A. O.; REZENDE, A. V.; PEREIRA, R. S. Estoque de carbono em Cerrado sensu stricto do Distrito Federal. **Revista Árvore**, v. 35, n. 3, p. 527-538, 2011. <https://doi.org/10.1590/S0100-67622011000300015>

PAOLUCCI, L. N.; PEREIRA, R. L.; RATTIS, L.; SILVÉRIO, D. V. et al. Lowland tapirs facilitate seed dispersal in degraded Amazonian forests. **Biotropica**, v. 51, n. 2, p. 245-252, 2019. <https://doi.org/10.1111/btp.12627>

PAPA, D. de A.; ALMEIDA, D. R. A.; de SILVA, C. A.; FIGUEIREDO, E. O.; STARK, S. C.; VALBUENA, R.; RODRIGUEZ, L. C. E.; D'OLIVEIRA, M. V. N. Evaluating tropical forest classification and field sampling stratification from LiDAR to reduce effort and enable landscape monitoring. **Forest Ecology and Management**. v. 457, n. 1, p. 117634, 2020. <https://doi.org/10.1016/i.foreco.2019.117634>.

PAUSAS, J. G.; KEELEY, J. E. A burning story: The role of fire in the history of life. **BioScience**, v. 59, n. 7, p. 593–601, 2009. <https://doi.org/10.1525/bio.2009.59.7.10>

PAUSAS, J. G. Bark thickness and fire regime. **Functional Ecology**, v. 29, n. 3, p. 315-327, 2015. <https://doi.org/10.1111/1365-2435.12372>

PERSSON, H. J.; STAHL, G. Characterizing Uncertainty in Forest Remote Sensing Studies. **Remote Sensing**, v. 12, n. 3, p. 505, 2020. <https://doi.org/10.3390/rs12030505>

PINAGÉ, E. R.; KELLER, M.; DUFFY, P.; LONGO, M.; DOS-SANTOS, M.; MORTON, D. Long-Term Impacts of Selective Logging on Amazon Forest Dynamics from Multi-Temporal Airborne LiDAR. **Remote Sensing**. v. 11, n. 6, p. 709, 2019. <https://doi.org/10.3390/rs11060709>.

PINAGÉ, E. R.; MATRICARDI, E. A. T. Detecção da Infraestrutura para Exploração Florestal em Rondônia Utilizando Dados de Sensoriamento Remoto. **Floresta e Ambiente**, Rio de Janeiro. v. 22, n. 3, p. 377-390, 2015. <https://doi.org/10.1590/2179-8087.064013>.

PIVELLO, V. R. The Use of Fire in the Cerrado and Amazonian Rainforests of Brazil: Past and Present. **Fire ecology**, v. 7, n. 1, p. 24–39, 2011. <https://doi.org/10.4996/fireecology.0701024>

PLANET TEAM. (2017). **Planet Application Program Interface: In Space for Life on Earth**. San Francisco. Disponível em:<<https://api.planet.com>>. Acesso em 6 dez 2020.

PORTO, A. C.; LINARES, J. A. H.; NETO, G. B. S. Análise da estrutura e dinâmica da paisagem do Parque Nacional da Chapada dos Veadeiros. **Anais do Simpósio Brasileiro de Sensoriamento Remoto-SBSR**. INPE, v.1, n.1, p. 3057, 2011.

POULTER, B.; FRANK, D.; CIAIS, P.; MYNENI, R. B.; ANDELA, N., BI, J.; BROQUET, G.; CANADELL, J. G.; CHEVALLIER, F.; LIU, Y. Y.; RUNNING, S.; STICH, S.; VAN DER WEF, G. R. Contribution of semi-arid ecosystems to interannual variability of the global carbon cycle. **Nature**, v. 509, n. 7502, p. 600-603, 2014. <https://doi.org/10.1038/nature13376>

PRATA, G. A.; BROADBENT, E. N.; DE ALMEIDA, D. R. A.; ST. PETER, J.; DRAKE, J.; MEDLEY, P.; CORTE, A. P. D.; VOGEL, J.; SHARMA, A.; SILVA, C. A.; ZAMBRANO, A. M. A.; VALBUENA, R.; WILKINSON, B. Single-Pass UAV-Borne GatorEye LiDAR Sampling as a Rapid Assessment Method for Surveying Forest Structure. **Remote Sensing**, v. 12, n. 2, p. 4111, 2020. <https://doi.org/10.3390/rs12244111>

PUGH, T. A.; LINDESKOG, M.; SMITH, B.; POULTER, B.; ARNETH, A.; HAVERD, V.; CALLE, L. Role of forest regrowth in global carbon sink dynamics. **Proceedings of the National Academy of Sciences**, v. 116, n. 10, p. 4382-4387, 2019. <https://doi.org/10.1073/pnas.1810512116>

PULITI, S.; SAARELA, S.; GOBAKKEN, T.; STAHL, G.; NAESSET, E. Combining UAV and Sentinel-2 auxiliary data for forest growing stock volume estimation through hierarchical model-based inference. **Remote Sensing of Environment**, v. 204, n. 1, p. 485-497, 2018. <https://doi.org/10.1016/j.rse.2017.10.007>

PYNE, S. J.; ANDREWS, P. L.; LAVEN, R. D. 1996. **Introduction to Wildland Fire**. 2<sup>a</sup> ed. John Wiley & Sons, New York/US, 808p.

QU, Y.; SHAKER, A.; SILVA, C. A.; KLAUBERG, C.; PINAGÉ, E. R. Remote sensing of leaf area index from LiDAR height percentile metrics and comparison with MODIS product in a selectively logged tropical forest area in Eastern Amazonia. **Remote Sensing**, v. 10, n. 6, p. 970, 2018. <https://doi.org/10.3390/rs10060970>

QURESHI, A.; BADOLA, R.; HUSSAIN, S. A. A review of protocols used for assessment of carbon stock in forested landscapes. **Environmental Science and Policy**, v. 16, n. 1, p. 81–89, 2012. <https://doi.org/10.1016/j.envsci.2011.11.001>

RAHMAN, M. F.; ONODA, Y.; & KITAJIMA, K. Forest canopy height variation in relation to topography and forest types in central Japan with LiDAR. **Forest Ecology and Management**, v. 503, n. 1, p. 119792, 2022.. <https://doi.org/10.1016/j.foreco.2021.119792>.

RATNAM, J.; BOND, W. J.; FENSHAM, R. J.; HOFFMANN, W. A.; ARCHIBALD, S.; LEHMANN, C. E.; ... & SANKARAN, M. When is a ‘forest’ a savanna, and why does it matter? **Global Ecology and Biogeography**, v. 20, n. 5, p. 653-660, 2011. <https://doi.org/10.1111/j.1466-8238.2010.00634.x>

REICHSTEIN, M.; BAHN, M.; CIAIS, P.; FRANK, D.; MAHECHA, M. D.; SENEVIRATNE, S. I.; ZSCHEISLER, J.; CRISTÁ, C.; BUCHMANN, N.; FRANK, D. C.; PAPALE, D.; RAMMING, A.; SMITH, P.; THONICKE, K.; VAN DER VELDE, M.; VICCA, S.; WALZ, A.; WATTENBACH, M. Climate extremes and the carbon cycle. **Nature**, v. 500, n. 7462, p. 287-295, 2013. <https://doi.org/10.1038/nature12350>

REUTEBUCH, S. E.; MCGAUGHEY, R. J.; ANDERSEN, H. –E., CARSON, W. W. Accuracy of a high-resolution LiDAR terrain model under a conifer forest canopy. **Canadian Journal of Remote Sensing**, v. 29, n. 5, p. 527-535. 2003.

REX, F. E.; SILVA, C. A.; DALLA CORTE, A. P.; KLAUBERG, C.; MOHAN, M.; CARDIL, A.; ... & HUDAK, A. T. Comparison of statistical modelling approaches for estimating tropical forest aboveground biomass stock and reporting their changes in low-intensity logging areas using multi-temporal LiDAR data. **Remote Sensing**, v. 12, n. 9, p. 1498, 2020. <https://doi.org/10.3390/rs12091498>

REX, F. E.; DALLA CORTE, A. P.; DEBASTIANI, A. B.; KAZAMA, V. S.; SANQUETTA, C. R. Uso de dados LiDAR na estimativa de variáveis biofísica na Amazônia, sob diferentes resoluções espaciais. **Nativa**, v. 6, n. 1, p. 841, 2018. <https://doi.org/10.31413/nativa.v6i0.6312>.

RIBEIRO, J. F.; WALTER, B. M. T. 2008. **As principais fitofisionomias do bioma Cerrado**. In: SANO, S. M.; ALMEIDA, S. P.; RIBEIRO, J. F. (Eds.), *Cerrado: Ecologia e flora* Embrapa Informação TeCCológica, 151-212p.

RIBEIRO, M. C.; FIGUEIRA, J. E. C. Uma abordagem histórica do fogo no Parque Nacional da Serra do Cipó, Minas Gerais–Brasil. **Biodiversidade Brasileira-BioBrasil**, v. 2, n. 2, p. 212-227, 2011. <https://doi.org/10.37002/biobrasil.v%25vi%25i.96>

RIBEIRO, S. C.; JACOVINE, L. A. G.; TORRES, C. M. M. E.; SOUZA, A. L. Influence of interspecific variation on árvore carbon stock of a Brazilian Cerrado. **Revista Árvore**, v. 41, n. 5, p. 1–11, 2017. <https://doi.org/10.1590/1806-90882017000500006>

RIBEIRO, S. C.; FEHRMANN, L.; SOARES, C. P. B.; JACOVINE, L. A. G.; KLEINN, C.; GASPAR, R. O. Above-and belowground biomass in a Brazilian Cerrado. **Forest Ecology and Management**, v. 262, n. 3, p. 491-499, 2011. <https://doi.org/10.1016/j.foreco.2011.04.017>

RING, J. The Laser in Astronomy. *New Scientist*, United Kingdom, v. 18, n. 344, p. 672-673, 1963.

RODIG, E.; CUNTZ, M.; RAMMIG, A.; FISCHER, R.; TAUBERT, F.; & HUTH, A. The importance of forest structure for carbon fluxes of the Amazon rainforest. **Environmental Research Letters**, v. 13, n. 5, p. 054013, 2018. <https://doi.org/10.1088/1748-9326/aabc61>.

RODRÍGUEZ-VEIGA, P.; QUEGAN, S.; CARREIRAS, J.; PERSSON, H. J.; FRANSSON, J. E. S.; HOSCILO, A.; ZIÓLKOWSKI, D.; STERENCZAK, K.; LOHBERGER, S.; STANGEL, M.; BERNINGER, A.; SIEGERT, F.; AVITABILE, V.; HEROLD, M.; MERMOZ, S.; BOUVET, A.; LE TOAN, T.; CARVALHAIS, N.; SANTORO, M.; CARTUS, O.; RAUSTE, Y.; MATHIEU, R.; ASNER, G. P.; THIEL, C.; PATHE, C.; SCHMULLIUS, C.; SEIFERT, F. M.; TANSEY, K.; BALZTER, H. Forest biomass retrieval approaches from Earth observation in different biomes. **International Journal of Applied Earth Observation and Geoinformation**, v. 77, n. 1, p. 53-68. 2019. <https://doi.org/10.1016/j.jag.2018.12.008>.

RODRÍGUEZ-GONZÁLVEZ, P.; JIMÉNEZ FERNÁNDEZ-PALACIOS, B.; MUÑOZ-NIETO, Á. L.; ARIAS-SANCHEZ, P.; & GONZALEZ-AGUILERA, D. Mobile LiDAR system. *New*

possibilities for the documentation and dissemination of large cultural heritage sites. **Remote Sensing**, v. 9, n. 3, p. 189, 2017. <https://doi.org/10.3390/rs9030189>.

ROITMAN, I.; BUSTAMANTE, M. M.; HAIDAR, R. F.; SHIMBO, J. Z.; ABDALA, G. C.; EITEN, G.; LINDOSO, G. S. Optimizing biomass estimates of savanna woodland at different spatial scales in the Brazilian Cerrado: Re-evaluating allometric equations and environmental influences. **PLoS one**, v. 13, n. 8, p. 1-21, 2018. <https://doi.org/10.1371/journal.pone.0196742>

ROSAN, T. M.; ARAGAO, L. E.; OLIVERAS, I.; PHILLIPS, O. L.; MALHI, Y.; GLOOR, E.; WAGNER, F. H. Extensive 21st-century woody encroachment in South America's savanna. **Geophysical Research Letters**, v. 46, n. 12, p. 6594-6603, 2019. <https://doi.org/10.1029/2019GL082327>

SAARELA, S., HOLM, S., GRAFSTRÖM, A., SCHNELL, S., NAESSET, E., GREGOIRE, TG., NELSON, RF., STAHL, G. Hierarchical utilizing three sources of information. **Annals of Forest Science**, v. 73, n. 4, p. 895–910, 2016. <https://doi.org/10.1007/s13595-016-0590-1>

SAIRAM, N.; NAGARAJAN, S.; & ORNITZ, S. Development of mobile mapping system for 3D road asset inventory. **Sensors**, v. 16, n. 3, p. 367, 2016. <https://doi.org/10.3390/s16030367>.

SANKARAN, M.; HANAN, N. P.; SCHOLLES, R. J.; RATNAM, J.; AUGUSTINE, D. J.; CADE, B. S.; ... & ZAMBATIS, N. Determinants of woody cover in African savannas. **Nature**, v. 438, n. 7069, p. 846-849, 2005. <https://doi.org/10.1007/s00442-017-3807-6>

SANKARAN, M.; RATNAM, J.; HANAN, N. P. Árvore–grass coexistence in savannas revisited—insights from an examination of assumptions and mechanisms invoked in existing models. **Ecology Letters**, v. 7, n. 6, p. 480-490, 2004. <https://doi.org/10.1111/j.1461-0248.2004.00596.x>

SANTOS J. R.; FEITAS, C. C.; ARAUJO, S. L.; DUTRA, V. L.; MURA, C. J.; GAMA F. F.; SOLER, S. L.; SANT'ANNA, J. S. S. Airborne P-band SAR applied to the aboveground biomass studies in the Brazilian tropical rainforest. **Remote Sensing of Environment**, v.87, n. 1, p. 482-493, 2003.

SCARANELLO, M. A. S.; KELLER, M.; LONGO, M.; SANTOS, M. N.; LEITOLD, V.; MORTON, D. C.; PINAGÉ, E. R.; ESPÍRITO-SANTO, F. D. B. Estimation of coarse dead wood stocks in intact and degraded forests in the Brazilian Amazon using airborne lidar. **Biogeosciences**, v. 16, n. 17, p. 3457-3474, 2019. <https://doi.org/10.5194/bg-16-3457-2019>.

SCHAEFER, C. E.; CÂNDIDO, H. G.; CORRÊA, G. R.; NUNES, J. A.; ARRUDA, D. M. **Soils associated with rupestrian grasslands**. In: Fernandes, G.W. (Ed.), *Ecology and Conservation of Mountaintop Grasslands in Brazil*. Springer, Switzerland, pp. 55–69, 2016. <http://dx.doi.org/10.1007/978-3-319-29808-53>.

SCHOLLES, R. J.; ARCHER, S. Árvore-grass interactions in savannas. **Annual Review of Ecology and Systematics**, v. 28, p. 517-544, 1997.

SHAO, G.; SHAO, G.; GALLION, J.; SAUNDERS, M. R.; FRANKENBERGER, J. R.; & FEI, S. Improving Lidar-based aboveground biomass estimation of temperate hardwood forests with varying site productivity. **Remote Sensing of Environment**, v. 204, n. 1, p. 872–882, 2018. <https://doi.org/10.1016/j.rse.2017.09.011>

SHIN, P.; SANKEY, T.; MOORE, M. M.; THODE, A. E. Evaluating unmanned aerial vehicle images for estimating forest canopy fuels in a ponderosa pine stand. **Remote Sensing**, v. 10, n. 8, p. 1266, 2018. <https://doi.org/10.3390/rs10081266>

SHAPIRO, S. S.; WILK, M. B. An Analysis of Variance Test for Normality (Complete Samples). **Biometrika**, v. 52, n. 3,4, p. 591, 1965. <https://doi.org/10.2307/2333709>

SHENDRYK, Y.; SOFONIA, J.; GARRARD, R.; RIST, Y.; SKOCAJ, D.; THORBURN, P. Fine-scale prediction of biomass and leaf nitrogen content in sugarcane using UAV LiDAR and multispectral imaging. **International Journal of Applied Earth Observation and Geoinformation**, v. 92, n. 1, p. 102177, 2020.

SILVA, C. A.; DUNCANSON, L.; HANCOCK, S.; NEUENSCHWANDER, A.; THOMAS, N.; HOFTON, M.; FATOYINBO, L.; SIMARD, M.; MARSHAK, C. Z.; ARMSTON, J.; LUTCHKE, S.; DUBAYAH, R. Fusing simulated GEDI, ICESat-2 and NISAR data for regional aboveground biomass mapping. **Remote Sensing of Environment**, v. 253, n. 1, p. 112234, 2021. <https://doi.org/10.1016/j.rse.2020.112234>

SILVA, C. A.; SAATCHI, S.; GARCIA, M.; LABRIERE, N.; KLAUBERG, C.; FERRAZ, A.; MEYER, V.; JEFFERY, K. J.; ABERNETHY, K.; WHITE, L.; ZHAO, K.; LEWIS, S. L.; HUDAK, A. T. Comparison of small- and large-footprint lidar characterization of tropical forest aboveground structure and biomass: A case study from Central Gabon. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 11 n.10, p. 3512-3526, 2018. <https://doi.org/10.1109/JSTARS.2018.2816962>

SILVA, C. A.; KLAUBERG, C.; HUDAK, A. T.; VIERLING, L. A.; JAAFAR, W. S. W. M.; MOHAN, M.; GARCIA, M.; FERRAZ, A.; CARDIL, A.; SAATCHI, S. Predicting Stem Total and Assortment Volumes in an Industrial *Pinus taeda* L. Forest Plantation Using Airborne Laser Scanning Data and Random Forest. **Forests**, v. 8, n. 7, 254, 2017. <https://doi.org/10.3390/f8070254>

SILVA, C. A.; KLAUBERG, C.; CARVALHO, S. P. C. E.; HUDAK, A. T.; RODRIGUEZ, L. C. E. Mapping aboveground carbon stocks using LiDAR data in Eucalyptus spp. plantations in the state of Sao Paulo, Brazil. **Scientia Forestalis**, v. 42, n. 104, p. 591–604, 2014.

SILVA, J. M. C.; BATES, J. M. Biogeographic patterns and conservation in the South American Cerrado: a tropical savanna hotspot: the Cerrado, which includes both forest and savanna habitats, is the second largest South American biome, and among the most threatened on the continent. **BioScience**, v. 52, n. 3, p. 225-234, 2002. [https://doi.org/10.1641/0006-3568\(2002\)052\[0225:BPACIT\]2.0.CO;2](https://doi.org/10.1641/0006-3568(2002)052[0225:BPACIT]2.0.CO;2)

<https://doi.org/10.1016/j.jag.2020.102177>

SILVA, V. S.; SILVA, C. A.; MOHAN, M.; CARDIL, A.; REX, F. E.; LOUREIRO, G. H.; ALMEIDA, D. R. A.; BROADBENT, E. N.; GORGENS, E. B.; DALLA CORTE, A. P.; SILVA, E. A.; VALBUENA, R.; KLAUBERG, C. Combined Impact of Sample Size and Modeling Approaches for Predicting Stem Volume in *Eucalyptus* spp. Forest Plantations Using Field and LiDAR Data. **Remote Sensing**, v. 12, n. 9, p. 1438, 2020. <https://doi.org/10.3390/rs12091438>

SILVA, L. A.; COSTA, M. M.; RODRIGUES, A. L.; BATISTA, J. A. F.; DE LEON, O. M. M.; GARCIA, P. P.; ... & CASTRO, A. S. Políticas Públicas Voltadas para a Redução dos Focos de Calor em Unidades de Conservação e Áreas Indígenas: O Caso do Bioma Cerrado. **Revista Brasileira de Geografia Física**, v. 15, n. 04, p. 1786-1799, 2022.

SILVA, S. R.; SILVA, A. P.; MUNHOZ, C. B.; SILVA J. R. M. C.; MEDEIROS, M. B. 2001. **Guia de plantas do Cerrado utilizadas na Chapada dos Veadeiros**. 1ª ed. WWF–Brasil.

SILVEIRA, P.; KOEHLER, H. S.; SANQUETTA, C. R.; ARCE, J. E. O Estado da arte na estimativa de biomassa e carbono em formações florestais. **Floresta**, v. 38, n. 1. p 185-206, 2008.

SIMON, M. F.; PENNINGTON, T. Evidence for adaptation to fire regimes in the tropical savannas of the Brazilian Cerrado. **International Journal of Plant Sciences**, v. 173, n. 6, p. 711-723, 2012. <https://doi.org/10.1086/6659732012>.



SIMON, M. F.; GREYER, R.; DE QUEIROZ, L. P.; SKEMA, C.; PENNINGTON, R. T.; HUGHES, C. E. Recent assembly of the Cerrado, a neotropical plant diversity hotspot, by in situ evolution of adaptations to fire. **Proceedings of the National Academy of Sciences**, v. 106, n. 48, p. 20359-20364, 2009. <https://doi.org/10.1073/pnas.0903410106>

SINGH, R. K.; KUMAR, P.; MUKHERJEE, S.; SUMAN, S.; PANDEY, V.; SRIVASTAVA, P. K. Application of geospatial technology in agricultural water management. In: **Agricultural Water Management**, v. 1, n. 1, p. 31-45, 2021. <https://doi.org/10.1016/B978-0-12-812362-1.00003-5>

SKOGEN, K.; HELLAND, H.; KALTENBORN, B. Concern about climate change, biodiversity loss, habitat degradation and landscape change: Embedded in different packages of environmental concern? **Journal for Nature Conservation**, v. 44, n. 1, p. 12- 20, 2018. <https://doi.org/10.1016/j.jnc.2018.06.001>

STRASSBURG, B. B.; BROOKS, T.; FELTRAN-BARBIERI, R.; IRIBARREM, A.; CROUZEILLES, R.; LOYOLA, R.; ... & BALMFORD, A. Moment of truth for the Cerrado hotspot. **Nature Ecology and Evolution**, v. 1, n. 4, p. 1–3, 2017. <https://doi.org/10.1038/s41559-017-0099>

SMITH, R. J. Logarithmic transformation bias in allometry. **American Journal of Physical Anthropology**, v. 90, n. 2, p. 215–228, 1993. <https://doi.org/10.1002/ajpa.1330900208>

SOUZA, C. M.; JÚNIOR.; Z. SHIMBO, J.; ROSA, M. R.; PARENTE, L. L.; A. ALENCAR, A.; RUDORFF, B. F. T.; HASENACK, H.; MATSUMOTO, M.; G. FERREIRA, L.; SOUZA-FILHO, P. W. M.; DE OLIVEIRA, S. W.; ROCHA, W. F.; FONSECA, A.V.; MARQUES, C. B.; DINIZ, C. G.; COSTA, D.; MONTEIRO, D.; ROSA, E. R.; VÉLEZ-MARTIN, E.; WEBER, E. J.; LENTI, F. E. B.; PATERNOST, F. F.; PAREYN, F. G. C.; SIQUEIRA, J. V.; VIERA, J. L.; NETO, L. C. F.; SARAIVA, M. M.; SALES, M. H.; SALGADO, M. P. G.; VASCONCELOS, R.; GALANO, S.; MESQUITA, V. V.; AZEVEDO, T. Reconstructing Three Decades of Land Use and Land Cover Changes in Brazilian Biomes with Landsat Archive and Earth Engine. **Remote Sensing**, v. 12, n. 17, p. 2735, 2020. <https://doi.org/10.3390/rs12172735>

STAHL, G.; SAARELA, S.; SCHNELL, S.; HOLM, S.; BREIDENBACH, J.; HEALEY, SP.; PATTERSON, P. L.; MAGNUSSEN, S.; NAESSET, E.; MCROBERTS, R. E.; GREGOIRE, T. G. Use of models in large-area forest surveys: comparing model-assisted, model-based and hybrid estimation. **Forest Ecosystems**, v. 3, n. 1, p. 1-11, 2016. <https://doi.org/10.1186/s40663-016-0064-9>

STAVER A. C.; ARCHIBALD, S.; LEVIN S. A. The global extent and determinants of savanna and forest as alternative biome states. **Science**, v. 334, n. 6053, p. 230-232, 2011. <https://doi.org/10.1126/science.1210465>

STREUTKER, D. R.; GLENN, N. F. LiDAR measurement of sagebrush steppe vegetation heights. **Remote Sensing of Environment**, v. 102, n. 1-2, p. 135-145, 2006. <https://doi.org/10.1016/j.rse.2006.02.011>

SUGIURA, N. Further analysts of the data by akaike' s information criterion and the finite corrections. **Communications in Statistics - Theory and Methods**, v. 7 n. 1, p. 13-26, 1978. <https://doi.org/10.1080/03610927808827599>

SULLIVAN, M. J.; TALBOT, J.; LEWIS, S. L.; PHILLIPS, O. L.; QIE, L.; BEGNE, S. K.; MILES, L. Diversity and carbon storage across the tropical forest biome. **Scientific Reports**, v. 7, n. 1, p. 1-12, 2017. <https://doi.org/10.1038/srep39102>

TANG, H.; ARMSTON, J.; HANCOCK, S.; MARSELIS, S.; GOETZ, S.; DUBAYAH, R. Characterizing global forest canopy cover distribution using spaceborne lidar. *Remote Sensing of Environment*, v. 231, n. 1, p. 15, p. 111262, 2019. <https://doi.org/10.1016/j.rse.2019.111262>

TORRES, F. T.; JÚNIOR, M. R. S.; LIMA, G. S. Influência dos Elementos Meteorológicos Sobre o Comportamento do Fogo. *Revista Brasileira de Meteorologia*, v. 34, n. 1, p. 33–41, 2019. <https://doi.org/10.1590/0102-7786334014>

VALBUENA, R.; O'CONNOR, B.; ZELLWEGER, F.; SIMONSON, W.; VIHERVAARA, P.; MALTAMO, M.; SILVA, C. A.; ALMEIDA, D. R. A.; DANKS, F.; MORSDORF, F.; CHIRICI, G.; LUCAS, R.; COOMES, D. A.; COOPS, N. C. Standardizing ecosystem morphological traits from 3D information sources. *Trends in Ecology & Evolution*, v. 3, n. 8, p. 656–667, 2020. <https://doi.org/10.1016/j.árvore.2020.03.006>

VALBUENA, R.; MALTAMO, M.; MEHTÄTALO, L.; PACKALEN, P. Key structural features of boreal forests may be detected directly using L-moments from airborne lidar data. *Remote Sensing of Environment*, v. 194, n. 1, p. 437–446, 2017. <https://doi.org/10.1016/j.rse.2016.10.024>

VAN DER WERF, G. R.; RANDERSON, J. T.; GIGLIO, L.; COLLATZ, G. J.; MU, M.; KASIBHATLA, P. S.; MORTON, D. C.; DEFRIES, R. S.; JIN, Y.; VAN LEEUWEN, T. T. Global fire emissions and the contribution of deforestation, savanna, forest, agricultural, and peat fires (1997–2009). *Atmospheric Chemistry and Physics*, v. 10, n. 23, p. 11707–11735, 2010. <https://doi.org/10.5194/acp-10-11707-2010>

WAGNER, W.; ULLRICH, A.; MELZER, T.; BRIESE, C.; KRAUS, K. From single-pulse to fullwaveform airborne laser scanners: potencial and practical challenges. In: ISPRS CONGRESS INTERNATIONAL ARCHIVES OF PHOTOGRAMMETRY AND REMOTE SENSING, 20., 2004, Freiburg. *Annals...* Freiburg: ISPRS, 2004. p. 201–206.

WANG, C.; SHU, Q.; WANG, X.; GUO, B.; LIU, P.; LI, Q. A random forest classifier based on pixel comparison features for urban LiDAR data. *ISPRS journal of photogrammetry and remote sensing*, v. 148, p. 1, p. 75–86, 2019. <https://doi.org/10.1016/j.isprsjprs.2018.12.009>

WANG, D.; XIN X.; SHAO, Q.; BROLLY, M.; ZHU, Z.; CHEN J. Modeling Aboveground Biomass in Hulunber Grassland Ecosystem by Using Unmanned Aerial Vehicle Discrete Lidar. *Sensors*, v. 17, n. 1, p. 180, 2017. <https://doi.org/10.3390/s17010180>

WHITE, B. L. A. **Incêndios florestais no Parque Nacional Serra de Itabaiana Sergipe**. Universidade Federal de Sergipe, 2010. Disponível em: <[https://bdtd.ibict.br/vufind/Record/UFS-2\\_24b484771a1d07251ba21ee0887e8506](https://bdtd.ibict.br/vufind/Record/UFS-2_24b484771a1d07251ba21ee0887e8506)>. Acesso em: 25 out. 2022.

WHITE, B. L. A.; RIBEIRO, G. T.; SOUZA, R. M. O uso do BehavePlus como ferramenta para modelagem do comportamento e efeito do fogo. *Pesquisa Florestal Brasileira*, v. 33, n. 73, p. 73–83, 2013. <https://doi.org/10.4336/2013.pfb.33.73.409>

WHITE, R. P.; MURRAY, S.; ROHWEDER, M.; PRINCE, S.; THOMPSON, K. M. **Grassland ecosystems**. World Resources Institute Washington, DC, USA, 2000. p. 1569734615.

WHITLEY, R.; BERINGER, J.; HUTLEY, L. B.; ABRAMOWITZ, G.; DE KAUWE, M. G., EVANS, B., ... & YU, Q. Challenges and opportunities in land surface modelling of savanna ecosystems. *Biogeosciences*, v. 14, n. 20, p. 4711–4732, 2017. <https://doi.org/10.5194/bg-14-4711-2017>

WILCOXON, F. Individual comparisons of grouped data by ranking methods. *Journal of economic entomology*, v. 39, n. 2, p. 269–270, 1945. <https://doi.org/10.1093/jee/39.2.269>

WILKINSON, B.; LASSITER, H. A.; ABD-ELRAHMAN, A.; CARTHY, RR., IFJU, P., BROADBENT, E., GRIMES, N. (2019). Geometric targets for UAS lidar. **Remote Sensing**, 11 (24), 3019. <https://doi.org/10.3390/rs11243019>.

YIN, T.; QI, J.; COOK, B. D.; MORTON, D. C.; WEI, S.; GASTELLU-ETCHEGORRY, J. P. Modeling Small-Footprint Airborne LiDAR-Derived Estimates of Gap Probability and Leaf Area Index. **Remote Sensing**, v. 12, n. 1, p. 4, 2020. <https://doi.org/10.3390/rs12010004>.

ZANNE, A. E.; LOPEZ-GONZALEZ, G.; COOMES, D. A.; ILIC, J.; JANSEN, S.; LEWIS, S. L.; ... & CHAVE, J. (2009). **Global wood density database**. Dryad. Identifier: <http://hdl.handle.net/10255/dryad.235>.

ZHANG, H.; SUN, Y.; CHANG, L.; QIN, Y.; CHEN, J.; QIN, Y.; ... & WANG, Y. Estimation of grassland canopy height and aboveground biomass at the quadrat scale using unmanned aerial vehicle. **Remote sensing**, v. 10, n. 6, p. 851, 2018. <https://doi.org/10.3390/rs10060851>

ZHANG, Y.; CHEN, H. Y. Individual size inequality links forest diversity and above-ground biomass. **Journal of Ecology**, v. 103, n. 5, p. 1245-1252, 2015. <https://doi.org/10.1111/1365-2745.12425>

ZHAO, K.; SUAREZ, J. C.; GARCIA, M.; HU, T.; WANG, C.; LONDO, A. Utility of multitemporal lidar for forest and carbon monitoring: Árvore growth, biomass dynamics, and carbon flux. **Remote Sensing of Environment**, v. 204, n.1, p. 883-897, 2018. <https://doi.org/10.1016/j.rse.2017.09.007>

ZIMBRES, B.; SHIMBO, J.; BUSTAMANTE, M.; LEVICK, S.; MIRANDA, S.; ROITMAN, I.; ALENCAR, A. Savanna vegetation structure in the Brazilian Cerrado allows for the accurate estimation of aboveground biomass using terrestrial laser scanning. **Forest Ecology and Management**, v. 458 n. 1, p. 117798, 2020. <https://doi.org/10.1016/j.foreco.2019.117798>

## CAPÍTULO 3 – CONSIDERAÇÕES FINAIS SOBRE A TESE

### 3.1. QUESTÕES DA PESQUISA REVISITADAS

**QUESTÃO 1:** Qual(is) o melhor (es) modelo(s) baseados em dados LiDAR e de levantamentos em campo para estimar com precisão a biomassa acima do solo (AGB) em UCs?

O melhor modelo para estimar AGBt foi o que usou H98TH (altura) e COV (cobertura da vegetação), pois eles foram os melhores preditores entre o conjunto de métricas LiDAR. Este modelo produziu o AICc mais baixo (36,49), um coeficiente de correlação de  $\text{adj-R}^2$  de 0,79, um RMSE de 19,11 Mg/ha (33,40%) e as suposições de normalidade e homocedasticidade residuais satisfeitas com base nos testes de Shapiro-Wilk ( $W = 0,95$  e  $p\text{-valor} = 0,07$ ) e Breusch-Pagan ( $BP > 1,47$  e  $p\text{-valor} > 0,48$ ).

**QUESTÃO 2:** Quais variáveis medidas derivadas do sensor LiDAR apresentam maior correlação com os dados de (AGBt) medidos em campo?

Nossa análise identificou que as métricas derivadas do lidar que apresentaram maior correlação com os dados de (AGBt) medidos em campo, foram: altura da vegetação dominante e a cobertura do dossel.

**QUESTÃO 3:** Quais as relações das variáveis LiDAR com a AGB em diferentes formações de vegetação do Cerrado? Qual a precisão na estimativa da AGB a partir de dados LiDAR?

A relação das variáveis do LiDAR com a AGBt do Cerrado foi alta com o modelo geral, já a precisão da estimativa de AGBt variou em função da formação, onde a precisão foi maior na formação florestal e na savana, e menor na campestre.

### 3.2. HIPÓTESE REVISITADA

**HIPÓTESE 1:** É possível mapear AGBt no Cerrado com precisão satisfatória.

Esta hipótese foi aceita, pois o estudo permitiu derivar com precisão diferentes métricas de vegetação para modelar, estimar e mapear biomassa total acima do solo na escala de paisagem nas formações do Cerrado em resolução moderada.

### **3.3. OPORTUNIDADES PARA NOVOS ESTUDOS**

É caro e desafiador conduzir trabalho de campo no Cerrado brasileiro, e os conjuntos de dados de campo existentes ainda não representam inteiramente a extensão e complexidade do bioma. Este estudo demonstrou que o UAV-lidar pode descrever com sucesso as formações de vegetação do Cerrado em grandes áreas e tem o potencial de aumentar drasticamente o tamanho e a precisão dos conjuntos de dados comumente usados para classificar (e classificar erroneamente) os tipos de vegetação do Cerrado em mapas AGB derivados de satélites de grande escala. O desenvolvimento de técnicas de mapeamento de AGB como as demonstradas neste estudo terá um forte impacto em nossa capacidade de mapear e monitorar AGB no bioma Cerrado, particularmente no que diz respeito à biomassa superficial frequentemente negligenciada. No entanto, a incerteza observada na formação campestre deve ser investigada em profundidade em estudos futuros para melhorar a precisão do mapeamento de AGB, e para atingir esse objetivo recomendamos testar a possibilidade de integrar TLS com UAV-lidar, bem como avaliar a precisão autônoma das técnicas TLS. Além disso, com crescentes estudos e expedições de inventário de campo na formação campestre, poderíamos expandir nosso repositório de dados e aumentar a precisão das estimativas de biomassa de superfície; isso também permitirá que os gerentes florestais determinem o número mínimo de parcelas de campo necessárias para estimar biomassa de superfície de forma satisfatória e ajudará a otimizar custos de aquisição de coleta de dados em campo. Trabalhos futuros que usa os fluxos de trabalho e os resultados apresentados neste estudo para derivar em grande escala mapas de AGBt, têm o potencial de contribuir significativamente para melhorias no monitoramento de carbono e gestão de incêndios florestais. Como a precisão das técnicas de sensoriamento remoto melhoram ao longo do tempo, é possível que este estudo tenha fornecido uma referência para mostrar melhorias na estimativa de AGBt para monitoramento de carbono e gestão de incêndios florestais.