

**RAFAEL WALTER DE ALBUQUERQUE**

**APLICAÇÃO DE AERONAVES REMOTAMENTE  
PILOTADAS E FOTOGRAMETRIA PARA  
AVALIAÇÃO E MONITORAMENTO DE ÁREAS EM  
PROCESSO DE RESTAURAÇÃO FLORESTAL**

São Paulo  
2022

**RAFAEL WALTER DE ALBUQUERQUE**

**APLICAÇÃO DE AERONAVES REMOTAMENTE  
PILOTADAS E FOTOGRAMETRIA PARA  
AVALIAÇÃO E MONITORAMENTO DE ÁREAS EM  
PROCESSO DE RESTAURAÇÃO FLORESTAL**

Tese apresentada ao Instituto de Energia e Ambiente da Universidade de São Paulo para obtenção do Título de Doutor em Ciência Ambiental. Versão corrigida.

Área de Concentração:

Ciência Ambiental

Orientador:

Dr Carlos Henrique Grohmann de  
Carvalho

Co-orientador:

Dr Manuel Eduardo Ferreira

São Paulo  
2022

Nome: ALBUQUERQUE, Rafael Walter de

Título: Aplicação de aeronaves remotamente pilotadas e fotogrametria para avaliação e monitoramento de áreas em processo de restauração florestal.

Tese apresentada ao Instituto de Energia e Ambiente da Universidade de São Paulo para obtenção do título de Doutor em Ciências.

Aprovado em:

Banca examinadora

Prof. Dr. \_\_\_\_\_

Instituição: \_\_\_\_\_

Julgamento: \_\_\_\_\_

Prof. Dr. \_\_\_\_\_

Instituição: \_\_\_\_\_

Julgamento: \_\_\_\_\_

Prof. Dr. \_\_\_\_\_

Instituição: \_\_\_\_\_

Julgamento: \_\_\_\_\_

Prof. Dr. \_\_\_\_\_

Instituição: \_\_\_\_\_

Julgamento: \_\_\_\_\_

Prof. Dr. \_\_\_\_\_

Instituição: \_\_\_\_\_

Julgamento: \_\_\_\_\_

**AUTORIZO A REPRODUÇÃO E DIVULGAÇÃO TOTAL OU PARCIAL DESTES  
TRABALHO, POR QUALQUER MEIO CONVENCIONAL OU ELETRÔNICO, PARA  
FINS DE ESTUDO E PESQUISA, DESDE QUE CITADA A FONTE.**

#### FICHA CATALOGRÁFICA

Albuquerque, Rafael Walter de.

Aplicação de aeronaves remotamente pilotadas e fotogrametria para  
avaliação e monitoramento de áreas em processo de restauração florestal.  
/ Rafael Walter de Albuquerque; orientador: Carlos Henrique Grohmann  
de Carvalho. – São Paulo, 2022.

168 f.: il. , 30 cm.

Tese (Doutorado em Ciência Ambiental) – Programa de Pós-  
Graduação em Ciência Ambiental – Instituto de Energia e Ambiente da  
Universidade de São Paulo.

1. Ecossistemas - restauração. 2. Aeronaves não tripuladas. 3.  
Fotogrametria. 4. Machine learning. 5. Deep learning. 6. Governança.  
I. Título.

Elaborado por Maria Penha da Silva Oliveira CRB-8/6961

## AGRADECIMENTOS

A toda minha família e amigos, especialmente meus pais e minha esposa, que sempre apoiaram e estimularam meus estudos e crescimento profissional.

A Carlos Henrique Grohmann de Carvalho, Manuel Eduardo Ferreira, Søren Ingvor Olsen, Daniel Luis Mascia Vieira, Luiz Eduardo Vicente, Luciana Spinelli Araujo, Ciro José Ribeiro Moura, José Alberto Quintanilha, Mariana Giannotti, Mauricio George Miguel Jardim, Manoel Cláudio da Silva Junior, Bruno Machado Telles Walter, Marcelo Brillhante Medeiros, Sérgio Eustáquio Noronha, Henrique Marinho Leite Chaves e Marcelo Hiromiti Matsumoto pela convivência e experiência profissional que proporcionaram ao longo de minha carreira acadêmica.

Ao programa CAPES PrIntUSP, por possibilitar intercâmbio não apenas acadêmico, mas também cultural mediante bolsa de doutorado sanduíche.

Ao Departamento de Ciência da Computação da Universidade de Copenhage (DIKU) por me receber em meu período de doutorado sanduíche e contribuir com minha formação profissional.

À Sociedade Brasileira de Restauração Ecológica (SOBRE) e todo o corpo técnico-científico participante do Protocolo de Monitoramento da Restauração de Ecossistemas via Sensoriamento Remoto para a Mata Atlântica e Amazônia, especialmente Alex Fernando Mendes e Julio Ricardo Caetano Tymus, que acompanharam e seguem acompanhando todo o processo.

À Coalizão Brasil Clima, Florestas e Agricultura, não apenas pelo importante trabalho feito à sociedade, mas também pelo convite à participação da Oficina “Como monitorar o reflorestamento e a restauração da vegetação Nativa no Brasil?”. Este evento me permitiu conhecer especialistas que contribuíram ao desenvolvimento desta tese.

À Embrapa CENARGEN, Embrapa Meio Ambiente, The Nature Conservancy (TNC), World Wide Fund for Nature (WWF) e World Resources Institute (WRI) pelo apoio profissional e estímulo ao desenvolvimento desta pesquisa.

Ao Instituto Estadual do Ambiente (INEA) por fornecer dados oficiais do monitoramento da restauração florestal correspondente à área estudada em Miguel Pereira (RJ).

Ao Instituto de Energia e Ambiente da Universidade de São Paulo (IEE-USP) pelo apoio institucional no desenvolvimento acadêmico-científico.

Ao Spatial Modelling Laboratory (SPAM Lab) e ao Laboratório de Processamento de

Imagens e Geoprocessamento (Lapig), Programa Pro-Vant, pela infraestrutura e ambiente de trabalho.

À CAPES pela concessão de bolsa de pós-graduação que permitiu o desenvolvimento desta pesquisa.

*“...[H]á, obviamente, uma diferença importante entre um sistema aberto que convida todo mundo a se aproximar, estudar os seus métodos e sugerir aperfeiçoamentos, e outro que considera o questionamento de suas credenciais um sinal de maldade no coração[.]...”*

-- Morris Raphael Cohen. Reason and nature. 1931.

# RESUMO

Diversas atividades humanas acarretam a supressão de vegetação nativa e muitas vezes os limites legais não são respeitados, tornando necessária a Restauração Florestal (RF). No campo das geotecnologias (em especial, no Sensoriamento Remoto orbital e aéreo), câmeras convencionais acopladas a Aeronaves Remotamente Pilotadas, ou *Remotely Piloted Aircrafts* (RPA) podem aprimorar o processo de monitoramento da RF, pois geram produtos de maior resolução espacial, dados altimétricos via Modelos Digitais de Superfície (MDS), dados de altura via *Canopy Height Model* (CHM), imagens não contaminadas por nuvens e não possuem carência de resolução temporal. O objetivo principal desta pesquisa é estudar a aplicação de RPA e fotogrametria para avaliação e monitoramento de áreas em processo de RF, considerando o contexto atual brasileiro. Seguindo diretrizes do Protocolo de Monitoramento da RF do Pacto pela Restauração da Mata Atlântica, dois importantes aspectos da vegetação foram obtidos por RPA e fotogrametria: (i) estrutura, que consistiu na cobertura de dossel (via intervalo de valor do CHM), densidade de árvores (via algoritmo Máxima Local), cobertura de gramíneas (via *machine learning*, índice de vegetação e filtros) e altura de dossel (via CHM); e (ii) biodiversidade, que consistiu tanto na identificação de duas espécies relevantes para a RF na Amazônia (via *deep learning*) quanto em locais com maior ou menor diversidade de espécies (via *deep learning* para delineamento de copas e análises de regressão baseadas em métricas de heterogeneidade do CHM e dados de campo). RPA e fotogrametria mostraram êxito na medição de todos os indicadores, sendo que dois deles apresentaram capacidade de generalização a imagens diferentes das utilizadas neste estudo. Dentre os aspectos estruturais da vegetação, altura e cobertura de dossel podem ser trabalhados de forma mais generalizada porque podem ser obtidos utilizando-se apenas dados da nuvem de pontos. Essa base de dados obtida em processos de fotogrametria não sofre influência das variações de luz solar ao longo do dia e das estações do ano, o que possibilita a capacidade de generalização. Já a utilização do ortomosaico não possibilita num primeiro momento essa capacidade de generalização porque os valores dos seus pixels sofrem influência da luz solar, demandando mais trabalhos para possibilitar a capacidade de generalização de modelos que usam essa base de dados. Logo, apesar dos bons resultados obtidos para o quesito biodiversidade, são necessários mais dados para obtenção de modelos com maior capacidade de generalização, o que permitiria uma utilização mais pragmática pela sociedade. Diante do amplo potencial de contribuição ao monitoramento da RF, trabalhos futuros devem aprimorar os processos de *machine learning* e a medição da biodiversidade via RPA e fotogrametria, pois as florestas tropicais brasileiras são amplamente diversas e apresentam considerável desafio neste sentido.

**Palavras-Chave** – Restauração de Ecossistemas, Drone, Machine learning, Deep learning, Governança.



# ABSTRACT

Many anthropogenic activities cause vegetation suppression and not rarely do these actions exceed legal limits, demanding Forest Restoration (FR) projects. Geo-technologies such as Red-Green-Blue (RGB) sensors onboard Remotely Piloted Aircraft (RPA) have been gaining prominence since their products contain high spatial resolution, altitude data on Digital Surface Models (DSM), height data on Canopy Height Model (CHM), cloud cover absence, and high temporal resolution. This study aims to evaluate RPA and photogrammetry performance on automatic extraction of FR project parameters, considering the current Brazilian context. According to the Protocol for FR monitoring of the Atlantic Forest Restoration Pact, two relevant vegetation parameters were assessed through RPA and photogrammetry: (i) vegetation structure, which was canopy cover (via CHM threshold value), tree density (via Local Maximum algorithm), grass cover (via machine learning, vegetation index and filters), and canopy height (via CHM); and (ii) biodiversity, which consisted on the identification of relevant tree species for the FR in the Amazon (via deep learning) and on patches with more or less species diversity (via deep learning for the delineation of tree crowns and regression analysis based on heterogeneity metrics of the CHM and field data). RPA and photogrammetry successfully measured all the vegetation parameters, and two of them presented generalization capacity, which are methods that generate accurate results on images that are not used in this research. Among the structural parameters of the vegetation, canopy height and cover can be measured with generalization capacity because their acquisition relies on point cloud data only. Point cloud data obtained by photogrammetry is not influenced by variations in sunlight conditions, which makes the generalization capacity possible. However, the sunlight conditions influence the orthomosaic's pixel values, and thus more work is needed to improve the generalization capacity of methods involving this database. Therefore, despite the good results regarding biodiversity, more data are needed to develop models with more generalization capacity, which would enable pragmatic usage by society. Future works must then improve the machine learning processes and the biodiversity measurements via RPA and photogrammetry because this research branch has high potential to upscale FR monitoring and is considerably challenging in tropical Brazilian forests.

**Keywords** – Ecosystem Restoration, Drone, Machine learning, Deep learning, Governance.

## LISTA DE FIGURAS

1	Possíveis caminhos da qualidade de um projeto de RF ao longo do tempo. Fonte: adaptado de Chaves et al. (2015). . . . .	17
2	As duas fases de um projeto de RF. A primeira avalia a estruturação dossel, que após atingir um valor mínimo de 70% de cobertura, dá início à segunda fase, que avalia se as funções ecológicas da floresta estão retornando. Fonte: Viani et al. (2013) . . . . .	18
3	Avaliação de acurácia aplicada ao delineamento de copa de árvore. A figura ilustra o polígono referência manualmente delineado, polígono classificado obtido automaticamente e vetores dos erros de omissão e comissão do processo classificatório. Fonte: Yurtseven et al. (2019). . . . .	39
4	Diferenças radiométricas nas imagens individuais aéreas RGB de vegetação na Bélgica conforme estação do ano. Fonte: Adaptado de Lisein et al. (2015). . . . .	46
5	Exemplo de RPA asa-rotativa (a) e asa-fixa (b). Fotografia obtida de acervo gratuito (a) e cedida pelo LAPIG / UFG (b). . . . .	49
6	Quadro-Resumo da Regulamentação da ANAC, que considera diferentes normativas conforme classe da RPA. BVLOS é <i>Beyond the Visual Line of Sight</i> e VLOS é <i>Visual Line of Sight</i> . Fonte: ANAC (2017b). . . . .	50
7	Altura ( $H'$ ) como variável a ser trabalhada na definição do GSD, uma vez que a resolução $f$ (Distância focal) do sensor não varia após a escolha do equipamento. . . . .	51
8	Sobreposição longitudinal e lateral de imagens de RPA. . . . .	52
9	Figura síntese do artigo " <i>Remotely piloted aircraft imagery for automatic tree counting in forest restoration areas: a case study in the Amazon</i> ", publicado no âmbito desta tese para avaliar a detecção automática de árvores em imagens obtidas via RPA-SfM. Fonte: Albuquerque et al. (2020). . . . .	55

10	Figura síntese do artigo " <i>Forest Restoration Monitoring Protocol with a Low-Cost Remotely Piloted Aircraft: Lessons Learned from a Case Study in the Brazilian Atlantic Forest</i> ", publicado no âmbito desta tese para avaliar a detecção automática de indicadores estruturais de RF em imagens obtidas via RPA-SfM. Fonte: Albuquerque et al. (2021) . . . . .	57
11	Localização dos estudos de caso na Mata Atlântica brasileira. . . . .	63
12	Ortomosaicos obtidos por sensor RGB a bordo de RPA referentes aos seis diferentes projetos de RF sobrevoados: restauração ativa em topo de morro com trechos de 6 anos de idade e trecho de 1 ano de idade (a); restauração ativa com trechos variando entre 4 e 16 anos de idade (b); trechos de restauração ativa e passiva de um ano de idade e trechos de floresta madura (c); restauração ativa de 40 anos com trechos de gramíneas (d); floresta madura com trechos de gramíneas (e); e floresta madura com trechos de restauração ativa de um ano de idade (f). . . . .	64
13	Resultados do mapeamento da cobertura de dossel destacados na cor verde em cada RF sobrevoada. . . . .	66
14	Figura síntese do artigo " <i>Mapping Key Indicators of Forest Restoration in the Amazon Using a Low-Cost Drone and Artificial Intelligence</i> ", publicado no âmbito desta tese para avaliar a detecção automática de indicadores de biodiversidade de RF em imagens obtidas via RPA-SfM. Fonte: Albuquerque et al. (2022) . . . . .	72

# LISTA DE TABELAS

1	Valores utilizados nos parâmetros do algoritmo “Classify Ground Points” e acurácia da cobertura de dossel dos estudos de caso. .....	67
---	---	----

## LISTA DE SIGLAS

Recuperação de Áreas Degradadas (RAD)

Restauração Florestal (RF)

Sensoriamento Remoto (SR)

*Light Detection And Ranging* (LiDAR)

*Remotely Piloted Aircraft* (RPA)

*Red-Green-Blue* (RGB)

*Structure from Motion and Multi-View-Stereo* (SfM-MVS)

Modelo Digital de Superfície (MDS)

Modelo Digital de Terreno (MDT)

*Canopy Height Model* (CHM)

*Global Navigation Satellite System* (GNSS)

Pacto pela Restauração da Mata Atlântica (PACTO)

*Forest Landscape Restoration* (FLR)

Cotas de Reserva Ambiental (CRA)

Cadastro Ambiental Rural (CAR)

Observatório da Restauração e Reflorestamento (ORR)

Pagamento por Serviços Ambientais (PSA)

Deteção Individual de Árvores (DIA)

Deteção de Copa de Árvores (DCA)

*Object Based Image Analysis* (OBIA)

*Support Vectors Machine* (SVM)

*Ground Sampling Distance* (GSD)

Máxima Verosimilhança (MAXVER)

*Modified Photochemical Reflectance Index* (MPRI)

*Tree Crown Heterogeneity Index* (TCHI)

# SUMÁRIO

<b>1</b>	<b>Introdução</b>	<b>1</b>
1.1	Justificativa da originalidade do trabalho . . . . .	6
<b>2</b>	<b>Objetivos</b>	<b>7</b>
2.1	Hipóteses . . . . .	7
<b>3</b>	<b>Referencial Teórico</b>	<b>8</b>
3.1	A Restauração Florestal e seus desafios . . . . .	8
3.1.1	Escalas da restauração . . . . .	13
3.1.2	Fases da RF e indicadores de monitoramento . . . . .	18
3.2	Uso de Geotecnologias na Restauração Florestal . . . . .	21
3.3	Uso de RPA-SfM no estudo da Vegetação e em projetos de Restauração Florestal . . . . .	32
3.3.1	RPA-SfM e a estrutura da vegetação . . . . .	32
3.3.2	RPA-SfM e a biodiversidade da vegetação . . . . .	40
3.3.3	Tipos de RPA . . . . .	48
3.3.4	Padrões de Voo . . . . .	49
<b>4</b>	<b>Avaliação dos aspectos estruturais da Restauração Florestal via RPA-SfM</b>	<b>54</b>
4.1	Síntese dos artigos publicados no âmbito desta tese sobre avaliação dos aspectos estruturais da Restauração Florestal via RPA-SfM . . . . .	54
4.2	Artigo submetido: Um protocolo para monitoramento da cobertura de dossel de projetos de Restauração Florestal via RPA de baixo custo . . . . .	58
4.2.1	Resumo do artigo submetido . . . . .	58
4.2.2	Destques do artigo submetido: . . . . .	59

4.2.3	Introdução do artigo submetido . . . . .	59
4.2.4	Materiais e Métodos do artigo submetido . . . . .	60
4.2.4.1	Materiais . . . . .	60
4.2.4.2	Padrões de voo . . . . .	61
4.2.4.3	Cobertura de dossel medida por RPA . . . . .	61
4.2.4.4	Estudos de caso . . . . .	63
4.2.5	Resultados do artigo submetido . . . . .	65
4.2.6	Discussão do artigo submetido . . . . .	66
4.2.7	Conclusões do artigo submetido . . . . .	69
<b>5</b>	<b>Avaliação dos aspectos de biodiversidade da Restauração Florestal via RPA-SfM</b>	<b>70</b>
<b>6</b>	<b>Conclusões</b>	<b>73</b>
	<b>Referências</b>	<b>75</b>
	<b>Anexo A – Artigo sobre detecção automática de árvores via RPA-SfM em áreas de Restauração Florestal</b>	<b>100</b>
	<b>Anexo B – Artigo sobre avaliação dos aspectos estruturais da Restauração Florestal via RPA-SfM</b>	<b>118</b>
	<b>Anexo C – Artigo sobre avaliação dos aspectos de biodiversidade da Restauração Florestal via RPA-SfM</b>	<b>140</b>



# 1 INTRODUÇÃO

Diversas são as atividades humanas que acarretam a supressão de vegetação nativa, em muitas vezes excedendo os limites legais estabelecidos pelos órgãos ambientais, bem como o próprio limite de resiliência natural, tornando necessária a Recuperação de Áreas Degradadas (RAD) (ARONSON; DURIGAN; BRANCALION, 2011). No Brasil, políticas de RAD foram estimuladas e geraram ações como o Programa de Recuperação de Áreas Degradadas da Amazônia (PRADAM) e os Centros de Referência em Recuperação de Áreas Degradadas (CRAD). A legislação brasileira defende a preservação do meio ambiente como um direito de todo cidadão (Constituição Federal, Art. 225) e a lei 9.985/2000 define conceitos relativos aos casos de RAD. Áreas degradadas por mineração, atividades ilegais, desmatamentos ou atividades agrícolas que não respeitaram os processos de licenciamento ambiental ou os limites estabelecidos no Código Florestal (lei 12.651/2012), devem passar pelo processo de RAD.

Entre os conceitos de RAD, segundo Aronson, Durigan e Brancalion (2011), estão a regeneração natural, quando a vegetação se desenvolve naturalmente sem a necessidade de intervenção humana, a reabilitação ecológica, isto é, a recuperação da área degradada a condições similares, mas não iguais às que se encontrava antes da degradação, além de outros conceitos. Neste estudo, adota-se o conceito de Restauração Florestal (RF) mencionado por DellaSala et al. (2003), pois abrange todas as ações de RAD mencionadas por Aronson, Durigan e Brancalion (2011), como reabilitação ecológica, regeneração natural, entre outras, e aborda a ligação também a aspectos econômicos e de comunidades.

Dentre os conceitos envolvendo RF, é oportuno destacar a forma na qual o reestabelecimento da vegetação é estimulado. Segundo Morrison e Lindell (2011) e Benayas, Bullock e Newton (2008), quando os responsáveis pela RF lançam mão de técnicas como preparo e correção do solo, seguido de semeadura ou plantio, ou seja, quando interferem direta e ativamente na condução da RF, tem-se uma Restauração Ativa (RA). Alternativamente, quando os responsáveis pela RF simplesmente deixam de realizar qualquer atividade na área para estimular a Regeneração Natural, realizando apenas o cercamento

do local quando há presença de animais, tem-se uma Restauração Passiva (RP) (MORRISON; LINDELL, 2011; BENAYAS; BULLOCK; NEWTON, 2008). Os autores reforçam que a RA é mais eficiente devido a um maior controle sobre o crescimento e diversidade da vegetação. Em contrapartida, a RP possui custo significativamente menor, mas só gera bons resultados se o local possuir certa resiliência ou se uma interferência mínima for feita para estimular bons resultados (PARROTTA; TURNBULL; JONES, 1997; CHAZDON; GUARIGUATA, 2016), ou seja, a RP é inviável em locais cujo impacto ambiental foi significativo (CHAZDON; GUARIGUATA, 2016).

Devido à ampla gama de possibilidades e situações diversas, trabalhos visando estratégias de RF foram desenvolvidos para, por exemplo, atividades de mineração (NERI; SANCHEZ, 2012), recuperação de manguezais (FERNANDES, 2012; LEWIS, 2009), recuperação de praias e dunas (NORDSTROM, 2010), recuperação da Caatinga (MOURA; MALHADO; LADLE, 2013), recuperação de ambientes campestres no hemisfério norte (MARTIN; WILSEY, 2006), nas pastagens do Pantanal (SANTOS et al., 2018) e nos Pampas (DICK; SCHUMACHER; MOMOLLI, 2016), além dos vários conceitos, técnicas e etapas de implementação de uma RF descritos por Martins (2012). Contudo, no Brasil a maior parte dos estudos de RF referem-se às formações florestais dos biomas Amazônia e Mata Atlântica, havendo já alguma quantidade de estudos para o Cerrado e pouca quantidade de trabalhos nos biomas Pantanal, Pampas e Caatinga (OVERBECK et al., 2015).

No campo das geotecnologias, em especial, no Sensoriamento Remoto (SR) orbital e aéreo, existem frentes de trabalhos que se utilizam de imagens aéreas ou orbitais no suporte a projetos de RF.

Andrade et al. (2013) e Dultra et al. (2009) utilizaram SR para o planejamento da RF na fase pré-campo apenas, sem utilizar produtos de SR para monitorar avanço ou estagnação da vegetação mesmo que via fotointerpretação. Já Miranda, Guimarães e Miranda (2002) utilizaram as Geotecnologias para monitorar políticas de preservação e RF com base em análises temporais, utilizando fotointerpretação (FLORENZANO, 2002) com validações em campo para checar avanço ou redução da vegetação.

Christakopoulos et al. (2011) lançaram mão de métodos quantitativos de SR, que são baseados em procedimentos matemáticos e estatísticos mesmo quando aplicados em bases qualitativas (CONGALTON; MEAD, 1983), para estimar a biomassa da vegetação como um indicador de qualidade de processos de RF. Já Leeuwen (2008) utilizou índices de vegetação (JENSEN, 2015) em análises temporais para avaliar a RF após ocorrência de

incêndio. Até mesmo a tecnologia de radar orbital já foi utilizada para medir a restauração de fisionomias alagadiças (JAENICKE; ENGLHART; SIEGERT, 2011).

Nos estudos envolvendo SR e RF mencionados acima, as imagens empregadas para realizar a avaliação foram as de nível orbital. Tais imagens possuem limitação temporal, em que o imageamento é sujeito à passagem do satélite, limitação de nebulosidade (presença de nuvens) e limitação espacial, na qual a resolução cartográfica depende do tipo de sensor, que normalmente varia entre 10 e 30 metros por pixel para plataformas multi-espectrais de acesso gratuito. Há também outras geotecnologias já utilizadas em projetos de RF, como aerofotogrametria utilizando avião convencional e LiDAR (*Light Detection And Ranging*), mas ambas possuem alto custo de aplicação, conforme exemplificado por Reif e Theel (2017) e Dufour et al. (2013).

Neste campo do saber, o uso de imagens obtidas por Aeronaves Remotamente Pilotadas, ou *Remotely Piloted Aircraft* (RPA) (ANAC, 2017a), popularmente conhecidos como *drones*, é ainda bastante incipiente, sobretudo na literatura especializada, demandando ainda experimentos específicos que vêm crescendo na última década para consolidar o uso desta tecnologia (POLEY; MCDERMID, 2020).

Atualmente, os RPA como plataforma de voo vêm ganhando notoriedade em diversos ramos da ciência em escala global. É possível acoplar diferentes sensores a bordo dos RPA, como câmeras digitais (TAY; ERFMEIER; KALWIJ, 2018), LiDAR (D'OLIVEIRA et al., 2020) e termais (WITCZUK et al., 2018). Dentre os diferentes sensores possíveis de serem acoplados aos RPA como plataforma de voo, esta tese trata de câmeras digitais operantes no espectro visível. Tais câmeras, também chamadas de sensores Red-Green-Blue (RGB), possuem menor custo de aquisição, denominando os RPA portadores de sensores RGB como RPA de menor custo (TAROLLI, 2014). O menor custo de aquisição deste tipo de equipamento permite sua aquisição por parte significativa da população e das diferentes instituições.

Câmeras digitais acopladas a RPA possibilitam o registro detalhado de paisagens em visão panorâmica através da tecnologia *Structure from Motion and Multi-View-Stereo* (SfM-MVS) (COLOMINA; MOLINA, 2014; SCHONBERGER; FRAHM, 2016; MICHELLETTI; CHANDLER; LANE, 2015). Essa tecnologia aplicada por RPA gera dados de alta precisão e alto detalhamento mesmo utilizando-se equipamentos de menor custo (TAROLLI, 2014). No âmbito de projetos florestais, já há estudo de caso executado com maior agilidade e menor custo frente a metodologias tradicionais de medição em campo (CHEN et al., 2017).

O uso de RPA e SfM-MVS, daqui em diante referido como RPA-SfM para maior fluidez de leitura, fornece produtos de alta resolução espacial, frequentemente menor que 10 cm. RPA-SfM também geram Modelos Digitais de Superfície (MDS), emergindo assim como uma alternativa a tecnologias tradicionais, como imagens de satélite (AASEN et al., 2015; OLTMANNNS et al., 2012) e levantamentos com sistemas de posicionamento global, ou *Global Navigation Satellite System* (GNSS) (MONICO, 2008; MEYER, 2018) de precisão. Além disso, as imagens não são contaminadas por nuvens e não possuem carência de resolução temporal (BERNI et al., 2009), uma vez que basta a realização de voos para se registrar a superfície na data desejada.

Outra vantagem no uso de RPA-SfM reside na obtenção de dados altimétricos, que permitem a obtenção de informações acerca da biomassa da vegetação (ZAHAWI et al., 2015), entre outras informações sobre o terreno.

Tais vantagens sugerem que RPA-SfM pode ser aplicado em áreas de RF, cabendo estudos para avaliar as vantagens no uso desta tecnologia. O uso de satélites é vantajoso quando grandes glebas de terra são avaliadas (OLTMANNNS et al., 2012). Satélites comerciais com 0,5 m de resolução espacial cobrem uma área de pelo menos 10.000 hectares, sendo que no Brasil, até o ano de 2009, cerca de 86% dos imóveis rurais possuía menos de 100 ha (DIEESE, 2011) e, no ano de 2017, o total de imóveis com menos de 100 ha foi de 89% (VIEIRA-FILHO; GASQUES, 2020). Além disso, áreas de mineração não são extensas (MININGFACTS.ORG, 2016) e exigem projeto de RF após o fechamento da mina (NERI; SANCHEZ, 2012), reforçando o potencial de aplicação de RPA-SfM.

As áreas em processo de RF dos imóveis rurais brasileiros, se consideradas em cerca de 20% da sua extensão segundo a lei 12.651/2012 (Código Florestal Brasileiro: a porcentagem depende da localização e presença de APP), engloba-se um valor significativamente menor do que a área mínima imageada por um satélite. RPA com menos de 25 kg (considerados microvant), segundo a classificação da ANAC (Agência Nacional de Aviação Civil, AIC no. 21/10), fornecem imagens com menos de 10 cm de resolução espacial (em geral, de 2 a 4 cm, dependendo do sensor fotográfico a bordo da plataforma e da altura do voo, conforme mostra a seção 3.3.4), cobrindo facilmente áreas de RF de cerca de 20 hectares (AASEN et al., 2015; OLTMANNNS et al., 2012; BERNI et al., 2009), que é o valor médio referente aos 89% dos imóveis rurais brasileiros (VIEIRA-FILHO; GASQUES, 2020). Além disso, o Programa de Regularização Ambiental (PRA), previsto na lei 12.651/2012 e Decreto 7.830/12, exige que a recomposição da vegetação em propriedades rurais brasileiras seja periodicamente monitorada e registrada numa frequência máxima a cada dois anos, reforçando que mais estudos para aplicação de RPA em RF no Brasil

devem ser realizados. O Brasil assumiu ainda, no âmbito do Acordo de Paris de 2015, o compromisso de recuperar cerca de 12 milhões de hectares de florestas até 2030 no País, sendo a década 2020-2030 considerada a Década da RF<sup>1</sup>.

Existem trabalhos em nível nacional dedicados ao mapeamento histórico da cobertura florestal brasileira, como o MapBiomias (<<http://mapbiomas.org/>>), e à obtenção de indicadores que medem a qualidade de uma RF de acordo com as peculiaridades dos biomas brasileiros, como o trabalho de Brancalion et al. (2012), de PRMA (2013) e o PACTO (RODRIGUES; ISERNHAGEM; BRANCALION, 2009). Existem também iniciativas internacionais que definiram parâmetros de avaliação de RF, como a *Society for Ecological Restoration* (MCDONALD et al., 2016). Finalmente, também as leis no âmbito federal (INSTRUÇÃO NORMATIVA ICMBIO 11/2014, por exemplo) e no âmbito estadual (Resolução INEA nº 143/2017 no RJ e Resolução SMA Nº 32 DE 03/04/2014 em SP, por exemplo), todas mencionam importantes indicadores de RF a serem monitorados, como Cobertura de Dossel, Densidade de Regenerantes e Biodiversidade. Logo, ao utilizar geotecnologias para medição de indicadores de RF, o SR deve gerar resultados interpretáveis por ecólogos (VALBUENA et al., 2020), devendo a RF orientar a tecnologia ao invés da tecnologia orientar a RF (ELLIOTT, 2016).

Diante deste contexto, urge a necessidade de estudar possíveis contribuições que o uso de RPA-SfM pode proporcionar a projetos de RF. Esta tese aborda tais contribuições através de três artigos já publicados em periódicos especializados. Os três artigos seguem a abordagem de duas fases da RF utilizada no protocolo de monitoramento da RF do Pacto pela Restauração da Mata Atlântica (PACTO): a primeira fase avalia a estruturação do dossel e a segunda fase aborda a trajetória ecológica (VIANI et al., 2013).

Em dois dos artigos publicados no âmbito desta tese (seções A e B), a avaliação da estrutura da vegetação é abordada. Em ambos os artigos a nuvem de pontos mostrou-se uma base de dados essencial. A seção A (ALBUQUERQUE et al., 2020) mostra que a nuvem de pontos incide diretamente na acurácia da detecção automática de árvores, e conseqüentemente na medição do indicador densidade de árvores. Já na seção B, Albuquerque et al. (2021) mostram que a nuvem de pontos é importante também para os indicadores estruturais cobertura de dossel e altura de dossel. Em Albuquerque et al. (2021), o ortomosaico foi necessário para mapear a ocorrência de gramíneas e de cobertura de dossel de árvores pequenas em área declivosa.

Em outro artigo publicado no âmbito desta tese (seção C), a biodiversidade foi avaliada

---

<sup>1</sup><<https://www.decadeonrestoration.org/>>

utilizando-se técnicas de *deep learning* e análises de regressão. Duas espécies chave para a gestão da RF na Amazônia foram mapeadas utilizando-se *deep learning*. Também via *deep learning* realizou-se o delineamento das copas de todas as árvores. Após delineadas as copas, uma análise de regressão avaliou a relação de suas medidas de heterogeneidade estrutural com as medidas de diversidade de espécies obtidas por trabalhos convencionais de campo.

## 1.1 Justificativa da originalidade do trabalho

A obtenção de métricas da vegetação a partir de imagens aéreas é oportuna em projetos de RF. No contexto brasileiro, o monitoramento de RF utiliza-se de critérios mínimos de percentual de cobertura do solo por espécies arbóreas nativas, além de percentual máximo permitido de cobertura de herbáceas exóticas, dentre outros critérios (PRMA, 2013).

Considerando que cada processo de RF leva anos para ser concluído (MARTINS, 2012), este trabalho propõe um aprimoramento na metodologia de inspeção, registro, avaliação e monitoramento da recomposição da vegetação. Poderá então contribuir com o processo de RF mediante o emprego de metodologias mais robustas, transparentes e inovadoras.

A inovação e originalidade do presente trabalho está na avaliação e monitoramento de indicadores de RF utilizando RPA-SfM. A avaliação convencional de projetos de RF ocorre em trabalhos de campo de inventários florestais, onde são registrados, dentre outras informações, altura, diâmetro e espécie de cada árvore dentro das parcelas. Também durante os inventários florestais são tiradas fotos de alguns trechos em nível de solo. Um RPA percorre toda a RF num intervalo de tempo menor, registrando a área como um todo em informação georreferenciada, promovendo assim maior governança ao processo. A partir da informação georreferenciada, busca-se uma metodologia de SR capaz de automaticamente obter indicadores de RF. Essa pesquisa busca, portanto, inovar a avaliação de projetos de RF, promovendo redução de custo e maior agilidade na análise de projetos.

## 2 OBJETIVOS

Frente aos elementos apresentados, o objetivo principal deste trabalho é estudar a aplicação do uso de RPA-SfM para avaliação e monitoramento de áreas em processo de RF, considerando o contexto atual do Brasil e seus biomas florestais. Busca-se um novo mecanismo, não só para monitorar, mas também para registrar informações acerca de indicadores da qualidade do processo de RF. Os resultados obtidos por RPA-SfM devem ser comparados com metodologias tradicionais e difundidas de monitoramento de forma a atestar a viabilidade da metodologia proposta. Para cada indicador de RF avaliado nesta pesquisa, são analisados os possíveis benefícios do uso de RPA-SfM, além da viabilidade prática de sua aplicação por parte da sociedade.

### 2.1 Hipóteses

É possível ampliar a escala de monitoramento de indicadores de RF utilizando-se RPA-SfM. Análises automáticas permitem obter alguns indicadores de RF com razoável precisão e contribuir para o ganho de escala do processo de monitoramento. Logo, o uso de RPA-SfM complementa, mas não substitui os trabalhos tradicionais de campo, pois determinados indicadores só podem ser obtidos mediante inventários florestais.

## 3 REFERENCIAL TEÓRICO

Projetos de restauração possuem relevante interesse público, pois envolvem: grandes proporções de área e a atuação conjunta de comunidades locais no fornecimento de sementes, mudas, cercas e demais insumos; proprietários rurais que sujeitam suas terras à implementação dos projetos; e eventualmente órgãos públicos que fazem a fiscalização ou mesmo a promoção de base legal de estímulo aos projetos de Restauração de Ecossistemas.

Para a devida promoção deste relevante e complexo interesse público, projetos de RF trazem consigo diversos desafios. Alguns (desses desafios) são mencionados na seção 3.1.

### 3.1 A Restauração Florestal e seus desafios

Paisagens brasileiras formaram-se como uma "herança de processos fisiográficos e biológicos", além de constituírem um "patrimônio coletivo dos povos que historicamente as herdaram como território de atuação de suas comunidades"(AB'SÁBER, 2003). Tal fato torna naturalmente complexa e desafiadora a execução de projetos de RF (HILDERBRAND; WATTS; RANDLE, 2005).

Trabalhos de RF começaram no Brasil como iniciativas isoladas, sem articulações interinstitucionais e sem troca de experiências. Por se tratar de um tema complexo, universidades foram envolvidas para geração e aprimoramento do conhecimento científico, restauradores começaram a trocar experiências, diferentes instituições começaram a unir esforços (MARTINS, 2012), a exemplo do PACTO (RODRIGUES; ISERNHAGEM; BRANCALION, 2009), e regulamentos legais começaram a ser sancionados (BRANCALION et al., 2010; SCHULTZ; JEDD; BEAM, 2012; CHAVES et al., 2015). Projetos de RF fazem parte, portanto, de um esforço conjunto de abrangência internacional (VERDONE; SEIDL, 2017).

Os benefícios de RF envolvem não apenas o provimento de serviços ecossistêmicos (CHAZDON, 2008), mas também induzem a melhoria dos indicadores sócioeconômicos,



devendo ser avaliados por indicadores sociais (LE et al., 2012). Em ambientes florestais, é possível obter renda com a comercialização de produtos madeireiros e não-madeireiros (GODOY; LUBOWSKI; MARKANDYA, 1993; SUNDERLIN et al., 2005), devendo as comunidades locais passar por um devido processo de conscientização sobre essas possibilidades de desenvolvimento sustentável (MEYFROIDT, 2013).

Adams et al. (2016) abordam o conceito de *Forest Landscape Restoration* (FLR), na qual a restauração de serviços ecossistêmicos gera bem-estar social em áreas anteriormente degradadas. Nesse trabalho, os autores verificaram que há pouca informação sobre os impactos da RF no bem-estar e modo de vida das populações locais. Governança e Renda foram os indicadores sociais mais encontrados na revisão feita por Adams et al. (2016). Porém, a ampla variabilidade de situações de FLR ao redor do mundo dificulta a obtenção de respostas assertivas acerca desses indicadores sociais. Os autores, portanto, ressaltaram a necessidade de mais esforços para efetivamente ligar conceitos ecológicos a sociais.

A abrangência de áreas com potencial para obter benefícios econômicos e sociais via RF foram estimadas em um total de dois bilhões de hectares (LAESTADIUS et al., 2011; WRI, 2014). Apesar de não validarem os dados em campo, não incluírem determinadas variáveis e utilizarem dados de baixa resolução, o estudo de Laestadius et al. (2011) reforça que em geral áreas de maior potencial à RF são em sua grande maioria de baixo potencial agrícola e baixa densidade populacional. Veldman et al. (2015), porém, alertam que nove milhões de hectares dentre os encontrados por WRI (2014) englobam biomas de formação não florestal, devendo estas áreas apresentar políticas de RF diferentes para evitar processos de arborização em formações savânicas ou campestres. Vieira e Scariot (2006) também reforçam a distinção de metodologias de RF para Florestas tropicais secas, que não necessariamente possuem predominância de estrato florestal e são frequentemente associadas a savanas. Outro questionamento de trabalho científico que estima o total de carbono sequestrado por potenciais ações de RF pode ser verificado em Veldman et al. (2019).

Em um balanço sobre oportunidades e desafios para projetos de RF no Brasil, Calmon et al. (2011) identificaram 6 milhões de hectares de áreas potenciais para a RF do bioma Mata Atlântica. Os autores comentaram que o Código Florestal Brasileiro, desde sua sanção em 1934, colaborou significativamente para a preservação da natureza em todo o país, pois previa punições a quem retirasse a vegetação além dos limites legais estabelecidos. Tal lei também estimulou ações de RF, pois enfatizou benefícios que a preservação do meio ambiente gera à sociedade e leis complementares passaram então a ser sanciona-

das no intuito de estimular a conexão de fragmentos de remanescentes de vegetação da Mata Atlântica via RF (essas conexões por vezes dependem da adesão de proprietários de terras a programas de RF). Apesar de um instrumento que contribuiu para a preservação ambiental, os autores à época da publicação de seu trabalho alertaram para mudanças no Código Florestal que estavam em discussão. De fato, foi então sancionada a lei Lei nº 12.651, de 25 de maio de 2012, o novo Código Florestal Brasileiro, que ao ser debatida por Soares-Filho et al. (2014) mostrou queda de proteção legal principalmente em áreas ripárias e em áreas de pequenos produtores que já haviam retirado a vegetação nativa antes do ano de 2008. Os autores verificaram alteração nas áreas estimadas de RF de  $50 \pm 6$  Mha para  $21 \pm 1$  Mha após a sanção da lei 12.651 (Novo Código Florestal), mas destacaram também importantes avanços na política ambiental que passaram a influenciar diretamente as ações de RF, como as Cotas de Reserva Ambiental (CRA) e o Cadastro Ambiental Rural (CAR).

Apesar dos avanços proporcionados pelo CAR ao monitoramento e à fiscalização do código florestal, sua implementação tem sido usada à margem da lei em determinadas regiões do Brasil. Por ser um instrumento auto-declaratório, o CAR tem sido usado indevidamente por grileiros de terras. No processo de ocupação ilegal, os grileiros usam o CAR como um instrumento que busca aparentar legalidade de operações na Amazônia. Essa ocupação ilegal do solo dificulta a atuação de agricultores familiares e povos indígenas (SANTOS; GALEÃO, 2018). Os autores comentaram que o uso propositadamente indevido do CAR foi mais intenso em regiões onde as instituições de fiscalização foram consideradas mais fracas.

Reflexos do enfraquecimento das instituições fiscalizadoras na Amazônia tomaram proporções internacionais recentemente. Houve aumento das queimadas após a implantação do novo código florestal, aumento esse significativamente expressivo a partir de 2019 (SILVA-JUNIOR et al., 2021). Tal aumento de atividades ilegais na Amazônia evidenciam um declínio de princípios básicos da democracia na região, como convívio harmônico entre diferentes grupos (PROTHRO; GRIGG, 1960) e diálogo (KALLIOLA; NAKARI; PESONEN, 2006). No caso da Amazônia, além da falta de harmonia entre diferentes grupos, atividades ilegais evidenciam ausência de diálogo por pessoas descontentes com o atual sistema, que fazem uso de força e violência para impor suas vontades ao invés de debater aprimoramentos.

Além dos desafios de políticas públicas, há também os desafios conceituais sobre projetos de RF. Hilderbrand, Watts e Randle (2005) alertaram a necessidade de evitar mitos ecológicos que, segundo os autores, muitas vezes norteiam políticas ambientais. Seguindo

linhas de pensamento registradas também por Arroyo-Rodríguez et al. (2017) e Aronson et al. (2011), Hilderbrand, Watts e Randle (2005) reforçaram a visão de que RF dificilmente devolve os aspectos ecológicos e ambientais anteriormente existentes na vegetação primária, de forma a alertar para as expectativas criadas sobre projetos de RF. Segundo os autores, RF não devolve integralmente as funcionalidades ambientais porque a natureza por si só é um sistema socioecológico complexo e ações de RF são norteadas por modelagens relativamente simples, a começar pela escala de tempo a qual a vegetação primária e RF são geradas. Neste trabalho, os autores geraram uma lista de 5 mitos recorrentes em RF, de forma que a análise destes mitos poderia revisar a compreensão da natureza e, portanto, aprimorar os modelos adotados de RF. Os autores não apresentaram soluções específicas aos mitos por eles levantados nem propuseram melhorias específicas aos modelos de RF porque soluções não foram o foco do artigo. Eles apenas comentaram sobre algumas recomendações gerais que devem ser levadas em conta, por exemplo, não introduzir espécies raras em ambientes ainda degradados. Assim, o foco maior dos autores foi ressaltar a importância de se compreender o papel que os mitos tiveram nas metodologias e projetos de RF e que devemos nos alertar para as incertezas proporcionadas pelos modelos de RF. Apesar da análise crítica, as avaliações de Hilderbrand, Watts e Randle (2005) não envolveram questões sociais, evidenciando falta de interdisciplinariedade ao abordar mitos apenas da vegetação.

Um frequente objeto de estudo em trabalhos de RF são as Florestas Secundárias, que são áreas onde a vegetação original foi degradada por causas antrópicas ou naturais (por exemplo, incêndios) e apresentaram reestabelecimento da formação florestal com o passar do tempo (CHOKKALINGAM; JONG, 2001). O trabalho de Guariguata e Otertag (2001) afirma existir certa previsibilidade no processo sucessional de uma floresta secundária, cujo sucesso como RF é importante para toda a sociedade ao ser beneficiada pelo fornecimento de produtos florestais e serviços ambientais. Os autores revisaram importantes variáveis para o sucesso do estabelecimento de uma floresta secundária, como histórico de uso da terra, proximidade a áreas preservadas, qualidade das áreas preservadas (biodiversidade, biomassa, banco de sementes, fauna, ciclagem de nutrientes, etc.), características do solo e características da incidência de luz. O trabalho destacou que florestas neotropicais possuem alto potencial de regeneração natural se estiverem próximas a áreas preservadas e se o uso da terra anterior à RF não foi muito predatório. Logo, em áreas antropizadas (é possível ocorrer RF em áreas preservadas, por exemplo, em casos de deslizamento de terra em áreas de remanescente de vegetação), os autores comentaram que há maior dificuldade em prever o sucesso de uma RF e hipotetiza que nestes casos

uma seqüência de fatos deve ocorrer para que uma RF tenha sucesso na geração de florestas secundárias: colonização por espécies vegetais, fechamento de dossel, recuperação da riqueza de espécies, aumento da área basal e da biomassa, e retorno da composição de espécies semelhante à situação anterior à antropização do local. Apesar dessa hipótese, os autores ressaltaram que o intervalo de tempo entre o incremento da biomassa e o aumento da riqueza de espécies é certamente o processo mais demorado, não sendo possível estimar um intervalo de tempo para este fenômeno, nem modelar como o histórico de uso do solo influencia neste incremento da biodiversidade.

Já Liebsch, Marques e Goldenberg (2008) analisaram diversas florestas secundárias em diferentes estágios de sucessão, ao longo de três estados brasileiros, com diferentes latitudes. Análises estatísticas identificaram correlação entre riqueza e distribuição de espécies com a idade da RF, estimando que uma RF na Mata Atlântica precisa de aproximadamente sessenta e cinco anos para atingir 80% de espécies vegetais zoocóricas e de cem a quatrocentos anos para que florestas secundárias atinjam níveis de endemismo semelhantes aos de florestas maduras (primárias). Porém, mesmo uma RF recuperando diversos aspectos ecológicos e ambientais, após centenas de anos, os autores comentam que parte destes quesitos já devem ter sido perdidos porque já haviam sobrado poucos dados utilizados como referência de floresta primária, que possui Ecologia histórica. Ou seja, os autores alertam que os poucos remanescentes de vegetação da Mata Atlântica utilizados como referência para RF sofreram algum tipo de degradação ambiental devido à ampla fragmentação das áreas preservadas.

O apoio ou a função do Poder Público em projetos de RF é essencial para a devida devolução de serviços ecossistêmicos à sociedade. No caso do Estado de São Paulo, o papel do poder público foi debatido por Aronson et al. (2011). Os autores comentaram a importância da regulamentação e definição de melhores práticas por parte do Poder Público, de forma a nortear com força de lei o sucesso de projetos de RF. O debate dos autores considera duas visões de RF: (1) parâmetros mínimos de qualidade que garantem o sucesso de uma RF, tomando como base trabalho de Brancalion et al. (2010) sobre o caso do estado de São Paulo; e (2) uma RF jamais devolverá as condições anteriormente existentes à área porque a ciência ainda está muito aquém deste nível de conhecimento, tomando como base trabalho de Durigan et al. (2010), que avaliam a regulamentação da RF no estado de São Paulo. Apesar de um dos grupos valorizar o conhecimento já existente e o outro alertar para limitações decorrentes do que ainda não foi descoberto, ambos concordam quanto à necessidade de introduzir na legislação parâmetros a serem atingidos para orientar o sucesso de uma RF. O primeiro grupo defende que estes parâmetros de

sucesso de uma RF sejam escritos em forma de lei, enquanto o segundo grupo defende que sejam escritos como assistência técnica. Além disto, os grupos concordam quanto à necessidade de iniciativas que agreguem educação ambiental, capacitação técnica, empreendedorismo, cultivo de mudas em viveiros, capacitação de órgãos fiscalizadores, incentivo fiscal, além de modificações na lei que considere variações e peculiaridades de cada local. Posteriormente ao debate de idéias proporcionado por Aronson et al. (2011), esforços dos profissionais atuantes no Estado de São Paulo fizeram com que fosse sancionada a Resolução SMA 189/2018, que trata da exploração sustentável de espécies nativas do Brasil. Outra importante normativa legal para o Estado de São Paulo, fruto de diversos debates entre especialistas, foi a SMA 32/2014, que trata de indicadores a serem avaliados durante o monitoramento da RF (CHAVES et al., 2015).

### 3.1.1 Escalas da restauração

Na esteira dos debates sobre a busca de boas práticas e soluções a projetos de RF, a discussão das escalas da RF é relevante, pois é necessário que as aplicações sejam bem-sucedidas em todas as escalas. Não é suficiente que projetos de RF sejam bem-sucedidos de forma isolada. É necessário que os projetos de RF estejam devidamente conectados entre si, pois casos isolados de sucesso não geram benefícios públicos.

Arroyo-Rodríguez et al. (2017) analisaram fatores que devem compor a estratégia de sucesso no crescimento de florestas secundárias, propondo então uma avaliação de RF em múltiplas escalas espaciais. Na escala local é importante avaliar a qualidade da vegetação de forma a propiciar uma devida resiliência via dispersão de sementes, conectividade de fragmentos, potencial atrativo de fauna nativa, sujeição a incêndios, invasões biológicas e biomassa total. Em escala regional, deve-se avaliar o histórico de uso da terra, presença de florestas primárias, clima, edafologia e riqueza de espécies. Em escala macro, ou de país, políticas econômicas e estímulos à produção e consumo devem ser avaliados, bem como políticas ambientais de incentivo à preservação da vegetação ou implementação de RF. Além desta abordagem multi-escalar, os autores comentaram os diferentes posicionamentos acadêmicos sobre florestas secundárias: um que a RF serve de reservas de biodiversidade e contribui para a preservação da natureza; e outro que condena o desmatamento porque RF nunca atingirão biodiversidade e aspectos ecológicos semelhantes à vegetação primária que outrora existia. Os autores, neste contexto acadêmico, concluem se posicionando numa espécie de meio termo a essas duas visões, pois consideraram que o sucesso de uma floresta secundária dependerá de diversos fatores a serem avaliados em múltipla escala. Cada escala deve, portanto, ser devidamente considerada, avaliada e mo-

nitorada no modelo adotado para condução de processos de RF (ARROYO-RODRÍGUEZ et al., 2017).

Devido ao histórico de ocupação do território e à conseqüente fragmentação das áreas preservadas, o bioma Mata Atlântica no Brasil (trata-se de um dos cinco maiores *hotspots* de biodiversidade mundiais) passou a ser estudado e monitorado de forma a engajar diversos setores da sociedade, como iniciativa privada, governos, Organizações Não-Governamentais (ONGs) e institutos de pesquisa, de forma a conduzir processos de RF de qualidade em escala nacional (BRANCALION et al., 2016a). Projetos ambiciosos de RF devem deixar de ser isolados e locais, passando a abranger milhões de hectares. Diante do desafio de coordenar a força-tarefa de restauração do bioma Mata Atlântica, desafio esse ainda mais acentuado pelo fato de RF ser um tema multi-disciplinar, o que demanda engajamento de diversos setores da sociedade, foi criado em 2009 o PACTO. O objetivo do PACTO é promover RF de quinze milhões de hectares de florestas da Mata Atlântica visando à preservação da biodiversidade, fornecimento de serviços ambientais, desenvolvimento sustentável e cumprimento do Código Florestal (lei 12.651/2012).

Adams et al. (2016) comentam que ações de RF devem apresentar uma interação em escala nacional (contexto legal e por biomas), escala regional (configuração e conectividades de paisagens) e escala local (formas e estratégias de produção e custos de oportunidade). Considerando-se esta terminologia de escalas, no âmbito de RF em escala nacional, Chazdon et al. (2017) avaliaram experiências internacionais que geraram tanto benefícios quanto novos desafios. Numa continuidade aos desafios da RF, os autores propuseram a criação de uma agenda de governança que busque responder questões ainda não descobertas por cientistas atuantes e iniciativas de RF. Esta agenda também deve incluir considerações de colaboradores não atuantes na comunidade acadêmica e considerações de governos, que são atores mais recentes na atuação de RF, porque notaram as perdas de serviços ambientais, produção agrícola e desenvolvimento econômico ocasionados por degradações ambientais. Segundo Chazdon et al. (2017), para se chegar a um bom modelo de RF em escala nacional, as particularidades da escala local são importantes e seus atores devem manter um diálogo contínuo e eficiente no longo prazo. Logo, é importante haver um alinhamento local acerca dos possíveis benefícios oferecidos por RF (por exemplo, fornecimento de madeira ou fornecimento de serviços ambientais) segundo as prioridades dos envolvidos em cada região, focando-se no desenvolvimento sustentável ao invés do antagonismo conservação/produção. Dessa forma, novos conhecimentos serão produzidos integrando-se colaborativamente proprietários de terras, instituições de pesquisa, serviços de extensão agrícola locais focados em particularidades locais e governos, sendo impres-

cindível a participação de agentes públicos capazes de transformar o conhecimento gerado de RF em políticas concretas (CHAZDON et al., 2017).

Regulamentação e governança de RF são desafios importantes conforme mostraram experiências em todo o mundo. Guariguata e Brancalion (2014) avaliaram que sistemas de governança devem ser adaptados de forma a incluir ampla e diversa gama de *stakeholders*, instrumentos legais, políticas inter-setoriais e administração governamental multi-nível, sendo que metas globais de restauração, como o Desafio de Bonn e a Convenção pela Diversidade Biológica (COP 10 - *Conference of the Parties to the Convention on Biological Diversity*), ampliaram a necessidade de gestão de RF em larga escala. Ao avaliar experiências de RF em sete países espalhados pela América Central, América do Sul, África e Ásia, os autores constataram: o Pagamento por Serviços Ambientais (PSA) como uma ferramenta eficiente no estímulo a RF; casos de políticas de RF em larga escala que, por mais nobre e bem-intencionadas que sejam, desconsideraram particularidades locais, o que contradiz a mensagem transmitida por Chazdon et al. (2017) de valorizar especificidades locais; e regeneração natural como um método viável de RF quando o uso da terra não foi intenso e nem prolongado, devendo a regeneração natural envolver critérios bio-físicos, sócio-econômicos e institucionais para tornar florestas secundárias protegidas por lei. Assim, ao revisar experiências positivas e negativas em todo o mundo, Guariguata e Brancalion (2014) comentaram que ainda há muito o que aprimorar em gestão de RF em escala global.

Outras leituras sobre a contextualização, benefícios e desafios da RF podem ser verificadas em Chazdon et al. (2016), DeLuca et al. (2010), Aerts e Honnay (2011), Holl (2002). Sobre exemplos concretos de produtos gerados em virtude de trabalhos, experiências e articulações de RF no contexto brasileiro, são citadas aqui três iniciativas que buscaram registrar e nortear ações de RF em maior escala: o "Plano Nacional de Recuperação da Vegetação Nativa" (PLANAVEG), o relatório da IUCN (*International Union for Conservation of Nature*) "Restauração de florestas e paisagens no Brasil" e o relatório organizado pelo Pacto pela Restauração da Mata Atlântica "Referencial dos conceitos e ações de restauração florestal". Todas as três iniciativas, enunciadas abaixo, são passíveis de ajustes à medida que são gerados novos conhecimentos.

Em resumo, o PLANAVEG trata de uma agenda positiva que apoiará os proprietários de terras de forma a permitir benefícios a toda sociedade brasileira. Proporcionará ainda novas oportunidades de negócios e reforçará o papel do Brasil como líder global entre as nações tropicais na conservação e recuperação de ecossistemas (PLANAVEG, 2017).

Esta obra tem a ambição de apontar caminhos para a restauração de paisagens e florestas no Brasil e, por isso, fomos buscar a opinião de pessoas que trabalham diariamente para construir uma agenda positiva. Pessoas que acreditam no potencial da restauração em larga escala como uma das principais contribuições para o enfrentamento das mudanças do clima. Pessoas comuns que atuam em empresas, bancos, universidades, organizações não-governamentais, associações, entre outros, que apostam no papel da restauração e dos plantios comerciais de espécies nativas como indutores de uma economia verde de baixo carbono e de base florestal. O contexto global demanda ações rápidas e assertivas, já que estamos diante de uma encruzilhada (MORAES, 2016).

... esse documento foi construído para sustentar as ações de restauração da Mata Atlântica, que deverão ser potencializadas com o esforço coletivo e integrado do Pacto pela Restauração da Mata Atlântica através das organizações não governamentais, governos federal, estaduais e municipais, proprietários rurais, comunidades tradicionais, cooperativas, associações e empresas. De forma alguma o presente documento deve ser tomado como o ponto final da Ciência e prática da restauração florestal da Mata Atlântica. Serve como um ponto de partida para que, daqui a alguns anos, possa ser atualizado pelo avanço da Ecologia da Restauração e pelas lições a serem aprendidas com as ações do Pacto (RODRIGUES; ISERNHAGEM; BRANCALION, 2009).

Apesar das iniciativas acima mencionadas, cada local tem particularidades que distinguem a dinâmica ecológica da vegetação secundária obtida por RF (BURSLEM; SWAINE, 2002). Este tipo de vegetação vem ganhando maior relevância devido aos serviços ecossistêmicos que proporcionam, urgindo a necessidade de se melhor compreender os fatores particulares que influenciam a RF (ARROYO-RODRÍGUEZ et al., 2017). Diferentes biomas possuem diferentes aspectos ecológicos e tipos de exploração antrópica, proporcionando diferentes sistemas adaptativos de gestão (FILOTAS et al., 2014). Logo, a devida compreensão das particularidades de cada RF influencia o seu adequado monitoramento (ANDERSEN et al., 2017; MANSOURIAN; VALLAURI, 2014).

Brancalion et al. (2012) menciona como principais desafios ao monitoramento de RF a falta de indicadores-chave, não redundantes e ágeis na geração de resultados de análise quanto ao sucesso da restauração. Afinal, quanto mais indicadores complexos utilizados, maior o tempo demandado por atividades de monitoramento e maior o custo do procedimento. Tempo hábil, custo compatível e indicadores adequados às particularidades locais são essenciais à continuidade do monitoramento da RF não só no Brasil (ANDRADE; SANCHEZ; ALMEIDA, 2014; DURIGAN; GUERIN; COSTA, 2013; BRANCALION et al., 2012) mas também em várias localidades ao redor do mundo (ANDERSEN et al.,



2017; SEWELL; BOUMA; ESCH, 2016; MANSOURIAN; VALLAURI, 2014; BURTON; MACDONALD, 2011; YIN; YIN, 2010; DELUCA et al., 2010).

Assim, considerando o contexto brasileiro e os desafios envolvendo monitoramento de RF, o presente trabalho busca aprimorar esta importante etapa de projetos de RF lançando mão de tecnologias de SR para ampliar a escala do monitoramento. Afinal, após instaurados, projetos de RF demandam um devido monitoramento (MARTINS, 2012; PLANAVEG, 2017; MORAES, 2016; RODRIGUES; ISERNHAGEM; BRANCALION, 2009; MCDONALD et al., 2016; BRANCALION et al., 2012) para garantir que os serviços ecossistêmicos sejam devidamente restabelecidos, sendo que o uso de SR auxilia a obtenção de informações em locais não amostrados por parcelas de campo. A Figura 1 ilustra possíveis caminhos, considerados adequados ou inadequados, que um projeto de RF pode tomar ao longo do tempo, devendo o monitoramento identificar as nuances que colocam a RF nos caminhos F e G apontados na Figura 1.

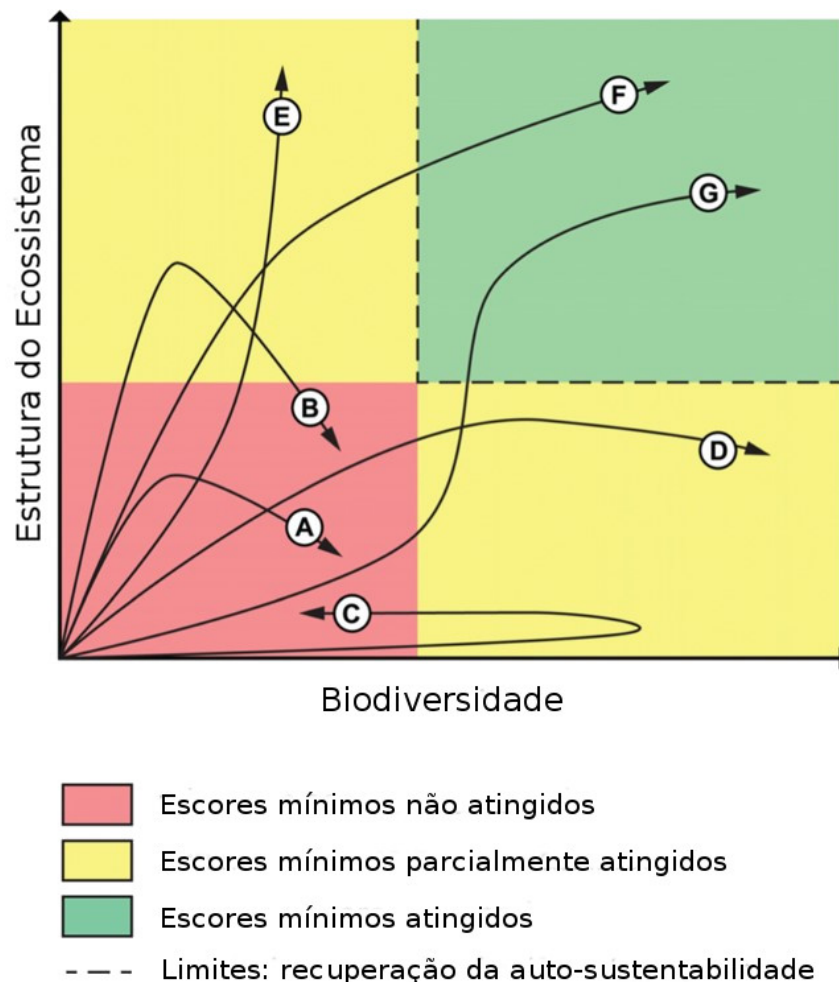


Figura 1: Possíveis caminhos da qualidade de um projeto de RF ao longo do tempo. Fonte: adaptado de Chaves et al. (2015).

### 3.1.2 Fases da RF e indicadores de monitoramento

O Protocolo de monitoramento para programas e projetos de restauração florestal (VIANI et al., 2013) elenca duas fases de avaliação do projeto na Mata Atlântica, um bioma florestal: Fase I, focada na estruturação do dossel, cuja cobertura deve atingir ao menos 70%; e Fase II, focada na trajetória ecológica, cujo sucesso depende de biodiversidade (Figura 2).

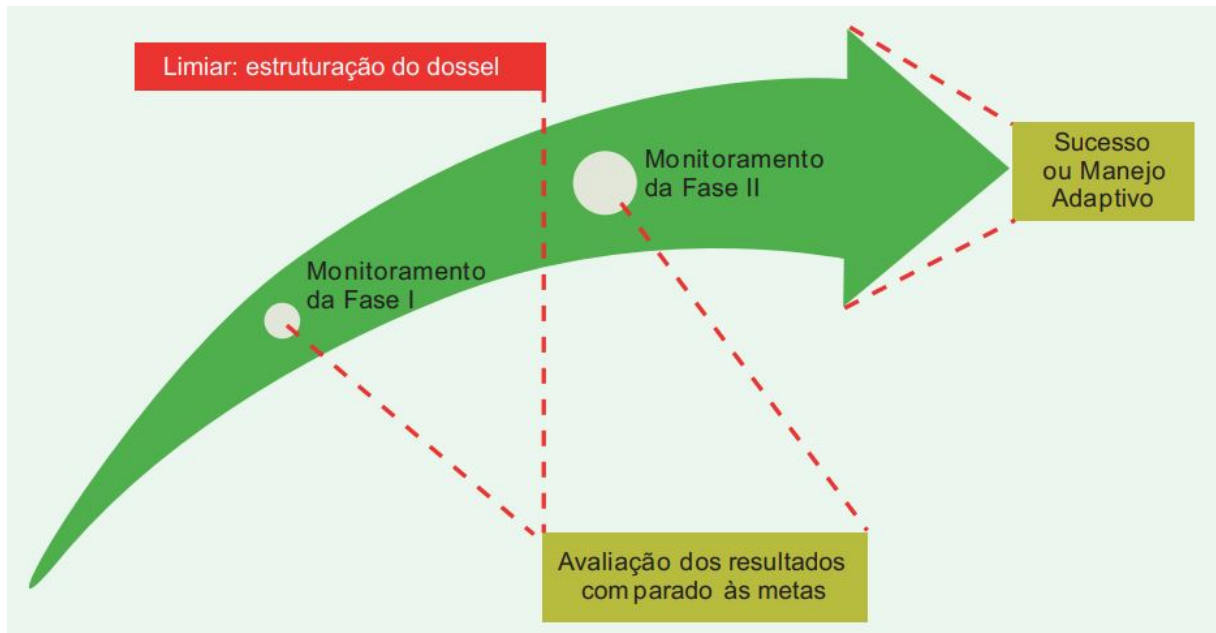


Figura 2: As duas fases de um projeto de RF. A primeira avalia a estruturação do dossel, que após atingir um valor mínimo de 70% de cobertura, dá início à segunda fase, que avalia se as funções ecológicas da floresta estão retornando. Fonte: Viani et al. (2013)

A avaliação da Fase II tem início ao concluir a Fase I, quando a cobertura de dossel atinge 70%. Ou seja, nos primeiros anos de um projeto de RF, a cobertura de dossel é um indicador de grande importância, que após minimamente estruturado faz com que outros indicadores, como ocorrência de diferentes espécies e de indivíduos regenerantes, ganhem relevância. Entretanto, ressalta-se que a importância da cobertura de dossel na Fase I não inibe a avaliação de outros indicadores nesta etapa. Nos primeiros anos de RF, é importante avaliar, por exemplo, a germinação de determinadas espécies em sementes ou a mortalidade de mudas em plantios.

Uma das funções básicas da cobertura de dossel é proteger e conservar o solo (ZUAZO; PLEGUEZUELO, 2009; SCHROTH et al., 2001; YOUNG, 1986; EVANS, 1984), o que acaba preservando também a fauna (HARVEY et al., 2006). Projetos de RF em biomas florestais, como a Amazônia e a Mata Atlântica, consideram como cobertura de dossel a fração de uma gleba coberta por indivíduos arbóreos apenas. Vegetação composta

por gramíneas não são desejadas nestes biomas (BRANCALION et al., 2012), portanto, o estrato herbáceo não é computado como cobertura de dossel. Entretanto, no caso do Bioma Cerrado, por exemplo, algumas Fitofisionomias são compostas por gramíneas (RIBEIRO; WALTER, 2008), ou seja, o valor desejado de cobertura de dossel será menor do que, por exemplo, os 70% desejados segundo o PRMA (2013). No caso do estado Mato Grosso (MT), Sousa e Vieira (2018) recomendam ao menos 50% de cobertura de dossel nas fitofisionomias savânicas do Cerrado.

Numa RF ativa de plantio de mudas, a mortalidade de mudas na fase inicial do projeto é um fator crucial para o seu sucesso (KEETON, 2008) e tem relação direta com a densidade de indivíduos arbóreos. Por exemplo, num plantio com espaçamento 3x2 metros e com 0% de mortalidade, existem 1.667 plantas/hectare. Logo, a densidade de indivíduos arbóreos também pode ser avaliada nas fases iniciais de um projeto.

Após o fechamento do dossel, a altura das árvores é um indicador importante da qualidade da vegetação (REIF; THEEL, 2017), pois indica se a sucessão ainda encontra-se dominada por pioneiras (possuem altura menor que as clímax), ou se o domínio da RF já ocorre por plantas clímax (possuem altura maior que as pioneiras) (FREITAS et al., 2019). Além disso, a altura de dossel tem relação com biomassa da floresta (ALMEIDA et al., 2019) e até mesmo com a regularidade do regime pluviométrico (DENSLOW; CHAZDON, 2002). Porém, a medição da altura das árvores em trabalhos convencionais de campo possui custosos procedimentos de ser obtida com precisão (FORTIN; DEBLOIS, 2010), sendo frequentemente obtida por estimativa visual, o que gera propagação de erros (HONGYA et al., 2012). Ou seja, nestes frequentes casos de estimativa visual da altura a aquisição desta informação possui alto grau de subjetividade que varia de indivíduo para indivíduo, o que gera uma oportunidade para medição em maior escala via SR, conforme mostra a seção 3.2.

Também após a estruturação do dossel, importantes objetivos de uma RF são a conservação do solo e de recursos hídricos (CHEN; CAI, 2006), mas a ausência de biodiversidade na floresta faz com que suas funções não sejam plenamente desempenhadas (III et al., 2000; RODRIGUES; BRANCALION; ISERNHAGEN, 2009). A biodiversidade é importante, por exemplo, para a resiliência, reprodução de espécies nativas e expulsão de espécies invasoras, e a degradação da biodiversidade afeta diretamente os serviços ambientais à sociedade, como fornecimento de alimentos, combustível, materiais estruturais, remédios e recursos genéticos (III et al., 2000).

A importância do monitoramento da biodiversidade é exemplificado na Amazônia por

Mesquita et al. (2015). O trabalho mostra que dependendo da forma como a terra é explorada na região amazônica, a regeneração natural proporcionará um amplo domínio de uma única espécie, tornando significativamente baixa a riqueza de espécies no bioma de maior biodiversidade do planeta. Alternativamente, a presença de espécies do gênero *Cecropia* sp. indicam que futuramente haverá uma composição diversa de espécies (JAKOVAC et al., 2016; DALLING; HUBBELL, 2002; MESQUITA et al., 2001), o que sugere uma boa avaliação da métrica biodiversidade em estágios intermediários de RF. Logo, para que uma RF seja adequada, é importante atingir padrões mínimos de biodiversidade, sendo este, portanto, um importante indicador a ser monitorado.

Outro indicador importante para avaliação da RF após a estruturação do dossel é a densidade de regenerantes, que é a regeneração natural no sub-bosque (NBL; TNC, 2013). Regenerantes evidenciam que indivíduos plantados em anos anteriores estão se reproduzindo, ou que indivíduos presentes no entorno da RF estão se estabelecendo no local outrora degradado, demonstrando o atingimento de condições necessárias à perpetuação do processo de restauração (RODRIGUES; GANDOLFI; BRANCALION, 2015). Para evitar confusões de termos entre regenerantes e regeneração natural (restauração passiva), cabe ressaltar que regenerantes são a regeneração natural abaixo do dossel, ou seja, uma restauração passiva ainda em fase de dossel aberto não apresenta regenerantes devido à ausência de sub-bosque. No entanto, uma regeneração natural (restauração passiva) pode apresentar regenerantes quando se encontrar em fases mais avançadas da RF de dossel fechado.

Apesar da relevância dos regenerantes, este trabalho não aborda diretamente sua medição por RPA-SfM devido à limitação desta tecnologia em coletar dados abaixo do dossel. Porém, sabe-se que projetos de RF com maior heterogeneidade estrutural da vegetação possuem maior diversidade de espécies (VIEIRA et al., 2021), sendo que RPA-SfM podem avaliar a relação da estrutura do dossel com a biodiversidade (BOURGOIN et al., 2020; CAMARRETTA et al., 2020).

As seções 3.2 e 3.3 a seguir mostram que o SR já foi amplamente utilizado no estudo da vegetação e RF, havendo ainda muitas lacunas de conhecimento a serem preenchidas para a ampliação da escala do monitoramento da RF.

## 3.2 Uso de Geotecnologias na Restauração Florestal

O SR estuda diversos quesitos voltados à ocupação do solo nos meios urbano e rural. No meio rural, onde ocorre boa parte dos projetos de RF, cabe ressaltar a agricultura, que se revolucionou ao utilizar tecnologias digitais voltadas à redução de desperdícios numa mesma gleba, o que é característico da Agricultura de Precisão (ZHANG; WANG; WANG, 2002; TSOUROS; BIBI; SARIGIANNIDIS, 2019). Esse avanço da produtividade via tecnologias digitais ficou evidente ainda no período da Agricultura 3.0, em que máquinas agrícolas passaram a ser equipadas com tecnologias digitais, mas continuaram operando sem muitas fontes de dados externas (ZHAI et al., 2020). A integração com outras fontes de informação e uso de tecnologias como o Processamento na Nuvem e Big Data possibilitaram planejamentos ainda mais interessantes nas lavouras, culminando na Agricultura 4.0 (ZHAI et al., 2020). Nesta nova fase, as máquinas agrícolas, que já eram equipadas com tecnologia digital, passaram a integrar dados de outras fontes, como previsão do tempo, características de solo e imagens de RPA, para recalcular sua operação em tempo real. Essa dinâmica de planejamento e replanejamento visa a redução de desperdício de alimentos (dose certa de fertilizantes e escoamento ágil) e de recursos naturais (otimização de produtos químicos e de recursos hídricos), o que por sua vez caracterizou maior sustentabilidade na Agricultura de Precisão (ZHAI et al., 2020). Tal sustentabilidade na Agricultura de Precisão também está ligada à maior produtividade das lavouras, que diminui a pressão pela retirada de vegetação nativa (STAFFORD, 2000; ZHAI et al., 2020).

A agricultura possui relevante importância econômica e social, sendo objeto de estudos de inovação por SR para aumento de produtividade (STAFFORD, 2000) e que já possui casos de sucesso (ZHAI et al., 2020). No caso do SR voltado à preservação do meio ambiente, a maior parte dos estudos, segundo Camarretta et al. (2020), envolve mudanças de cobertura do solo e áreas de remanescente de vegetação, sendo projetos RF ainda carentes de estudos nos diferentes sensores. Entretanto, diversos outros estudos já vêm sendo conduzidos nos últimos anos de forma a sinalizar potenciais benefícios significativos ao monitoramento da RF em larga escala (ALMEIDA et al., 2020). Diante de um ritmo avançado de aprimoramento de conhecimentos tanto de campo quanto de SR, Castro et al. (2021) chegaram a propor, inspirados nos conceitos de agricultura de precisão (ZHANG; WANG; WANG, 2002; TSOUROS; BIBI; SARIGIANNIDIS, 2019) e de silvicultura de precisão (KOVÁCSOVÁ; ANTALOVÁ, 2010), o termo Restauração de Precisão.

A comprovação do grande potencial do SR em proporcionar maior escala à RF pode

vir mediante definição de um conjunto de métricas e metodologias capazes de gerar informação efetiva (DELUCA et al., 2010; PETTORELLI et al., 2018). Porém, tal definição de um conjunto de métricas e metodologias entre RF e SR depende da escala da análise, sendo um dos gargalos do monitoramento da RF via SR a alocação de profissionais especializados para a coleta e processamento de dados (CAMARRETTA et al., 2020).

Mecanismos de ampliação da escala ou de monitoramento mais eficiente da RF são buscados não apenas por empreendedores, mas também por órgãos fiscalizadores. No caso de atividades de fiscalização, as geotecnologias mostraram êxito em mapear não apenas incêndios (SOUZA et al., 2019) e fronteiras agrícolas (ARVOR et al., 2013), mas também o cumprimento de metas de RF em projetos de mineração (NASCIMENTO et al., 2020) e de agropecuária (SILVA et al., 2022). Mesmo utilizando-se o SR para ampliar a escala da fiscalização da RF, há dificuldade dos agentes públicos em retornar ao campo para aplicar as penalidades cabíveis em lei tanto por questões burocráticas quanto por questões de quantitativo de pessoal (SILVA et al., 2022). Para aumentar a eficiência da aplicação de penalidades, a verificação remota do não cumprimento da RF poderia coincidir com outros processos de automatização, como o rastreamento de produtos originários de imóveis rurais em situação irregular (SILVA et al., 2022).

Além das atividades de fiscalização, há atualmente no Brasil uma importante iniciativa que busca compilar em uma única plataforma as iniciativas de RF no território nacional, o Observatório da Restauração e Reflorestamento (ORR) <<https://observatoriodarestauracao.org.br/home>>. Essa plataforma separa os dados como polígono onde há um projeto oficialmente registrado e a certeza de ocorrência de RF; e dados de pixel, onde informações de imagens de satélite estimam a ocorrência de RF, mas há incertezas inerentes a essa estimativa. O ORR é uma iniciativa pioneira em âmbito internacional de tentativa de monitoramento do cumprimento de metas do Desafio de Bonn. Ressalta-se, entretanto, que o ORR compila, mas não processa dados de SR, pois essa tarefa cabe aos mais diversos atores responsáveis pelo constante aprimoramento do SR.

No caso do trabalho de Ruggiero et al. (2019), o SR foi utilizado para avaliar ganhos sócio-ambientais da RF após a implementação de políticas de Pagamento por Serviços Ambientais (PSA) (MURADIAN et al., 2010), que buscam estimular a preservação ambiental. Ruggiero et al. (2019) comentam que o PSA estimula ações de RF e de preservação de remanescentes de vegetação. Na área de estudo, verificaram a dinâmica da cobertura do solo ao longo da implementação dos programas de PSA através do acervo Google Earth e de imagens SPOT fornecidas pelo órgão ambiental local. Os autores encontraram influência significativa do PSA no aumento da RF e calcularam que, neste ritmo de in-

cremento vegetacional, a meta de cobertura de 33% de vegetação na área abrangida pelos programas de PSA levará 180 anos. Apesar dos resultados positivos, os autores alertaram para um problema crucial de governança: para garantir os benefícios de RF impulsionados pelo PSA, é necessário que os contratos de PSA sejam renovados ao longo do tempo. Caso tais contratos não sejam renovados, a floresta gerada por RF ainda não estará legalmente protegida na Mata Atlântica por falta de porte, o que aumentaria o tempo necessário para que a floresta passe a ser protegida por lei. Logo, nos programas de PSA estudados, para que a RF consiga atingir o patamar de tornar a vegetação protegida por lei, são necessárias as renovações dos contratos, pois, segundo os autores, a floresta precisa de 8 a 15 anos de RF para se tornar protegida por lei. Vale também verificar que o único parâmetro de monitoramento adotado por Ruggiero et al. (2019) foi a cobertura de dossel, até porque os autores trataram de RF em escala, segundo terminologias de escala em Adams et al. (2016), regional.

Utilidades do SR orbital para escalar análises de RF também são mencionados por DeLuca et al. (2010) e Ding et al. (2021), visto que é inviável realizar trabalhos de campo em todas as áreas de interesse. Ding et al. (2021), entretanto, apontam uma possível solução à questão de análises em maior escala, pois usa satélites gratuitos para avaliar a qualidade das florestas ao longo do tempo (decréscimo, acréscimo ou permanência de qualidade). Os autores detectaram áreas com vegetação, classificaram-nas segundo topografia, clima e solo junto a uma comparação com dados de campo, detectaram áreas de remanescentes (modelo referência para a restauração) como sendo as ausentes de desmatamento ao longo do tempo, compararam áreas de restauração com os remanescentes próximos para finalmente diagnosticar a qualidade da restauração. Apesar de atingir boa acurácia avaliada por parcelas de campo e proporcionar avanços no monitoramento em larga escala, Ding et al. (2021) não comentam em seu texto que os parâmetros dos modelos criados, para serem aplicados em outros biomas de outros países, devem passar por um processo de calibração.

Quando observamos os estudos e experiências de restauração em escala regional nos biomas brasileiros, a iniciativa MapBiomas, que usa imagens de satélites disponibilizadas gratuitamente, verificou que a área total de floresta nativa manteve-se estável de 1990 a 2017 na Mata Atlântica, mas houve nesse período redução de florestas maduras e aumento de florestas secundárias, além do maior isolamento destas áreas (ROSA et al., 2021). Tal fato gera consequências ambientalmente negativas ao bioma, pois serviços ecossistêmicos ocorrem com menor efetividade, o que demanda integração de políticas de Restauração de Ecossistema em escala regional e nacional (ROSA et al., 2021). Junior et al. (2020)

também utilizaram satélites com imagens disponibilizadas gratuitamente e constataram amplo desmatamento em uma região da Amazônia brasileira, levantando alertas para a necessidade de integração de projetos de RF em escala regional para evitar colapso ambiental e promoção de desenvolvimento sustentável.

Imagens de satélites já foram usadas para definir também em escala regional (considerando-se a terminologia de escalas de Adams et al. (2016)) áreas prioritárias de RF entre blocos fragmentados de remanescentes de vegetação (WICKHAM et al., 1999). Os autores avaliaram a vegetação em bacias hidrográficas e constataram que em determinados locais a mesma apresentou uma distribuição fragmentada ao longo do espaço, o que é indesejado. Para amenizar o fenômeno de fragmentação (pequenos trechos desconectados entre si ao longo do espaço) da região, o uso do SR permitiu mapear potenciais áreas de RF que aumentariam a conectividade entre as florestas. Tal mapeamento de áreas potenciais para RF considerou a relação espacial entre a quantidade de área antropizada e a quantidade de grandes fragmentos de florestas, verificando-se então a localização dos maiores ganhos de cobertura de dossel ao ligar via RF fragmentos vegetacionais desconectados. Os autores concluíram que a relação que mais proporciona incremento vegetal ao ligar dois fragmentos vegetacionais é quando a região possui entre 20% e 40% de cobertura antropizada: valores menores tendem a possuir florestas já bem conectadas e valores maiores tendem a possuir vegetação em diversos e pequenos blocos. Sobre o planejamento de unidades de preservação ambiental, vale ressaltar, entretanto, a constatação de Simberloff e Abele (1976) e Higgs (1981), em que a teoria da biogeografia de ilhas não deve ser o único norteador ou única fonte de embasamento, pois grandes fragmentos não necessariamente otimizam variáveis ecológicas desejadas por políticas ambientais. Esse contraponto de Simberloff e Abele (1976) e Higgs (1981) evidencia a complexidade de assuntos voltados à preservação ambiental e RF. Ainda, o fato de Wickham et al. (1999) terem usado apenas cobertura de dossel como parâmetro para avaliar locação de corredores ecológicos via RF reforça o contraponto de Simberloff e Abele (1976) e Higgs (1981).

Apesar da importância do SR no mapeamento da cobertura do solo por vegetação arbórea, que é uma variável importante na gestão e monitoramento de processos de RF conforme mostrou a seção 3.1.2, Putz e Redford (2010) alertaram que a degradação da qualidade das florestas é imperceptível ao SR, concluindo então que tal limitação tornará sempre necessária a realização de trabalhos de campo em áreas de RF. Tal constatação é importante, pois o surgimento de tecnologias frequentemente impulsionam o debate da substituição do campo por SR, sendo que o objetivo do SR deve ser ampliar a escala do monitoramento da RF.



Num apanhado sobre possibilidades e necessidades de envolver RF e SR em diferentes escalas, Reif e Theel (2017) abordaram a demanda de protocolos de monitoramento gerais possíveis de serem implementados em políticas e órgãos ambientais. Segundo os autores, satélites como Terra, Landsat e SPOT contribuíram para políticas ambientais em maior escala, mas a baixa resolução espacial destes produtos tornavam ações locais carentes de mapeamento mais detalhado. Aerofotogrametria convencional ofereceu maior resolução espacial, mas o alto custo de voos em aviões comerciais limitou o uso desta tecnologia. Essa questão da abrangência de áreas foi sanada por satélites como o WorldView-2, que proporcionaram avanços em estudos ecológicos detalhados em maior extensão que fotogrametria, possibilitando, inclusive, mapear espécies desejadas e indesejadas. No decorrer do avanço tecnológico, sensores hiperespectrais aprimoraram a identificação de espécies vegetais e sensores *Light detection and ranging* (LiDAR) auxiliaram a medição da estrutura das árvores. Mesmo diante de tantos avanços tecnológicos e contribuindo para o meio ambiente, Reif e Theel (2017) alegaram que protocolos eficientes de monitoramento de RF no mundo todo ainda careciam de metodologias eficientes. Iniciativas começaram então a direcionar o uso de geotecnologias para aprimorar a gestão e monitoramento de RF. Os autores reforçaram a cobertura do solo e a biodiversidade como duas métricas básicas e essenciais no monitoramento de RF, sendo a altura e a biomassa variáveis que também devem ser consideradas. Outras variáveis importantes, segundo os autores, são a cobertura do solo não apenas da vegetação na RF em si, mas também dos arredores da RF, pois o avanço de áreas antropizadas podem pressionar pela má condução ou mesmo extinção da RF.

O mapeamento via SR da complexidade de estruturas horizontais vegetacionais de áreas em RF foi realizado por Dickinson et al. (2016). Os autores utilizaram o SR de forma colaborativa com os *stakeholders* de florestas visando a tornar mais transparente o monitoramento de processos de RF. A busca pela maior governança na gestão de projetos de RF utilizou imagens aéreas de câmera multiespectral em aeronave convencional. Através de três imagens, obtidas em 2009, 2011 e 2013, bem como da alta correlação das mesmas com os dados coletados em campo, verificou-se que o SR contribuiu para extração de informações fidedignas quanto às métricas horizontais de cobertura de dossel em RF. Os autores, portanto, confirmaram que o registro das imagens aéreas ao longo do tempo permite também maior engajamento dos *stakeholders*, maior transparência e maior governança na gestão de RF.

Um dos *stakeholders* que agregam valiosas informações aos dados de SR em projetos de RF são os fazendeiros. Os motivos pelos quais estes *stakeholders* na Amazônia preferem

fazer uso da terra em áreas com florestas secundárias ao invés de áreas com florestas primárias, principalmente nas situações de proximidade com estradas, podem ser, segundo Moran et al. (1996), uma importante diferença entre sustentabilidade e devastação, além de auxiliar a compreensão do ciclo da unidade doméstica. Os autores buscaram melhor compreender a RF na região amazônica realizando pesquisas nas casas de moradores locais (casas identificadas por classificação não-supervisionada), medições das estruturas da vegetação local (áreas de medição escolhidas a partir de entrevistas realizadas com moradores, que indicavam determinados históricos de uso do solo) e mapeamento das áreas de RF segundo histórico de imagens de satélite da área de estudo (município de Altamira - PA). Foi constatado que pastagens nos arredores de uma rodovia na Amazônia se tornaram vegetação secundária entre 1985 e 1991 numa taxa maior que a de desmatamento na área de estudo, o que é justificado pela falta de demanda de *commodities*, situação típica de estagnação econômica (o Brasil passava por crise econômica no período estudado pelos autores). O trabalho também verificou que a forma pela qual se fez uso da terra e o tempo de regeneração natural influenciam diretamente no porte da vegetação secundária, confirmando que o uso de SR aliado a trabalhos de campo integram dados de escala local, regional e global, contribuindo para o planejamento e gestão da RF na Amazônia. Outra constatação importante deste trabalho foi o motivo da preferência da população local em utilizar florestas secundárias ao invés de primárias: é mais fácil utilizar a terra de vegetação secundária como pastagem, monocultura e agrofloresta. Comenta-se, neste caso, que tal preferência por florestas secundárias caracteriza ocorrência de áreas de pousio ao invés de áreas de RF, o que não reduz a importância do trabalho na compreensão e definição de políticas públicas voltadas à RF.

Nesta relação de importância que os trabalhos de campo têm para as informações obtidas por SR, o trabalho de Shuman e Ambrose (2003) comparou o monitoramento de RF de regiões pantaneiras feito por trabalhos de campo e por imageamento aéreo. Os autores concluíram que o imageamento aéreo tem a vantagem de mapear a cobertura de dossel com mais eficiência, o que é desejável em grandes áreas, e a desvantagem de não ser capaz de mapear a quantidade de espécies presentes no local. Já os trabalhos de campo possuem a vantagem de mapear espécies e a desvantagem da morosidade de se mapear devidamente a cobertura de dossel. Concluíram, portanto, que o método ideal de monitoramento de regiões pantaneiras deve combinar imageamento aéreo com trabalhos de campo.

Satélites de diferentes resoluções, nomeadamente Ikonos utilizado na estação seca e Landsat utilizado na transição da estação chuvosa para seca foram utilizados para mapear

os diferentes estágios de sucessão florestal em áreas de RF na Costa Rica. O trabalho de Arroyo-Mora et al. (2005) buscou identificar a etapa de sucessão florestal a qual se encontra uma RF com base nos parâmetros da vegetação ao invés de classificar com base no tempo de implementação da RF. Afinal, duas RF com mesmo tempo de implementação podem apresentar desempenhos totalmente diferentes (PEET, 1981; ARROYO-MORA et al., 2005). A análise dos autores verificou que índices de vegetação utilizando a banda infravermelho próximo separaram bem as etapas de sucessão ecológica, ao passo que índices utilizando o infravermelho médio não obtiveram bons resultados. Apesar de identificarem padrões de valores de índices de vegetação para os diferentes estágios de sucessão florestal (quando utilizada a banda infravermelho próximo), os autores ressaltaram que não foi possível por SR obter o tempo em anos a qual cada estágio de sucessão se encontra. Devido à época em que foi realizado o trabalho, é interessante notar que os autores comentaram também a diferença da resposta espectral da vegetação na estação seca e chuvosa. Este trabalho de Arroyo-Mora et al. (2005) foi realizado antes de uma maior difusão metodológica do SR em utilizar séries temporais em grandes arquivos de imagens obtidas em diversas épocas de vários anos como feito por Hansen et al. (2013) e Maus et al. (2016).

O mapeamento da cobertura do solo utilizando séries temporais (HANSEN et al., 2013; MAUS et al., 2016) tem um objetivo inicial de mapear com maior precisão a ocorrência de desmatamentos. Nestes casos, verifica-se ano a ano via SR locais onde ocorreu desmatamento, mas áreas desmatadas não raramente voltam a apresentar repostas espectrais semelhantes à de florestas, sendo então detectada uma ocorrência de RF (CROUZELLES et al., 2019; HANSEN et al., 2013). Hasan et al. (2017) utilizaram o algoritmo CLASlite, que sobre a imagem bruta do satélite automaticamente realiza calibração, pré-processamento, correção atmosférica, detecção de nuvens e processamento dos sinais de diversos satélites, gerando, então, valores em porcentagem de Vegetação Fotossintética nas áreas de dossel, Vegetação Não-fotossintética nas áreas desmatadas e Solo Exposto nas áreas de minerais ou construções. O mapeamento dessas três classes em cada ano, conferidas por dados obtidos em campo, permitiu inferir o desmatamento anual e, conseqüentemente, detecção de áreas de RF, apesar de alguma confusão na distinção entre as seguintes classes: exploração madeireira e exploração agrícola; nuvem e sombra de nuvem em áreas úmidas; e florestas primárias e florestas secundárias.

Em relação a séries temporais, o trabalho de Hansen et al. (2013) foi inovador ao considerar a variação da resposta fotossintética e evapotranspiração das florestas ao longo do ano, variação esta evidente no auge da estação chuvosa e no auge da estação seca.

A partir deste conceito, os autores analisaram a perda de vegetação em todo o mundo (exceto a região dos polos) e, conseqüentemente, mapearam áreas de RF entre os anos 2000 e 2012. O trabalho de Hansen et al. (2013) influenciou diretamente uma importante iniciativa de dimensão nacional no Brasil: o MapBiomas (SOUZA et al., 2020).

Crouzeilles et al. (2019) utilizaram dados de SR obtidos por séries temporais e disponibilizados pela iniciativa MapBiomas (<<http://mapbiomas.org/>>) para localizar as áreas de RF no Brasil. O MapBiomas considera como RF áreas desmatadas que ao longo do tempo voltaram a apresentar resposta espectral típica de vegetação, devendo essa situação (resposta espectral típica de vegetação) permanecer durante um intervalo mínimo de tempo de forma a confirmar que não se trata de áreas de pousio (CIRNE; SOUZA, 2014). Neste caso, Crouzeilles et al. (2019) consideraram trechos que eram antropizados até 2011 e deste ano até 2015 passaram a ser cobertos por vegetação, vegetação esta que deveria perdurar até 2017 para ser considerada RF. Com metodologia conservadora de SR e acurácia obtida de 78%, os autores encontraram um total de RF excedendo o Desafio de Bonn em 1 Mha para o bioma Mata Atlântica, ressaltando apenas que a regeneração natural, apesar do baixo custo de implementação, pode comprometer a biodiversidade, tornando o plantio de nativas importante no contexto da Mata Atlântica. Os autores apontaram três quesitos que foram fundamentais na obtenção dos bons números obtidos para a RF na Mata Atlântica baseados em movimentos *bottom-up* (FRASER et al., 2006): (1) desenvolvimento de estratégias de articulação, comunicação e governança capazes de efetivamente engajar todos os *stakeholders*, bem como de instrumentos legais contra o desmatamento; (2) desenvolvimento de sistemas de monitoramento baseados em SR e trabalhos de campo divulgados em plataforma *online*; e (3) promoção de visão estratégica influenciadora de políticas públicas e de ações em multi-nível, tendo grande peso regiões íngremes de pecuária improdutivo que acabaram sendo abandonadas.

Satélites permitem avaliação da RF em escala regional e nacional. Quando se considera a escala local, satélites comerciais, aviões convencionais e drones geram produtos com resolução espacial elevada, com pixel inferior a 30 centímetros, o que caracteriza um elevado grau de detalhes nas imagens. Alguns satélites comerciais mostraram-se capazes de detectar copas de árvores no deserto do Sahara (BRANDT et al., 2020), aviões comerciais com LiDAR associados a drones classificaram cobertura do solo (REIS et al., 2019a), drones carregando sensores LiDAR identificaram diferentes estágios de sucessão ecológica (ALMEIDA et al., 2019) e drones de menor custo mostraram potencial para monitoramento da RF (ZAHAWI et al., 2015), sendo o trabalho de Figueiredo e Figueiredo (2018) um interessante material sobre a realização de voos autônomos no Brasil. Dentre

todas essas tecnologias e frentes de trabalho, a utilização de sensores LiDAR apresentaram maior riqueza de detalhes da vegetação, possibilitando inovações e transparência nas medições de carbono cujo alto custo de implementação poderá futuramente ser reduzido mediante uso conjunto a satélites gratuitos (ALMEIDA et al., 2020).

Ao se considerar produtos de SR orbital com maior resolução espacial, é possível obter dados que requerem maiores detalhes, como a densidade de árvores. A densidade de árvores pode ser obtida por Detecção Individual de Árvores (DIA), na qual cada árvore é contabilizada por uma coordenada geográfica (MOHAN et al., 2017), ou por Detecção de Copa de Árvores (DCA), onde cada árvore tem sua copa delineada (BRAGA et al., 2020), o que permite inferir alguns atributos de cada árvore, como identificação da espécie, clareiras ou biomassa (JING et al., 2012).

Frente à possibilidade de detectar árvores por DCA, que fornece métricas das copas, Dalponte, Frizzera e Gianelle (2019) alegaram que o DCA nem sempre é melhor obtido a partir de dados LiDAR, pois conseguiram melhores resultados utilizando sensor hiperespectral, apesar de ressaltar que a performance depende de como fazer uso dos dados e que a espécie mais frequente na área de estudo foi mais acurada ao ser classificada por sensor hiperespectral do que por LiDAR. No caso, os autores utilizaram máscara  $NDVI > 0,6$ , levantamento da DIA, delineamento das coordenadas da DIA pelo algoritmo *itcSegment* (DALPONTE, 2018) e refinamento do modelo a partir de dados coletados em campo. A acurácia do DCA avaliada pela pontuação Jaccard (REAL; VARGAS, 1996) obteve valores equivalentes a 0,3402 (34% verdadeiro-positivo). Apesar do valor Jaccard baixo, os autores alegaram que esta metodologia foi robusta e recebeu prêmios no desafio *National Ecological Observatory Network—National Institute of Standards and Technology*.

Wagner et al. (2018) realizaram o DCA em imagem RGB obtida por satélite de alta resolução espacial (0,5m). Os dados referência foram manualmente delineados e confirmados em campo. A metodologia foi complexa, envolvendo áreas de sombra, operações morfológicas de erosão e dilatação, filtro de tamanho de copas e filtros kernel. O índice Kappa obtido foi de 0,7, valor este de acurácia considerado bom pelos autores devido ao fato de se tratar de imagem RGB. Os autores também comentaram que o método não funciona em florestas sem dossel fechado.

Mesmo diante de tamanha complexidade na obtenção do DCA conforme o trabalho de Wagner et al. (2018), recentemente o *deep learning* vem mostrando resultados promissores em análises da vegetação. Algoritmos de *deep learning* consistem em múltiplas camadas de processamento com capacidade de aprender sobre a representação dos dados em diversos

níveis de abstração, o que gerou uma revolução no campo de processamento de imagens (LECUN; BENGIO; HINTON, 2015).

O trabalho de Wagner et al. (2019) utilizou o *deep learning*, algoritmo U-Net, em imagem Worldview (resolução espacial de 0,3 metros) no intuito de classificar a cobertura do solo (floresta nativa ou eucalipto) e de detectar uma espécie invasora na Mata Atlântica. Os autores obtiveram acurácia geral maior que 95% e Fscore superiores a 0,8. Os erros nos remanescentes de vegetação e nos plantios de eucalipto ocorreram em sua maioria na homogeneidade espectral ocasionada por ausência de sombra (confusão com gramíneas) e na ausência de espaçamento regular, respectivamente. Os autores, portanto, recomendaram o uso do U-Net em análises locais por ser fácil de executar e ter bons resultados em imagens de alta resolução, sendo recomendados outros algoritmos ou outras arquiteturas *deep learning* quando se deseja mapear em maior escala (por exemplo, escala nacional como a iniciativa MapBiomass). Também comentaram que a coleta de amostras para o U-Net pode ser mais difícil em regiões de dossel menos denso ou aberto, como savanas, devido à limitação de amostras disponíveis.

Mostrando-se promissor na acurácia de DCA, o algoritmo Mask-RCNN (HE et al., 2017) foi avaliado por Braga et al. (2019) numa área do estado Mato Grosso (MT), Brasil. Os autores utilizaram bandas RGB do satélite WorldView (resolução espacial de 0,5 metros), rede residual ResNet-101, algoritmo retro-propagação do erro para ajuste dos parâmetros peso e viés da rede e treinamento em 30 épocas. A acurácia foi avaliada por acurácia global e IoU (*Intersection over Union*, que é a quantidade relativa de Verdadeiros-Positivo) e os valores obtidos foram iguais a, respectivamente, 0,638 e 0,812. As dificuldades do algoritmo foram em copas muito pequenas ou nas regiões de fronteira das árvores (sombras e outros elementos). Segundo os autores, as falhas podem ser contornadas caso sejam acrescentadas ao treinamento amostras de árvores pequenas e, possivelmente, removendo-se regiões sombreadas. Entretanto, os valores de acurácia são considerados altos, e as figuras do trabalho mostram resultados interessantes de DCA em ambiente urbano.

Em outro trabalho deste mesmo grupo de pesquisa, Braga et al. (2020) avaliaram a obtenção do DCA pelo algoritmo Mask-RCNN em uma área preservada da Mata Atlântica. Seguindo os procedimentos descritos no parágrafo anterior, exceto a rede residual, que neste caso foi a ResNet-51, os autores conseguiram valores de acurácia global e IoU equivalentes a 0,88 e 0,61, respectivamente. Considerando a complexidade e heterogeneidade das copas que compõem o dossel fechado da área de estudo, trata-se de um trabalho relevante para DCA em floresta tropical, dada a dificuldade do mapeamento das árvores

neste tipo de ambiente. Vale notar que o uso de *deep learning* por Braga et al. (2020) gerou resultados mais acurados que outros trabalhos de DCA, como a complexa metodologia utilizada por em Wagner et al. (2018).

Uma tecnologia que tem mostrado importantes resultados na análise da vegetação é o LiDAR porque é capaz de mapear objetos abaixo de dossel, o que possibilita estudos da estrutura vertical da vegetação (DUBAYAH; DRAKE, 2000; LEFSKY et al., 2002; LIM et al., 2003; ALMEIDA et al., 2019). Tal análise da estrutura vertical é possível porque um mesmo pulso recebe múltiplos retornos (NATIONAL SCIENCE FOUNDATION, 2021).

Trabalhos como o de Jaafar et al. (2018) geraram o DCA a partir de segmentação (algoritmo watershed) do CHM obtido por sensor LiDAR e refinamento a partir de dados de campo. A acurácia foi medida comparando-se com os dados de campo a quantidade de segmentação perfeita (verdadeiro-positivo), subsegmentação (falso-negativo) e sobresegmentação (falso-positivo). Os índices *Recall*, *Precision* e *Fscore* apresentaram valores variando de 0,69 a 0,88 nas áreas de estudo. Comenta-se que dados LiDAR são capazes de gerar informações sobre a estrutura da vegetação abaixo do dossel, informação esta utilizada no DCA realizado por Jaafar et al. (2018), que consideraram copas menores nas árvores mais baixas.

Castillo et al. (2012) utilizaram LiDAR para mapear a estrutura da vegetação em áreas de florestas secas em estágio secundário de sucessão florestal. Castillo et al. (2012) encontraram uma relação direta entre distribuição vertical de biomassa vegetal e estágio de sucessão ecológica, relação esta devidamente identificada e agrupada pelo algoritmo de classificação não-supervisionada ISODATA (SCHOWENGERDT, 2007). O estágio de sucessão intermediário é importante, segundo os autores, porque orienta políticas de Pagamento por Serviços Ambientais (PSA) e foi possível de ser devidamente subdividido em três diferentes padrões de classificação segundo distribuição de biomassa vegetal. Ou seja, a tecnologia LiDAR contribuiu para um bom monitoramento da RF e, conseqüentemente, para a gestão de PSA.

A tecnologia LiDAR mostrou-se robusta na obtenção da altura das árvores (WALLACE et al., 2016), que ocorre de forma mais precisa que as medições por métodos convencionais de campo (SIBONA et al., 2017). Com a possibilidade de se ampliar a escala da medição da altura, a aquisição precisa das equações alométricas (relações matemáticas entre diâmetro, altura e densidade de madeira das árvores) tem se mostrado importante para ampliação da escala de cálculos de biomassa (LAU et al., 2019) e sequestro de carbono (MATZEK; STELLA; ROPION, 2018).

Por exemplo, através das equações alométricas oriundas dos dados coletados nas parcelas de campo, aliadas à medição precisa da altura das árvores por SR (principalmente por LiDAR) de toda uma gleba em processo de restauração, a biomassa presente em toda a área pode ser calculada com mais precisão (FIGUEIREDO et al., 2016; JUCKER et al., 2017; LAU et al., 2019; ALMEIDA et al., 2019), bem como o sequestro de carbono (MATZEK; STELLA; ROPION, 2018). Ressalta-se que o cálculo de biomassa tem grande relevância para o mapeamento do ciclo do carbono pelo mundo, que tem ligação com políticas de combate às mudanças climáticas (BACCINI et al., 2012). Esse processo promove maior escala aos detalhes da vegetação, que partem de parcelas e vão à áreas inteiras em processo de restauração, aprimorando assim a qualidade das informações de toda uma região (ALMEIDA et al., 2020).

Frente às diversas possibilidades tecnológicas que o SR oferece ao monitoramento de RF, conforme mostrados nesta seção, busca-se uma que ofereça bom custo-benefício de forma a tornar mais célere e fidedigna a realização deste processo. Uma tecnologia promissora a este objetivo são as RPA-SfM. O potencial das aplicações de RPA-SfM voltada para trabalhos de vegetação e de monitoramento de RF é abordado na seção 3.3 a seguir.

### **3.3 Uso de RPA-SfM no estudo da Vegetação e em projetos de Restauração Florestal**

Frente ao potencial uso de RPA-SfM no registro da superfície terrestre, marcado pela alta resolução espacial de dados altimétricos e dos ortomosaicos (AASEN et al., 2015; OLTMANNNS et al., 2012), trata-se de uma tecnologia aplicada ao monitoramento da RF em escala local (CAMARRETTA et al., 2020). A alta resolução dos produtos cartográficos obtidos por RPA-SfM tornou recorrentes estudos acerca de detalhes estruturais da vegetação e ocorrências de espécies.

#### **3.3.1 RPA-SfM e a estrutura da vegetação**

Na proposta de monitoramento de RF via RPA-SfM, a altura do dossel é uma variável importante na fase definida por Brancalion et al. (2012) como Fase de vegetação formada (4 ou mais anos). Ou seja, uma vez fechado o dossel, o que numa RF bem conduzida ocorre após 4 anos de instauração do projeto, a variável altura ganha importância porque sua evolução indicará se as plantas clímax se estabeleceram no processo de sucessão ecológica



o qual se baseou a RF. Ressalta-se que RPA-SfM é capaz de medir a elevação da paisagem com precisão centimétrica (CLAPUYT; VANACKER; OOST, 2016; UYSAL; TOPRAK; POLAT, 2015), logo, a variável altura das árvores, antes muitas vezes menosprezada, pode ser medida rapidamente e de forma precisa (ZAHAWI et al., 2015), compondo assim uma importante base de dados no monitoramento da RF.

Chen et al. (2017) avaliaram diferentes metodologias de medição de altura das árvores em áreas de RF no Canadá através de RPA-SfM, utilizando diferentes métodos de obtenção do MDT. Tal obtenção do MDT foi realizada via: mapeamento de coordenadas precisas obtidas por *Real-time Kinematic* (RTK); LiDAR pré-existente na área de estudo; e nuvem de pontos SfM-MVS. Sobre a acurácia, os autores concluíram que SfM-MVS pode substituir LiDAR quando a vegetação é menor e sem dossel fechado. Já nos casos de vegetação densa, os autores observaram que a princípio o SfM-MVS tende a subestimar a real altura da vegetação, o que não ocorre com a tecnologia LiDAR, sendo necessários mais estudos para confirmar essa questão. Ou seja, o trabalho de Chen et al. (2017) reforçou o SfM-MVS como uma tecnologia mais rápida de ser trabalhada e de menor custo, sendo, portanto, indicada para monitorar RF em estágio inicial. O estágio inicial de uma RF é muito importante para o sucesso do projeto, pois é uma fase mais sujeita a adversidades. Quando devidamente monitoradas, eventuais adversidades são encontradas e a remediação pode ser devidamente direcionada (MARTINS, 2012).

Em seu trabalho, Chen et al. (2017) fizeram também uma análise de custos considerando a área total das parcelas de campo de 2,7 ha e as três metodologias de monitoramento: inventário florestal, RPA com base LiDAR e RPA-SfM. Verificaram que o trabalho de campo convencional foi o mais caro (\$16.900,00), seguido por RPA com base LiDAR para pontos de controle (\$14.344,00) e por RPA-SfM (\$10,463). O fato da utilização de RPA-SfM ser o de menor custo não ocorreu apenas devido ao preço de aquisição, mas também o tempo de trabalho o qual a tecnologia demanda, que foi o mais rápido em relação às demais estudadas pelos autores. Conforme relatado no parágrafo anterior, o RPA-SfM mostrou boa acurácia em situações de RF em estágio inicial, o que aliado a um menor custo de execução acaba por reforçar o uso desta tecnologia no monitoramento de fases iniciais de RF.

Há trabalhos publicados no âmbito acadêmico que consideram RPA de baixo custo aqueles que embarcam sensores RGB (SCHIRRMANN et al., 2016), ou mesmo sensores de baixo custo (GAGEIK; BENZ; MONTENEGRO, 2015). No caso do trabalho de Sankey et al. (2017), foram utilizados dois sensores altamente complexos embarcados em um RPA, que são os sensores LiDAR e hiperespectral, na comparação com sensores multiespectrais

e dados de campo para monitoramento de biomassa vegetal em evento pós-incêndio. A correlação com dados de campo utilizando fusão de sensores LiDAR e hiperespectral foi maior do que utilizando esses complexos sensores separadamente e do que utilizando o sensor multiespectral. O sensor multiespectral, porém, obteve bons índices de acurácia referentes à biomassa (a identificação de espécies não foi realizada no trabalho) e se mostrou uma alternativa de menor custo ao monitoramento de RF pós incêndio no Arizona (EUA) principalmente se a densidade de árvores for baixa.

Zahawi et al. (2015), via sensor RGB, buscaram medir altura de dossel, biomassa, complexidades estruturais da vegetação e aberturas de clareiras em áreas de RF, bem como a capacidade de previsão de chegada de aves frugívoras, que possuem potencial para estimular o processo de RF. Foram coletadas informações de campo acerca da estrutura e da copa da vegetação, verificação da presença de aves frugívoras e altitude do terreno abaixo da vegetação, constituindo assim a base de dados considerada referência para medições de altura de dossel. Com uma série de tratamentos estatísticos entre os dados de campo e os dados coletados via RPA-SfM, os autores constataram uma alta correlação com  $R^2 > 0,8$  para altura do dossel, biomassa acima do solo, percentual de presença de clareiras e capacidade de previsão de chegada de aves frugívoras. Já as medidas baseadas em proporção, como fração de altura de árvores composta pela copa, apresentaram menor correlação entre os dados referência e os dados RPA-SfM.

A riqueza de detalhes em imagens de alta resolução é objeto de estudo em metodologias *Object Based Image Analysis* (OBIA) (BLASCHKE, 2010). O trabalho de Goodbody et al. (2018) utilizou método OBIA para avaliar automaticamente a estrutura da vegetação em regeneração natural imageada por RPA com sensor RGB. Na RF de regeneração natural, os autores buscaram mapear a ocorrência de vegetação conífera, vegetação decídua e solo exposto. Trabalhos de campo geraram inventário florestal e coordenadas GNSS no solo foram obtidas para possibilitar a geração do Modelo Digital de Terreno (MDT) e, conseqüentemente, o *Canopy Height Model* (CHM), que é a diferença entre MDS e MDT (LISEIN et al., 2013; GUTH et al., 2021). Os índices de vegetação MPRI, VARI e GLI, descritos por Hunt et al. (2013), foram gerados e utilizados como atributos na segmentação "watershed por imersão". Após a segmentação, a classificação do algoritmo *Random Forest* considerou 86 atributos, dentre os quais estão o CHM, estatísticas (mínimo, máximo, média, alcance, moda e desvio padrão) das bandas RGB e atributos de textura obtidos a partir do software FETEX 2.0 (RUIZ et al., 2011). Os resultados apresentaram algumas confusões entre as classes de vegetação conífera e decídua, mas alta acurácia geral. Os autores comentaram a importância de se utilizar os índices de vegetação e desvio

padrão do CHM para promover a correta discriminação dos alvos, podendo os resultados ser melhorados se houver calibração radiométrica das imagens aéreas. A metodologia dos autores mostrou-se robusta e os RPA com sensor RGB foram adequados para auxiliar a gestão das três classes-alvo de RF no Canadá. Além disto, os autores comentaram que o SfM-MVS com coordenadas do solo mostrou bons resultados nas medidas de estrutura da vegetação, mas é necessário ressaltar que as áreas de estudo não possuíam dossel fechado e que as florestas canadenses possuem menor biodiversidade que florestas tropicais.

Diante de rápidos avanços científicos no mundo eletrônico e digital, Elliott (2016) fez uma revisão das tecnologias disponíveis para estimar futuras contribuições de sensores diversos embarcados em RPA no monitoramento de áreas em Regeneração Natural Assistida (RNA) visando a auxiliar a formação adequada de florestas secundárias. RNA, conforme explicado por Shono, Cadaweng e Durst (2007), são regenerações naturais com algum tipo de ação humana visando a uma adequada RF, como locação de aceiros, desbastes, atração a aves, etc. Assim, o trabalho de Elliott (2016) citou benefícios da tecnologia LiDAR em identificar mudas de árvores suprimidas por gramíneas ou estrutura das árvores abaixo do dossel, sendo que o uso do sistema Ecosynth <<http://ecotope.org/projects/ecosynth/>> permite estimar essas medidas a partir da tecnologia *Structure from Motion and Multi-View-Stereo* (SfM-MVS) (COLOMINA; MOLINA, 2014; MICHELETTI; CHANDLER; LANE, 2015; SCHONBERGER; FRAHM, 2016), que pode ser empregada utilizando-se equipamentos de menor custo (TAROLLI, 2014). Já para identificação de espécies, o autor indicou sensores hiperespectrais como mais apropriados, apesar de que mesmo com essa tecnologia a identificação de espécies deve ser analisada com cuidado porque uma mesma espécie não raramente varia em termos de idade, saúde, fenologia, declividade, etc., o que dificulta a obtenção de bons índices de acurácia.

Outro comentário de Elliott (2016) é que um dos fatores de maior insucesso em regeneração natural é a presença de gramíneas, sendo a capina o tratamento mais importante em RNA, mas também o de maior custo. O autor acredita que a automatização da capina será, futuramente, realizada via lançamento de herbicidas por RPA. Similarmente, em relação ao enriquecimento de espécies em RNA, o autor acredita que futuramente essa operação será automatizada via semeadura aérea a ser realizada por RPA. Em relação aos obstáculos existentes até a publicação do estudo de Elliott (2016), o autor citou: a duração das baterias; planejamentos de voos seguros e automáticos sobre o dossel e sobre áreas dominadas por gramíneas; e diminuição dos custos das tecnologias envolvendo RPA (apesar de que muitos dos recursos disponíveis até a publicação do estudo já apresentaram redução de preço). Finalmente, o autor concluiu que a RF deve direcionar a

tecnologia e não que a tecnologia direcione a RF, estimulando o uso da interdisciplinaridade para o desenvolvimento de tecnologias de bom custo-benefício, socialmente aceitas e cientificamente inovadoras.

Sensor hiperespectral e SfM-MVS de sensor RGB a bordo de RPA foram utilizados em voos separados em duas áreas de ambiente florestal na Finlândia para avaliar árvores que sofreram ataques de besouros (NÄSI et al., 2015). A utilização destes sensores permitiu a obtenção de imagens hiperespectrais e nuvens de pontos, sendo utilizado também um acervo do Scanner Aéreo Nacional da Finlândia como base para extrair o nível do solo abaixo da nuvem de pontos do dossel. A acurácia do delineamento de copas via algoritmo watershed foi de 74,7%. Cada copa envolveu atributos dos mosaicos hiperespectrais e dos mosaicos RGB para classificação do algoritmo *k-nearest neighbor* (knn) (KHUMAN, 2013). As classes para cada árvore foram Saudável, Infectada ou Morta. Como a classificação entre Saudável e Infectada apresentou certa confusão, resultados mais acurados foram obtidos considerando-se apenas as classes Saudável e Morta na identificação de árvores atacadas por besouros. Comenta-se que sensores hiperespectrais possuem maior custo de aquisição, sendo oportuna a sugestão de utilizar sensores mais acessíveis, como RGB ou multiespectrais.

No intuito de estudar sensores de menor custo de aquisição, Puliti et al. (2015) verificaram a correlação de dados de inventário florestal e dados obtidos por RPA-SfM. Os autores comentaram que o uso de LiDAR possui bom custo-benefício se utilizado em larga escala, mas ainda assim essa tecnologia possui limitações de alto custo de aquisição e de área total sobrevoada devido à demanda computacional para processar grande volumes de dados. Devido a estas limitações, os autores optaram por estudar o potencial da tecnologia SfM-MVS, via sensor RGNIR, aliada a dados de campo (inventário florestal) e informações espectrais na obtenção e modelagem (regressão múltipla) de métricas florestais em área da Noruega. Como resultados, apenas as variáveis número de troncos e área basal não obtiveram  $R^2 > 0,71$  e as métricas espectrais contribuíram pouco para o aprimoramento da acurácia do modelo. As métricas espectrais contribuíram menos ao modelo que métricas do CHM (altura das árvores) porque foram avaliados parâmetros estruturais, mas segundo os autores, essa baixa contribuição ocorreu devido aos voos serem realizados no outono (folhas ausentes ou com baixa reposta espectral), sugerindo então que novos voos sejam feitos em épocas de estações de folheamento. Puliti et al. (2015) comentaram também que trabalhos em estações anuais de folheamento também agilizariam a realização de voos porque no outono a incidência de luz é mais curta e rapidamente variável ao longo do dia. Apesar dos bons resultados, os autores comentaram que a metodologia aplicada

difícilmente obteria bons resultados em florestas tropicais densas (maior biodiversidade e dossel fechado, sendo que a área estudada pelos autores na Noruega possui dossel aberto) ou em áreas declivosas (a área de estudo no trabalho dos autores possui relevo plano).

Diante do potencial que os RPA oferecem no monitoramento de áreas em RF, Reis et al. (2019a) compararam a performance de sensor multiespectral RGNIR (SfM-MVS) e LiDAR no mapeamento automático de quatro importantes classes a serem monitoradas em RF na Bahia (Brasil): sombra (classe muito presente no sensor RGNIR, que é um sensor passivo), dossel, gramíneas e solo exposto. Os autores também buscaram comparar a acurácia dos classificadores supervisionados MAXVER e Random Forest (GISLASON; BENEDIKTSSON; SVEINSSON, 2006). Coordenadas geográficas foram coletadas em campo para validar a classificação e a acurácia foi medida por matriz de confusão e índice Kappa. Os resultados SfM-MVS e LiDAR obtidos por Reis et al. (2019a) tiveram excelente desempenho, sendo maior no algoritmo Random Forest do que no MAXVER em ambos os casos. Acerca da aplicação das tecnologias SfM-MVS e LiDAR, os autores ressaltaram que o primeiro tem a vantagem de ter menor custo de aquisição e o último a vantagem de não ser afetado por sombra por ser um sensor ativo.

Uma informação importante em projetos de RF é a quantidade de árvores presentes no local, havendo estudos de automatização na Detecção Individual de Árvores (DIA) (MOHAN et al., 2017). Conforme mencionado na seção 3.2, DIA identifica automaticamente indivíduos arbóreos através de uma coordenada geográfica no ponto mais alto de cada árvore ao invés de delinear toda a copa de cada árvore, o que é conhecido como Detecção de Copa de Árvores (DCA) (WAGNER et al., 2018). Processos de DCA geram um polígono para representar cada árvore, o que demanda maior processamento computacional do que processos de DIA, que geram uma coordenada apenas para cada árvore.

A acurácia de DIA utilizando RPA com sensor RGB numa área florestal nos EUA foi avaliada por Mohan et al. (2017). Utilizando pontos de controle via GNSS, parcelas aleatórias na imagem para coletar dado referência via fotointerpretação, geração do CHM e aplicação do algoritmo Máxima Local (WULDER; NIEMANN; GOODENOUGH, 2000; SILVA et al., 2016; SILVA et al., 2017) (escolhendo-se o melhor resultado dentre os obtidos variando-se os valores dos parâmetros deste algoritmo), foi obtido  $Fscore > 0,8$ , evidenciando alta acurácia nos resultados. Mais detalhes sobre o parâmetro Fscore na avaliação de acurácia pode ser verificado em Nevalainen et al. (2017). A alta acurácia sugeriu o SfM-MVS como uma alternativa ao LiDAR em projetos de DIA em áreas florestais, bem como um importante complemento a inventários florestais. O algoritmo Máxima Local foi aplicado numa área florestal nos EUA, onde há poucas espécies e idade semelhante

das árvores, o que segundo os autores contribuiu para a boa acurácia do método aplicado devido à baixa variabilidade no formato das copas. Tal fato torna oportuno estudar a aplicação de DIA numa área de RF em bioma brasileiro devido à maior biodiversidade e diferentes portes entre os indivíduos arbóreos.

Já Torres-Sánchez et al. (2018) obteve o DCA mediante OBIA utilizando o software *eCognition* numa área de plantio de oliveiras imageada por sensor RGB embarcada em RPA. O procedimento consistiu em segmentar a imagem em objetos quadrados de  $1\text{m}^2$ , separação entre solo exposto e vegetação através de valores referentes ao desvio padrão do DSM e segmentação apenas das áreas classificadas como árvores. Comparando-se (i) o volume das copas obtido por DCA automático com o volume obtido por copas delineadas manualmente e (ii) a alturas de árvores oriundas do DCA com a altura de árvores medidas em campo, os autores obtiveram acurácia de 95% para o volume das copas e erro de altura inferior a 10% nas áreas vegetadas. Estes foram os melhores resultados obtidos pelos autores, recomendando então voos com sobreposição longitudinal de 95% e sobreposição lateral de pelo menos 60%. Apesar dos bons resultados, a acurácia avaliada foi a qualidade do DSM e não a qualidade do DCA em si. Além disso, plantios de oliva são homogêneos e simetricamente espaçados, sendo que RF em florestas tropicais lidam com maior quantidade de espécies (muitas vezes com diferentes formatos de copa) e espaçamentos não regulares em linhas e entrelinhas de plantio. Se a RF for regeneração natural, não há qualquer tipo de espaçamento definido.

Em outro trabalho utilizando OBIA em imagens obtidas por sensor RGB em RPA, Yurtseven et al. (2019) utilizaram o *eCognition* na obtenção do DCA numa área da universidade de Instambul. Os autores utilizaram como dado referência dados de campo (inventário florestal) e fotointerpretação. Os autores não utilizaram na avaliação de acurácia análises como Matriz de Confusão, mas índices calculados a partir de vetores referentes aos erros de omissão e comissão dos resultados (maior comprimento do vetor de erro contribui para menor acurácia final), vetor da média dos erros, distância euclidiana do vetor de maior erro e Polígono dos Erros a partir da Maior Distância Euclideana conforme mostra a Figura 3. A acurácia encontrada segundo os índices adotados foi igual a 0,8553 com desvio padrão de 0,1662, sendo os erros horizontais iguais a  $0,3542 \pm 0.4133$  metros e erros verticais inferiores a 0,5 metros. Apesar da alta acurácia, comenta-se que o trabalho de Yurtseven et al. (2019) não apresentou dossel fechado na área de estudo, sendo que florestas tropicais brasileiras possuem dossel fechado.

Duarte, Silva e Teodoro (2018) desenvolveram um plugin no software QGIS 2.18 para realização do DCA. Para validar o plugin, os autores utilizaram sensor multiespectral Mi-

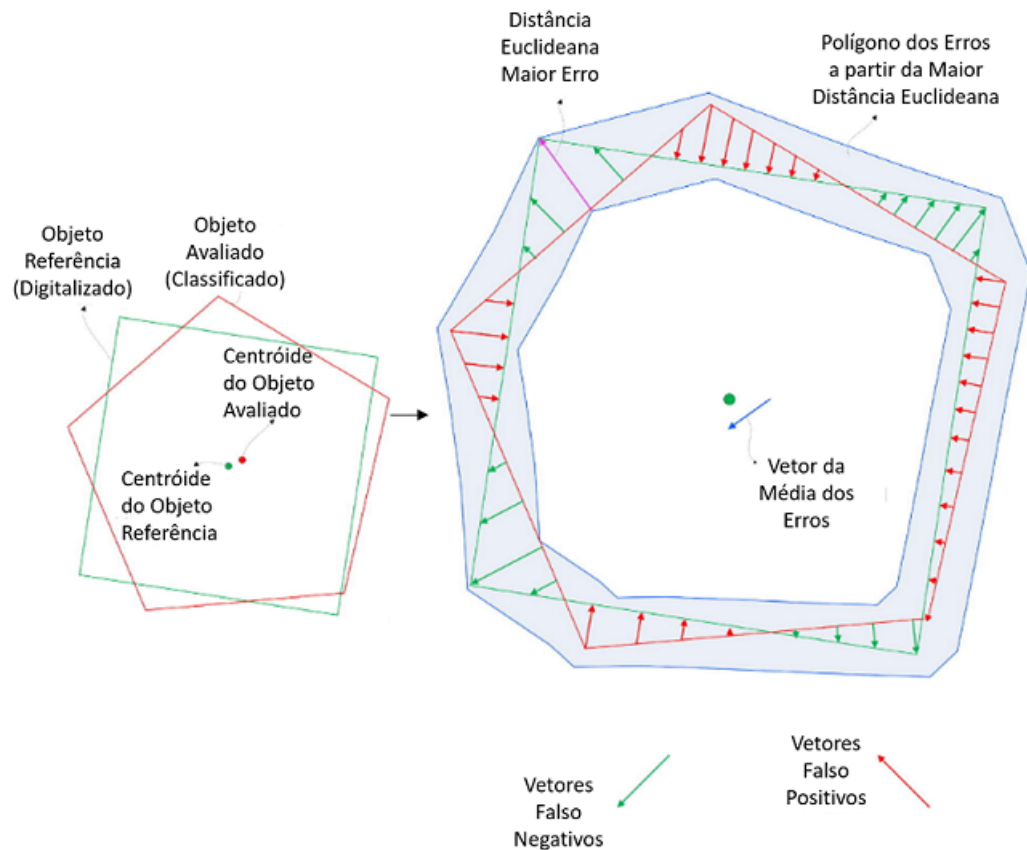


Figura 3: Avaliação de acurácia aplicada ao delineamento de copa de árvore. A figura ilustra o polígono referência manualmente delineado, polígono classificado obtido automaticamente e vetores dos erros de omissão e comissão do processo classificatório. Fonte: Yurtseven et al. (2019).

caSense, índice NDVI, aplicações integradas do software GRASS 7.2.2 (segmentação de crescimento por regiões) contra aplicações integradas do software OrfeoToolBox (OTB) 5.0.0 (segmentação watershed) e classificação utilizando o algoritmo Support Vectors Machine (SVM) contra o algoritmo Kmeans. A segmentação crescimento por regiões obteve melhores resultados que a watershed e os resultados dos classificadores SVM e Kmeans foram muito superiores, sendo então escolhidos ao plugin a segmentação crescimento por regiões e o Kmeans - este algoritmo foi escolhido frente ao SVM pelo fato de ser não-supervisionado, o que aumenta o grau de automatização do processo (BELGIU; DRĂGUȚ, 2014). Alguns erros de classificação foram relatados, como árvores que não tiveram copas devidamente separadas e presença de estradas que superestimaram o número de ausência de árvores detectadas (análise pressupôs que a área de estudo só teria vegetação, mas acabou incluindo estradas vicinais que não possuem árvores), resultando num Índice Kappa igual 0,71. Esta metodologia de Duarte, Silva e Teodoro (2018) pode ser uma alternativa para análises preliminares, apesar do longo tempo de processamento de dados na análise OBIA.

Trabalhos de *deep learning* (LECUN; BENGIO; HINTON, 2015) também têm sido publicados para o DCA. A arquitetura U-Net foi avaliada por Zhao et al. (2018), comparando os resultados com a arquitetura Mask-RCNN em plantios de romãs. Imagens foram divididas em *tiles* de 534x600 pixels (tamanho que inclui 10 árvores no plantio) para delineamento manual das copas como dados de treino e teste (somente copas inteiras destas cenas foram manualmente delineadas, pois muitas das copas nas bordas ficaram cortadas na separação em *tiles*). O U-Net obteve bons resultados apenas em copas maiores, o que não ocorreu com o Mask-RCNN, que obteve melhor acurácia em todos os quesitos, apesar de demandar mais tempo de processamento computacional.

Mesmo diante de tantos trabalhos evidenciando boa acurácia da tecnologia SfM-MVS aplicada por RPA em áreas florestais de dossel aberto (WALLACE et al., 2016; CHEN et al., 2017; YURTSEVEN et al., 2019; PULITI et al., 2015) e modelagens mais robustas se mostrando necessárias em locais com dossel fechado (WALLACE et al., 2016; CHEN et al., 2017), é oportuno estudar a contribuição desta tecnologia no contexto de monitoramento da RF. A seção 4 dedica-se ao uso de RPA-SfM na avaliação da estrutura da vegetação em RF.

### 3.3.2 RPA-SfM e a biodiversidade da vegetação

Indicadores de Biodiversidade são significativamente desafiadores de serem obtidos por sensores embarcados em RPA nos biomas brasileiros porque há grande biodiversidade nestes locais (MYERS et al., 2000; PRANCE, 1994). Tal desafio é reconhecido por autores que estudaram mapeamento automático de espécies de florestas temperadas (menor biodiversidade) com uso de tecnologias de SR (PULITI et al., 2015; NEVALAINEN et al., 2017).

Alonzo, Bookhagen e Roberts (2014) realizaram a identificação de espécies e tipo de folhas de árvores localizadas em uma área urbana. Utilizaram sensor hiperespectral para dados radiométricos e sensor LiDAR para dados volumétricos e estruturais da vegetação (o LiDAR forneceu informações acerca de estruturas de tronco e de copas das árvores). Cabe ressaltar no trabalho de Alonzo, Bookhagen e Roberts (2014) a separação de grupos de espécies comuns (80% das árvores) e de espécies não comuns (20% das árvores) no processo de classificação. Tal distinção entre espécies comuns e incomuns é interessante porque assemelha-se ao fenômeno conhecido por “J” Invertido (ASSUNÇÃO; FELFILI, 2004), que sugere capacidade de autoregeneração de florestas. Alonzo, Bookhagen e Roberts (2014) obtiveram acurácia geral igual a 83,4% e Kappa igual 82,6 para uma lista total de



29 espécies comuns e um grupo classificado como espécies incomuns. Essa alta acurácia, porém, foi obtida utilizando-se sensores LiDAR e hiperespectrais, que possuem alto custo de aquisição.

Laliberte, Browning e Rango (2012) realizaram o mapeamento de 27 espécies de vegetação consideradas dominantes com base em sensores multiespectrais. Os autores realizaram segmentação automática com dados referência obtidos mediante avaliação visual, utilizando no processo uma separação entre classes de sombra, solo exposto, vegetação e vegetação esparsa e amostragem por espécie nas áreas classificadas como vegetação. Dentre os vários testes de modelos de classificação, os valores de Kappa variaram entre 0,4 e 0,9.

Gini et al. (2012) mencionaram a geração de algumas variáveis a serem utilizadas no processo de classificação para identificação de espécies: NDVI, RATIO (NIR/R), NIR/(R+G+B+NIR), G/(R+G+B+NIR), IHS (Intensidade, Matiz e Saturação) (SCHOWENGERDT, 2007; NOVO, 2008; LILLESAND; KIEFER; CHIPMAN, 2015) usando apenas H e S na classificação, bem como o algoritmo de classificação não-supervisionada ISO-CLASS (SCHOWENGERDT, 2007). Constataram que o uso de variáveis geométricas, como altura do dossel, diâmetro da copa, declividade da copa, etc. só aprimoram o processo de classificação se as espécies avaliadas possuírem valores típicos. Assim, os autores sugeriram que cada espécie alvo seja devidamente verificada para que seus dados possam ser inseridos no treinamento dos algoritmos.

Em outro trabalho, Gini et al. (2014) reforçaram a necessidade de degradar a resolução espacial de RPA-SfM no processo de classificação e de identificação de espécies, pois GSD (*Ground Sampling Distance*) de altíssima resolução pode reduzir a performance de classificação em imagens devido ao excesso de detalhamentos. Esses autores mencionaram também a possibilidade de se estudar o uso do MDS no processo de classificação, uma vez que a diferença de altitude entre os estratos arbóreo e campestre é uma informação complementar importante. A possibilidade de uso do MDS em trabalhos futuros comentado por Gini et al. (2014) para discriminar áreas arbóreas mostrou-se oportuna na ocasião da publicação do trabalho destes autores, pois este aprimoramento do processo classificatório foi confirmado posteriormente por Torres-Sánchez et al. (2018).

Ratificando a conclusão de Gini et al. (2014), Reif e Theel (2017) alegaram que produtos de alta resolução não necessariamente facilitam a identificação de espécies por SR, pois junto ao maior detalhamento da superfície há ruídos nas imagens, que confundem os classificadores. Os autores comentaram ser os RPA-SfM ainda uma tecnologia inci-

piente, mas que já fornece a possibilidade de coletar dados de altíssima resolução e em maior quantidade, ou seja, RPA-SfM fornecem grande quantidade de dados referência em atividades de campo. Os autores listaram também iniciativas em curso que estudam a capacidade de RPA-SfM obter métricas de RF, como cobertura do solo, biomassa e biodiversidade utilizando dados do espectro visível, infravermelho e nuvens de pontos, concluindo o texto alegando que é necessário saber o que e qual precisão se deseja obter para então escolher os materiais e métodos mais adequados ao projeto.

Tay, Erfmeier e Kalwij (2018) avaliaram o uso de RPA-SfM para tentar promover maior agilidade no mapeamento de espécie exótica indesejada em paisagens naturais da Alemanha, pois tal espécie é uma adversidade tanto para a agropecuária quanto para áreas de preservação ambiental. Para utilizar o algoritmo de classificação supervisionada Máxima Verosimilhança (MAXVER) - mais informações do MAXVER em Jensen (2015), foram definidas as seguintes classes, sendo todas as classes, bem como as amostras de cada classe, validadas em campo: espécie exótica (mapeada em estágio de floração para facilitar sua distinção na paisagem), vegetação e solo exposto. O índice kappa resultante da classificação foi superior a 0,65 em todas as áreas de estudo. A regressão linear e ANOVA (IVERSEN; NORPOTH; NORPOTH, 1987) apresentaram alta correlação entre os dados obtidos por RPA-SfM e por trabalhos de campo. As partes onde houve inacurácia foram justificadas pelos autores pela variação na quantidade de luz (passagem de nuvens durante voos) e rajadas de vento, que afetaram a qualidade do ortomosaico. Comenta-se que este trabalho de Tay, Erfmeier e Kalwij (2018) utilizou apenas dados RGB embarcados em RPA, pois as bandas do espectro visível apresentaram melhor resultado que os sensores utilizando a banda NIR. As explicações para este fato foram baixa sobreposição lateral e longitudinal (70% e 30%, respectivamente) e falta de calibração em valores de reflectância destes sensores multispectrais. Finalmente, os autores concluíram que o uso de RPA-SfM ainda não sobrepõe métodos tradicionais porque não obteve acurácia suficientemente alta e porque tomou mais tempo que os trabalhos de campo. Porém, os autores comentaram a utilidade dos RPA-SfM registrarem uma área maior que a possível pelo tradicional método de parcelas de campo e ressaltaram que um aprimoramento na metodologia utilizando RPA-SfM certamente concretizará o uso desta tecnologia em análises de vegetação.

Um fator muito importante para a plenitude das florestas é a presença de animais (HANDEL, 1997; HOWE, 1984; FERRETTI, 2002; GADELHA; FERRAZ; AGUIAR, 2009). Diante de um cenário carente de metodologias efetivas de monitoramento de mamíferos, Witczuk et al. (2018) utilizou sensores termais a bordo de RPA para detectar esses animais em ambiente florestais. Mamíferos muitas vezes se camuflam em imagens

RGB obtidas através de sobrevoos de RPA, tornando oportuno estudo de sensores termais para detecção destes animais. Através de vídeos gerados com o sensor termal e transformando em ortomosaico os trechos do vídeo onde há presença de animais, os autores reforçaram a necessidade de cautela na análise de trechos próximos para evitar dupla contagem de mesmos indivíduos. Concluíram então que sensores termais se mostraram propícios à detecção de mamíferos, sendo o nascer do sol, o pôr do sol e a noite os melhores horários para esse mapeamento. A ausência de luz evita aquecimento de árvores e ausência de sombra melhora a nitidez, evitando assim confusão na identificação de mamíferos. Estudos futuros para aumentar a resolução dos produtos termais e aplicação de técnicas automáticas nesta tarefa poderão aprimorar a identificação das espécies animais em grandes áreas.

Também sobre a identificação de animais, Elliott (2016) comenta que o uso de câmeras *trap* e sensores termais podem auxiliar a identificação de animais abaixo do dossel, enquanto que microfones podem auxiliar a detecção de aves e morcegos. Tais microfones também podem servir para a detecção do trajeto percorrido por aves e morcegos via triangulação com base nas posições dos microfones que captam o som destes animais voadores.

Apesar destas iniciativas de detecção de animais, a maior parte de estudos de RPA tem como alvo a vegetação. Ao olhar para a vegetação, uma integração entre sensores LiDAR e hiperespectral poderia contribuir, segundo Elliott (2016), com a identificação de árvores que estão produzindo sementes em remanescentes florestais próximos a RF. Frente ao desafio de mapear espécies de árvores, o autor cita outras tecnologias que poderiam servir de apoio ao monitoramento automático de RF, como a identificação de espécies em campo via aplicativos como o Pl@ntNet ([m.plantnet-project.org/](http://m.plantnet-project.org/)) e Leafsnap ([leafsnap.com/](http://leafsnap.com/)).

Miyoshi (2016) buscou identificar espécies vegetais através de sensor hiperespectral embarcado em RPA. A autora delineou manualmente as copas de doze espécies clímax ou secundárias alvo no estudo e realizou a caracterização espectral de cada espécie utilizando espectroradiômetro e índices de vegetação, que aprimoraram os resultados. Em outro trabalho desta autora (MIYOSHI et al., 2018), avaliou-se a obtenção de ortomosaicos de regiões florestais e de cana-de-açúcar a partir de sensor hiperespectral a bordo de RPA, comparando os resultados de diferentes parâmetros no ajuste radiométrico de blocos (para obtenção do ortomosaico) com medições de espectroradiômetro em campo. Neste último trabalho, os melhores resultados foram os que consideraram apenas dados obtidos pelas imagens, sem considerar as medidas obtidas por espectroradiômetros posicionados em

locais fixos. Os autores comentaram que trechos cobertos por nuvem tiveram menor qualidade dos dados porque o modelo de calibração ainda não possui adaptação para a iluminação da localização da área de estudo (Estação Ecológica Mico-Leão-Preto, SP, Brasil). Como variações de luminosidade são comuns no local, esforços futuros buscarão aprimorar o modelo de calibração do sensor hiperespectral para maior capacidade de generalização do método na região.

Considerando a importância da banda NIR no estudo da vegetação (NOVO, 2008), Knoth et al. (2013) avaliou a performance de sensores NIR e RGNIR modificados a bordo de RPA, sendo a modificação destes sensores realizada manuseando-se filtros de forma similar ao exemplificado por Hunt et al. (2010). Além dos sensores mencionados, foram utilizados para avaliação de RF de regiões pantaneiras na Alemanha pontos de controle GNSS, segmentação e classificação de imagens. Na identificação de quatro classes de cobertura, sendo uma classe para alagamento e três classes para três espécies vegetais, os resultados em geral obtiveram boa acurácia e o índice Kappa foi igual a 0,87. Logo, os autores comentaram que a metodologia mostrou-se promissora ao propiciar maior agilidade e menor custo no monitoramento da RF utilizando RPA. Contudo, Knoth et al. (2013) alertaram que outras duas espécies recorrentes e indesejadas em RF de regiões pantaneiras na Alemanha não estavam presentes na área de estudo, o que poderia dificultar o método de classificação utilizado e possivelmente demandaria o uso de padrões de contornos dos segmentos gerados.

Nevalainen et al. (2017) utilizaram DIA não só para calcular a densidade de indivíduos, mas também para identificar espécies em áreas florestais na Finlândia. No caso, os autores utilizaram dados altimétricos por SfM-MVS obtidos de sensor RGB, dados espectrais obtidos por sensor hiperespectral, dados referência obtidos por inventário florestal em pontos quadrantes (OLIVEIRA et al., 2015), pontos de controle obtidos por levantamento GNSS, base nacional de LiDAR disponível na Finlândia para referência de solo na obtenção do CHM e metodologia de processamento de imagens hiperespectrais específico para DIA. No caso, os autores utilizaram o algoritmo Máxima Local para DIA e, realizando buffer de um metro ao redor das coordenadas obtidas para cada árvore para o delineamento das copas, aplicaram algoritmos para identificar automaticamente 4 espécies vegetais. A acurácia geral variou entre 40% e 95% para a DIA e para identificar as 4 espécies arbóreas nas onze áreas de estudo obteve melhor resultado equivalente a 95% na aplicação do Random Forest e Multi Layer Perceptron (MITRA; PAL, 1995). Os autores comentaram que: bibliotecas espectrais poderiam acelerar a identificação de espécies; atributos espectrais tiveram maior contribuição na identificação de espécies, mas atribu-

tos estruturais foram importantes devido à aplicação do algoritmo Máxima Local para realizar a DIA; o algoritmo Máxima Local foi acurado em copas estreitas de florestas boreais, o que provavelmente não ocorreria com copas mais irregulares de outras localidades, tornando oportuno o uso de atributos espectrais nestes casos; na metodologia dos autores, as copas foram delineadas aplicando-se um buffer nas coordenadas de cada árvore, logo, futuramente tentarão delinear as copas automaticamente; e trabalhos futuros aplicarão a metodologia do trabalho em florestas de maior biodiversidade, o que, nas palavras dos próprios autores, aumentará o desafio.

O trabalho de Dalponte, Frizzera e Gianelle (2019), após realizar o DCA automaticamente conforme visto na seção 3.2, realizou a classificação de espécies considerando atributos espectrais do sensor hiperespectral e a nuvem de pontos obtida por LiDAR. O dado referência foi obtido por fotointerpretação e os resultados foram acurácia geral de 88,1% e Índice Kappa de 0,757, valores esses considerados como acurácia elevada. Os autores constataram que os maiores erros desta classificação foram em espécies com menor quantidade de amostras, que eram as espécies não dominantes. Novamente ressalta-se o alto custo destes sensores, sendo oportuno avaliar equipamentos de menor custo.

O trabalho de Lisein et al. (2015) utiliza o termo silvicultura de precisão. Os autores realizaram voos de RPA-SfM em diferentes períodos do ano no intuito de avaliar eventuais influências das estações na acurácia da identificação de espécies decíduas na Bélgica. Buscaram também checar se diferentes condições climáticas e fenológicas contribuem para maior separabilidade das espécies via SR, bem como a contribuição dos sensores RGB e NIR modificado (modificação semelhante ao exemplificado por Hunt et al. (2010)) na tarefa de classificar espécies. Um exemplo mostrado pelos autores das diferenças nas imagens de RPA conforme época do ano na área de estudo (Bélgica) é mostrado na Figura 4. Quando avaliadas separadamente, os autores constataram que o sensor RGB obteve maior acurácia que o NIR modificado e quando unificados a acurácia aprimorou somente em 4%. A acurácia dos resultados obteve erros *out of bag* (OOB) (BREIMAN, 1996) entre 15,9% e 36,0%. O período de voo com melhor acurácia em geral foi no final do processo de descarga das folhas, sendo que para árvores largas o melhor período de voo foi entre a primavera e começo do verão. Em geral, os autores recomendaram evitar o auge do verão. Ressaltaram também alguns fatores de variação espectral intra-espécie os quais alteraram a pigmentação das folhas e contribuíram para erros na classificação: patologias florestais, diferença de idade e frutificação. Como a área de estudo foi a Bélgica, o número de espécies a serem identificadas foi equivalente a cinco, sendo que florestas tropicais como as brasileiras possuem biodiversidade significativamente maior.



Figura 4: Diferenças radiométricas nas imagens individuais aéreas RGB de vegetação na Bélgica conforme estação do ano. Fonte: Adaptado de Lisein et al. (2015).

Também com área de estudo na Bélgica e no intuito de aprimorar a gestão ambiental, Michez et al. (2016) utilizaram RPA com sensor GBNIR para avaliar em análises temporais a saúde da vegetação e a composição das espécies em zonas ripárias. Buscaram também encontrar as melhores janelas de tempo ao longo de um ano para avaliar quando é possível obter resultados mais acurados. Os autores utilizaram base LiDAR já existente para geração do CHM, identificação de cada árvore em campo junto à coleta de coordenada geográfica DGPS, delineamento manual das copas, segmentação utilizando software *eCognition*, classificação *Random Forest*, definição de cinco classes (4 classes para 4 espécies e 1 classe para várias espécies não comuns) e stepwise para escolha de atributos mais significativos ao processo de classificação. Os autores identificaram como melhor período para voo o final da estação de atividade foliar e começo da queda das folhas, semelhante ao verificado por Lisein et al. (2015). As variáveis do sensor RGB contribuíram mais para o processo classificatório em uma das áreas de estudo e as variáveis do sensor RGNIR contribuíram mais para a outra área (neste caso da RGNIR, havia maior ocorrência de espécies decíduas, o que ampliou o contraste captado pela banda NIR), mas ambas tiveram seus resultados aprimorados quando foram utilizadas as variáveis estruturais do CHM na classificação. Outra constatação dos autores foi que uma das espécies obteve maior acurácia quando o indivíduo estava saudável, ou seja, sem a ocorrência de patologia florestal. A questão das patologias florestais reduzindo acurácia da classificação também foi constatada por Lisein et al. (2015). Para as duas áreas estudadas, os autores obtiveram acurácia geral de 79.5 % e 84.1% e comentaram significativa variabilidade espectral no âmbito intra-espécie. Os autores comentaram também que o DCA é um âmbito de pesquisa à parte e por isso simplificaram esta questão no trabalho, mas ressaltaram a importância deste passo na automatização da identificação de espécies. Apesar de simplificarem o DCA em seu trabalho, verificaram que objetos mais largos são mais sujeitos à heterogeneidade dos atributos, o que reduziu a acurácia dos resultados. Comenta-se que

este trabalho de Michez et al. (2016) envolveu quantidade de espécies significativamente menor do que a quantidade presente em florestas tropicais brasileiras.

Já o trabalho de Baena et al. (2017) foi realizado em floresta tropical seca peruana, que sofre pressões antrópicas e demandou estudos para inovar a gestão ambiental. Os autores mencionaram que sensores hiperespectrais e LiDAR possuem elevado custo de aquisição, o que inviabilizaria aplicação em maior escala destas tecnologias nas políticas ambientais de países em desenvolvimento. Neste caso, para identificar as três espécies arbóreas dominantes na região, podendo ser considerada como uma quarta classe indivíduos de uma espécie infectados com patologias florestais, os autores utilizaram como dado referência parcelas de campo de inventários florestais, onde foram anotados também o estado de saúde de cada árvore da espécie sob ataque de patógenos, área de cada copa e delineamento manual das copas das árvores seguida de anotação da respectiva espécie. A metodologia de classificação OBIA com software *eCognition* envolveu sensor GBNIR (obtido manuseando-se filtros como em Hunt et al. (2010)) e etapas de DCA e de identificação de espécies. O DCA e a identificação de espécies obtiveram acurácia geral de 95,3% e 94,1%, respectivamente. Os autores comentaram que o DCA apresentou erros em casos de patologia florestal e que a identificação de espécies apresentou erros influenciados por inaccurácias no DCA (principalmente erros nas bordas que incluíam, por exemplo, solo exposto) e por patologia florestal. Apesar da boa acurácia, os autores comentaram que: a aplicação de sensores modificados deve ser feita com cuidado por tornar o mosaico sujeito a inconsistências radiométricas oriundas da mistura de bandas espectrais; o CHM apresenta imprecisões em árvores desfolhadas mas é uma base robusta para árvores folhadas; o uso de dados de contexto (relação do objeto com a vizinhança) contribuiu para refinar a acurácia; e o fato das áreas de estudo possuírem poucas espécies arbóreas bem espaçadas entre si (sem dossel fechado) de certa forma contribuiu para boa acurácia.

O trabalho de Hamamura et al. (2019) realizou identificação de espécies arbóreas em área urbana através de imagens RGB obtidas por RPA. Os dados referência foram obtidos por identificação das espécies em campo e delineamento manual das copas com associação à espécie correspondente. Foram consideradas apenas espécies com pelo menos cinco indivíduos. Sem dados verticais, ou seja, utilizando apenas dados espectrais, os autores utilizaram dados RGB, dados HSV obtidos do sensor RGB e análise das componentes principais para a imagem como um todo. Os autores então selecionaram como variáveis mais relevantes à identificação de espécies aquelas com correlação entre -0,8 e 0,8 para reduzir a redundância e aquelas com maior índice de importância segundo árvores de decisão do algoritmo Random Forest. A acurácia geral foi igual a 61,87% e o índice Kappa igual

a 0,5887. Os autores comentaram que a baixa acurácia na maioria das espécies ocorreu devido à baixa quantidade de amostras decorrente da baixa quantidade de exemplares das espécies na área urbana estudada e à variabilidade intra-espécie, possivelmente acentuada pela estiagem à época do voo que eventualmente gerou estresse hídrico em diferentes escalas nos indivíduos de uma mesma espécie. Outro comentário feito pelos autores foi que a ausência da nuvem de pontos pode ter prejudicado a acurácia dos resultados.

Uma ferramenta que revolucionou a identificação automática de feições em imagens é o *deep learning* (LECUN; BENGIO; HINTON, 2015), tanto que no âmbito dos RPA-SfM foram obtidos altos valores de acurácia na detecção de algumas espécies ao se aplicar esta técnica de processamento de imagens (NEZAMI et al., 2020; FERREIRA et al., 2020). A alta resolução dos dados gerados por RPA tornou o *deep learning* uma tecnologia de grande potencial para a extração automática de feições mapeadas por este tipo de imageamento aéreo (BERGADO; PERSELLO; GEVAERT, 2016). No contexto das florestas tropicais brasileiras, espécies com características visualmente distintas em imagens de RPA já foram automaticamente mapeadas através do *deep learning*, como palmeiras (FERREIRA et al., 2020) e outras seis espécies recorrentes em áreas de RF na Amazônia (MOURA et al., 2021).

Apesar do *deep learning* ter apresentado grande potencial para identificação de espécies vegetais via RPA-SfM em florestas tropicais (FERREIRA et al., 2020; MOURA et al., 2021), a questão da avaliação da biodiversidade por meio desta tecnologia ainda será objeto de muitos estudos futuros porque há muitas espécies que ainda precisam ser estudadas. Afinal, se a temática da taxonomia é historicamente um desafio para os botânicos (GODFRAY, 2002; ROUHAN; GAUDEUL, 2014; JAMES et al., 2018), naturalmente o desafio também seguirá para os pesquisadores de SR e RPA.

A seguir são apontadas informações acerca de RPA-SfM que devem ser levadas em conta em projetos que utilizam esta tecnologia para o monitoramento da RF.

### 3.3.3 Tipos de RPA

RPAs podem ser asa-fixa ou asa-rotativa. A Figura 5 abaixo ilustra exemplos desses tipos de RPA.

Conforme mencionado por Jaimes, Kota e Gomez (2008), asa-fixa tem a vantagem de cobrir maior área por voo, mas demanda maiores restrições para decolagem e pouso ao requerer área mínima sem obstáculos e de baixa declividade. Já os RPA asa-rotativa pos-






Figura 5: Exemplo de RPA asa-rotativa (a) e asa-fixa (b). Fotografia obtida de acervo gratuito (a) e cedida pelo LAPIG / UFG (b).

suem a relação inversa de vantagem e desvantagem. Pequenas clareiras já são suficientes para decolagem e pouso de asa-rotativa, mas em compensação cobrem menor área por voo. Como áreas de RF em geral não são extensas e com certa frequência não possuem áreas adequadas para decolagem e pouso de asa-fixa, RPA asa-rotativa costumam ser mais adequados a áreas de RF (ALBUQUERQUE et al., 2017).

### 3.3.4 Padrões de Voo

O sobrevoo de áreas utilizando RPA requer cuidados legais (ANAC, 2017a) e técnicos (HE; LI; ZHANG, 2012; DANDOIS; OLANO; ELLIS, 2015; TORRES-SÁNCHEZ et al., 2018).

Os cuidados legais variam principalmente conforme a classe do RPA, que depende basicamente do peso da aeronave. Assim, RPA de classe 1, classe 2 e classe 3 devem ter peso máximo de decolagem maior que 150 kg, entre 25 kg e 150 kg e até 25 kg (ANAC, 2017a). A Figura 6 ilustra um Quadro-Resumo das particularidades legais de cada classe.

Notar que a Figura 6 apresenta a classe aeromodelos, descrita pela própria fonte da figura como "Aeronave não tripulada usada para recreação"(ANAC, 2017b). Comenta-se, portanto, que aeromodelos não serão utilizados neste trabalho.

Sobre as classes de RPA, esta tese engloba RPA apenas da classe 3, pois possui menores restrições de uso, maior facilidade de manuseio (o que facilita a difusão do conhecimento) e menor custo de aquisição. As vantagens das RPA das demais classes seriam a capacidade de sobrevoar áreas maiores, mas como a maioria das propriedades rurais possui menos de

<b>Resumo da Regulamentação da ANAC</b>				
	<b>RPA Classe 1</b>	<b>RPA Classe 2</b>	<b>RPA Classe 3</b>	<b>Aeromodelos</b>
Registro da aeronave?	Sim	Sim	BVLOS: Sim VLOS: Sim <sup>1</sup>	Sim <sup>1</sup>
Aprovação ou autorização do projeto?	Sim	Sim <sup>2</sup>	Apenas BVLOS ou acima de 400 pés <sup>2</sup>	Não
Limite de idade para operação?	Sim	Sim	Sim	Não
Certificado médico?	Sim	Sim	Não	Não
Licença e habilitação?	Sim	Sim	Apenas para operações acima de 400 pés	Apenas para operações acima de 400 pés
Local de operação	A distância da aeronave não tripulada <b>NÃO</b> poderá ser inferior a 30 metros horizontais de pessoas não envolvidas e não anuentes com a operação. O limite de 30 metros não precisa ser observado caso haja uma barreira mecânica suficientemente forte para isolar e proteger as pessoas não envolvidas e não anuentes. Esse limite não é aplicável para operações por órgão de segurança pública, de polícia, de fiscalização tributária e aduaneira, de combate a vetores de transmissão de doenças, de defesa civil e/ou do corpo de bombeiros, ou operador a serviço de um destes.			

Figura 6: Quadro-Resumo da Regulamentação da ANAC, que considera diferentes normativas conforme classe da RPA. BVLOS é *Beyond the Visual Line of Sight* e VLOS é *Visual Line of Sight*. Fonte: ANAC (2017b).

cem hectares (DIEESE, 2011; VIEIRA-FILHO; GASQUES, 2020), o uso apenas da classe 3 é oportuno.

A legislação permite voos de RPA classe 3 em altura de até 120 metros sem habilitação específica, sendo necessário apenas ser maior de 18 anos (ANAC, 2017a). Sensores RGB comuns são capazes de gerar ortomosaicos com *Ground Sampling Distance* (GSD) inferior a cinco centímetros, o que é um produto de altíssima resolução espacial.

O GSD é uma variável muito relevante em trabalhos de RPA e, basicamente, depende de duas importantes componentes: resolução do sensor (distância focal e tamanho do pixel) e altura do voo (HE; LI; ZHANG, 2012). Cada sensor possui suas especificações, que na prática são escolhidas no ato da aquisição do equipamento. Uma vez adquirido o sensor, a resolução do mesmo já é escolhida e a variável a ser trabalhada na definição do GSD é a altura do voo. A Figura 7 abaixo ilustra a relação de altura do voo e GSD, que

nada mais é do que uma semelhança de triângulos.

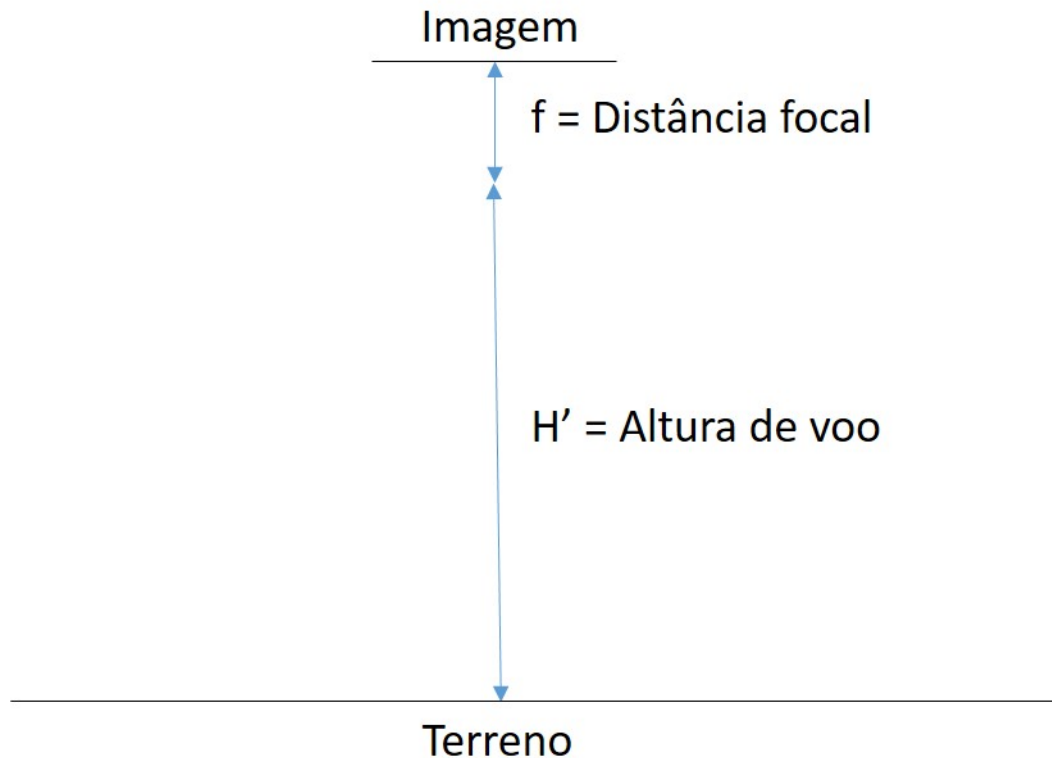


Figura 7: Altura ( $H'$ ) como variável a ser trabalhada na definição do GSD, uma vez que a resolução  $f$  (Distância focal) do sensor não varia após a escolha do equipamento.

A Equação 3.1 mostra a relação entre altura de voo ( $H'$ ), distância focal ( $f$ ) e Tamanho do pixel ( $Tp$ ) ilustrada na Figura 7 para definição do GSD. Na prática, aumentando-se a altura de voo, aumenta-se o GSD (HE; LI; ZHANG, 2012). Dandois, Olano e Ellis (2015) verificaram que voos a 80 metros apresentaram melhores resultados que alturas abaixo deste valor. Já Torres-Sánchez et al. (2018) voaram RPA a alturas menores que 100 metros, verificando que esta altura de cem metros gerou os melhores resultados.

$$GSD = Tp * \frac{H'}{f} \quad (3.1)$$

A altura de cem metros para o voo costuma ser suficiente para garantir segurança do drone em relação a objetos da superfície, obtenção de permissão de uso do espaço aéreo brasileiro (ANAC, 2017a) e obtenção de GSD inferior a três centímetros para sensores RGB embarcados em RPA. Logo, para RPA-SfM de baixo custo recomenda-se voos a uma altura inferior a 100 metros.

Outra questão importante em relação aos voos com RPA reside na sobreposição de imagens para ocorrência do fenômeno estereoscopia (SHABAYEK et al., 2012; SANTOS et

al., 2017), que no âmbito das geotecnologias possibilita o fornecimento de produtos como ortomosaicos e DSM (EISENBEISS, 2009). Ao se planejar um voo, é necessário informar a sobreposição longitudinal e a sobreposição lateral (Figura 8), sendo que quanto maior a sobreposição, maior a qualidade dos dados, porém, maior o tempo de processamento computacional (HAALA; CRAMER; ROTHERMEL, 2013; DANDOIS; OLANO; ELLIS, 2015; WALLACE et al., 2016; TORRES-SÁNCHEZ et al., 2018).

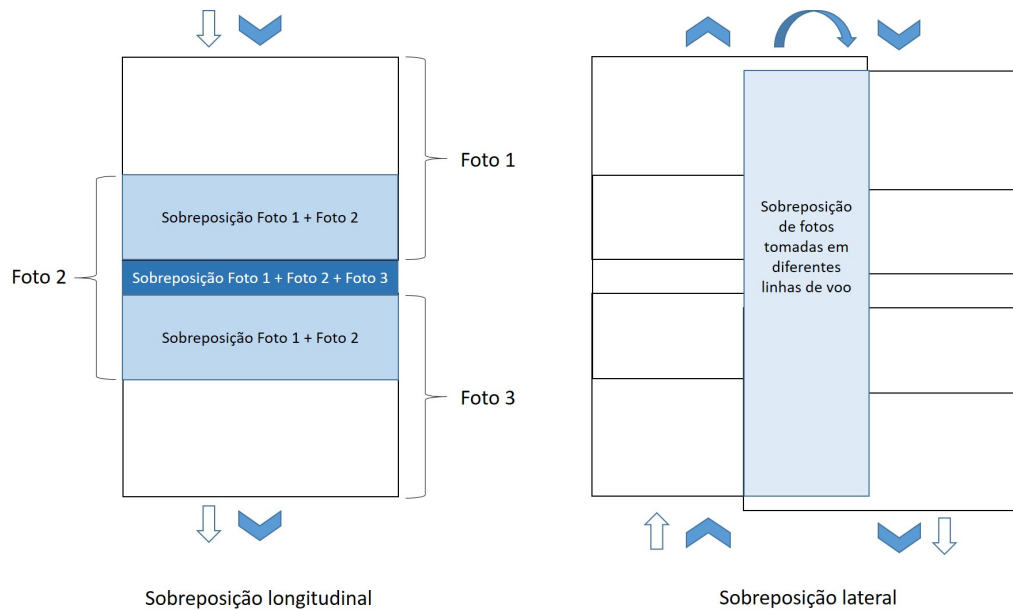


Figura 8: Sobreposição longitudinal e lateral de imagens de RPA.

Dandois, Olano e Ellis (2015) concluíram que estudos de vegetação demandam alta sobreposição de imagens, no caso, maior que 80% longitudinal e lateral. Já Torres-Sánchez et al. (2018) verificaram que sobreposição lateral de 95% longitudinal geraram melhores resultados no delineamento automático de copa de árvores em plantio de oliveiras, sendo que o tempo de processamento de dados para 97% de sobreposição longitudinal foi 85% maior que em sobreposição longitudinal de 60%. A Agricultura de Precisão demanda alta resolução temporal na obtenção de dados sobre o plantio (ZHANG; WANG; WANG, 2002), resolução temporal esta não tão urgente em projetos de RF, tornando oportuno o uso de altas taxas de sobreposição de imagens neste trabalho para um maior detalhamento das copas das árvores (WALLACE et al., 2016). Ainda, seguindo uma recomendação do software Map Pilot<sup>1</sup>, sugere-se a sobreposição longitudinal dos voos de 90% e a sobreposição lateral de 80% quando se deseja mapear árvores.

Um fator importante a ser observado na realização de voos RPA é o vento. Neste assunto, Dandois, Olano e Ellis (2015) verificaram que ventos fortes aumentam o consumo

<sup>1</sup><[https://www.mapsmadeeasy.com/data\\_collection](https://www.mapsmadeeasy.com/data_collection)>

de bateria do RPA, pois demanda-se mais potência no motor para fazer seu deslocamento e conseqüentemente diminui o tempo de voo. Além disto, RPA de asa-fixa tendem a ser mais prejudicados por vento do que RPA de asa-rotativa (DANDOIS; OLANO; ELLIS, 2015), além de possuírem melhor capacidade de voo em condições de vento intenso (ALBUQUERQUE et al., 2017), reforçando o uso de asa-rotativa neste trabalho.

Nesta pesquisa estão sendo propostas alternativas que promovam mais eficiência na coleta de informações acerca de áreas em processos de RF. O mecanismo proposto, descrito nas seções 4 e 5, busca promover aos processos de RF maior transparência na governança pública ou privada, redução de custos e aprimoramento na qualidade dos dados usados para o monitoramento.

## 4 AVALIAÇÃO DOS ASPECTOS ESTRUTURAIS DA RESTAURAÇÃO FLORESTAL VIA RPA-SfM

### 4.1 Síntese dos artigos publicados no âmbito desta tese sobre avaliação dos aspectos estruturais da Restauração Florestal via RPA-SfM

No âmbito desta tese foram publicados os trabalhos Albuquerque et al. (2020) e Albuquerque et al. (2021), que correspondem ao capítulo que trata do uso de RPA-SfM para obter indicadores voltados à estrutura da vegetação. Esses trabalhos encontram-se anexos à esta tese nas seções A e B.

No artigo intitulado "*Remotely piloted aircraft imagery for automatic tree counting in forest restoration areas: a case study in the Amazon*" (ALBUQUERQUE et al., 2020), foram avaliados RPA asa-rotativa e RPA asa-fixa para a Detecção Individual de Árvores (DIA), que realiza a contagem de árvores e leva ao indicador densidade de árvores (Figura 9). O método utilizou o algoritmo Máxima Local, sugerindo-se que o mesmo seja utilizado sobre o DSM ao invés do uso (mais comum) sobre o CHM. Tal sugestão foi motivada pelo fato do processo de geração do DTM ocasionar perda de alguns detalhes da superfície, afetando consequentemente o CHM. A aplicação do algoritmo Máxima Local gerou, portanto, resultados mais acurados ao ser aplicado sobre o DSM do que sobre o CHM. Cabe destacar que, ao utilizar o algoritmo Máxima Local, a menor sobreposição de fotos durante o voo do RPA influenciou a qualidade dos resultados em geral (tanto na base DSM quanto na base CHM). Tal relação entre queda de acurácia do algoritmo Máxima Local com menor sobreposição de fotos era de certa forma esperada, pois maior sobreposição de fotos gera maior riqueza de detalhes na nuvem de pontos. Verificou-se também que o uso do índice *Modified Photochemical Reflectance Index* (MPRI) pode auxiliar na eliminação de erros de comissão quando há diferença de resposta espectral entre árvores e gramíneas, apesar de que muitas vezes essa diferença espectral não ocorre utilizando-se sensor RGB.

Outro destaque é a comparação entre o tempo de processamento de dados demandado pelo uso do algoritmo Máxima Local e pelo *Deep Learning*: Máxima Local é consideravelmente mais rápido. Logo, o método DIA utilizado em Albuquerque et al. (2020), por ter alcançado valores razoáveis de acurácia, é mais pragmático que o *deep learning* e, portanto, mais viável de ser utilizado de forma mais generalizada pela sociedade. Afinal, trabalhos envolvendo *deep learning* requerem mão-de-obra especializada e um procedimento demorado, que podem não compensar os custos se comparados às despesas necessárias ao trabalho convencional de campo, que gera maior riqueza de detalhes.

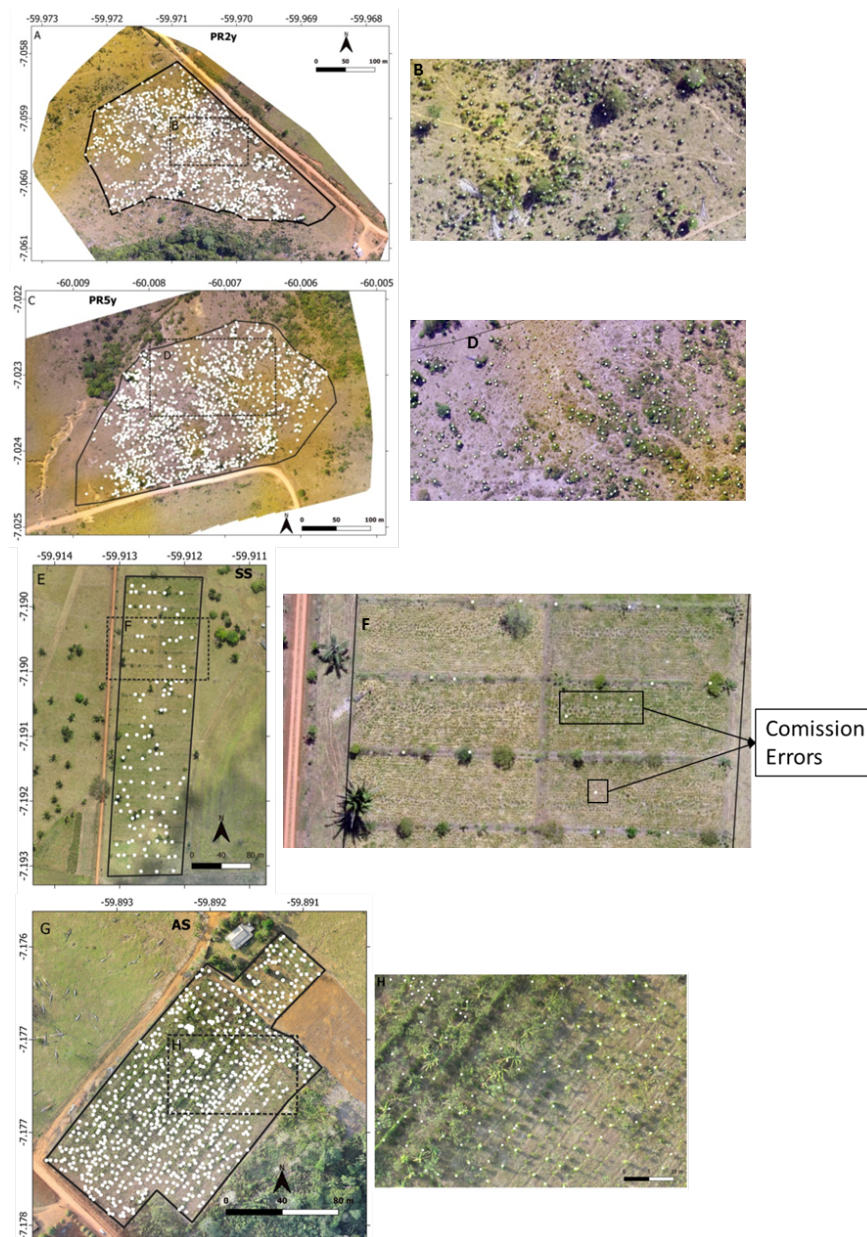


Figura 9: Figura síntese do artigo "*Remotely piloted aircraft imagery for automatic tree counting in forest restoration areas: a case study in the Amazon*", publicado no âmbito desta tese para avaliar a detecção automática de árvores em imagens obtidas via RPA-SfM. Fonte: Albuquerque et al. (2020).

O método descrito em Albuquerque et al. (2020) para realizar DIA foi utilizado no artigo intitulado "*Forest Restoration Monitoring Protocol with a Low-Cost Remotely Piloted Aircraft: Lessons Learned from a Case Study in the Brazilian Atlantic Forest*" (ALBUQUERQUE et al., 2021). Uma vez realizado o DIA para obtenção da densidade de árvores, extraiu-se para cada uma das árvores o valor correspondente do CHM, sendo a média destes valores o resultado do indicador altura do dossel na área de estudo. Os outros indicadores avaliados em Albuquerque et al. (2021) foram cobertura de dossel e cobertura de gramíneas. A cobertura de dossel considerou valores obtidos a partir da nuvem de pontos (CHM e desvio padrão do DSM) e do ortomosaico (índice *Triangular Greenness Index* (TGI) e detecção de sombra). Apenas o CHM poderia obter a cobertura de dossel, mas os demais recursos foram utilizados para incluir árvores pequenas em trechos declivosos. Já a cobertura de gramíneas foi obtida pelo resultado da subtração da classe vegetação - mapeada pelo algoritmo *Random Forest* (essa classe incluiu árvores e gramíneas) - pela cobertura de dossel (possui somente árvores). Os resultados foram todos acurados (Figura 10), sendo que RPA-SfM mostraram-se mais adequados para medir cobertura de dossel do que métodos tradicionais de campo devido à alta resolução das imagens obtidas por RPA-SfM para toda a área de interesse. Outro indicador importante que se mostrou mais adequado para medir via RPA-SfM é a altura do dossel. Porém, para que a altura de dossel seja medida de forma acurada em situações de dossel fechado, é necessário realizar ao menos um voo com pontos de controle (coordenadas GNSS precisas) antes do início da RF: isso disponibiliza um DTM preciso para voos realizados (também com coordenadas GNSS precisas) após o fechamento do dossel.

No voo realizado para a obtenção de um MDT preciso, a possibilidade de utilização de marcos topográficos nos arredores da RF pode otimizar o esforço da coleta de pontos de controle nos levantamentos futuros. A coleta das coordenadas GNSS precisas nos marcos topográficos permite que, nos voos futuros de RPA-SfM, os marcos sejam sinalizados com alvos ou pintados com cal em formato de cruz ou "x". Tal sinalização permite a visualização dos marcos topográficos nas imagens obtidas por RPA-SfM. Uma vez que as coordenadas GNSS precisas dos marcos topográficos já foram coletadas em momento anterior, a obtenção de pontos de controle nas novas imagens torna-se mais ágil.

Vale destacar também que a medição acurada dos aspectos estruturais da vegetação via RPA-SfM permitiu a detecção de trechos com diferentes graus de sucesso ao longo da RF. A identificação de trechos com diferentes graus de sucesso reforça a vantagem de RPA-SfM registrar áreas não amostradas por parcelas de campo. Logo, RPA-SfM mostram-se inovadores na medição da cobertura e da altura do dossel.



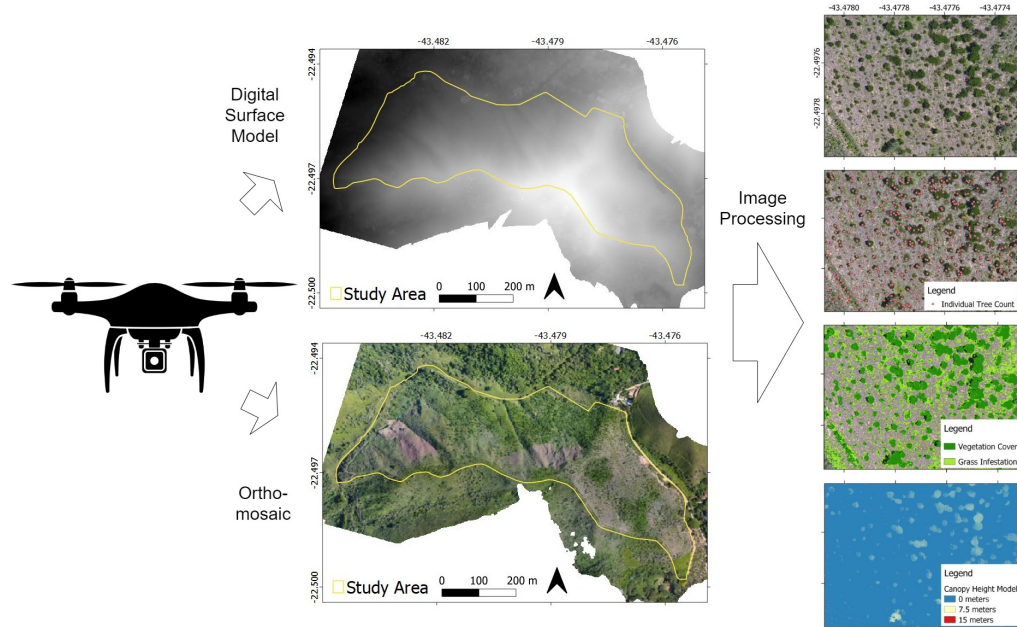


Figura 10: Figura síntese do artigo "*Forest Restoration Monitoring Protocol with a Low-Cost Remotely Piloted Aircraft: Lessons Learned from a Case Study in the Brazilian Atlantic Forest*", publicado no âmbito desta tese para avaliar a detecção automática de indicadores estruturais de RF em imagens obtidas via RPA-SfM. Fonte: Albuquerque et al. (2021)

Uma vez que cobertura e altura de dossel são passíveis de aumento de escala via RPA-SfM, o Protocolo de Monitoramento da Restauração de Ecossistemas via Sensoriamento Remoto para a Mata Atlântica e Amazônia, neste momento em fase de desenvolvimento e fruto de trabalhos envolvendo esta tese, também apresentará informações sobre a obtenção de indicadores de estrutura da vegetação via RPA-SfM. No Protocolo, a descrição das metodologias ocorrerá de forma mais amigável, inclusive em forma de tutoriais. Espera-se que a medição de cobertura e altura de dossel por RPA-SfM auxilie não apenas os responsáveis por projetos de RF, mas também atividades de fiscalização por parte dos órgãos públicos competentes.

A seção 4.2 apresenta em português um artigo submetido em periódico internacional (aguardando parecer) sobre um método amigável de medição da cobertura de dossel via RPA-SfM. Esse método não apresenta novidade científica, mas possui relevância por mostrar como medir de forma eficiente o indicador mais importante da fase I do Protocolo de Monitoramento da RF do Pacto pela Restauração da Mata Atlântica (VIANI et al., 2013).

Para pesquisadores que desejarem avaliar a acurácia dos indicadores cobertura e altura de dossel, reforça-se que a cobertura de dossel deve ser avaliada por fotointerpretação (semelhante a trabalhos tradicionais de SR orbital, onde o olho humano, mediante

interpretação visual de imagens, é capaz de distinguir a cobertura do solo) ao invés de comparação com dados de campo. Afinal, a fotointerpretação neutraliza as incertezas nos posicionamentos obtidos por GNSS de navegação ( $\pm 2$  m de precisão) dos inventários florestais. Além disso, cobertura de dossel é uma variável de duas dimensões, mas a fita métrica utilizada em campo gera dados de uma dimensão apenas (ALBUQUERQUE et al., 2021). Já a altura de dossel requer dados de campo para avaliação de acurácia, sendo necessário atenção para a propagação de erros ocasionada por estimativa visual da altura das árvores em trabalhos de campo (HONGYA et al., 2012). O uso de LiDAR acoplado a plataformas aéreas é uma boa opção para dados referência de altura de dossel, pois gera resultados mais acurados que trabalhos de campo ao medir esse indicador (SIBONA et al., 2017).

## 4.2 Artigo submetido: Um protocolo para monitoramento da cobertura de dossel de projetos de Restauração Florestal via RPA de baixo custo

Além da participação do autor, orientador e co-orientador desta tese, o artigo intitulado "Um protocolo para monitoramento da cobertura de dossel de projetos de Restauração florestal via RPA de baixo custo" foi desenvolvido em parceria com: o World Resources Institute (WRI), nas pessoas do Marcelo Hiromiti Matsumoto e Miguel Calmon; e com a Embrapa CENARGEN, na pessoa do Daniel Luís Mascia Vieira.

### 4.2.1 Resumo do artigo submetido

Remotely Piloted Aircrafts (RPA), conhecidos como drones, têm sido cada vez mais usados no monitoramento da Restauração florestal (RF). Considerando que a cobertura de dossel é o indicador mais importante na fase inicial de uma RF, apresentamos um protocolo de avaliação deste indicador utilizando um RPA de baixo custo e um método amigável de uso de softwares. Testamos o protocolo em seis projetos diferentes de RF na Mata Atlântica brasileira. Após processar automaticamente as imagens para gerar o Modelo Digital de Superfície (MDS) e o Modelo Digital de Terreno (MDT), medimos a cobertura de dossel no QGIS considerando apenas intervalos de altura do *Canopy Height Model* (CHM). Os resultados apresentaram valores de F1 maiores que 0,9, confirmando a robustez de uma metodologia simples e que não demanda conhecimentos específicos de Ciência da Computação nem de Sensoriamento Remoto. RPA de baixo custo mostraram-se, portanto,

capazes de medir a cobertura de dossel de forma acurada e amigável, contribuindo para o aprimoramento da medição deste indicador em diferentes estágios de RF. Tal fato deve ser considerado em políticas de RF porque torna o monitoramento de um importante indicador mais transparente. Trabalhos futuros deverão buscar protocolos amigáveis para a medição remota de outros indicadores de RF.

#### 4.2.2 Destaques do artigo submetido:

- Apresenta-se um protocolo para mensurar a cobertura de dossel utilizando-se drones de baixo custo
- O protocolo é amigável e não requer um especialista em Sensoriamento Remoto
- O protocolo pode ser usado na maior parte dos diferentes estágios de Restauração Florestal de fitofisionomias florestais
- Há maior qualidade ao monitoramento da Restauração Florestal ao se utilizar o protocolo aqui apresentado

#### 4.2.3 Introdução do artigo submetido

O monitoramento da Restauração Florestal (RF) é necessário para certificar se o projeto está cumprindo seus objetivos ou se alguma ação é necessária (DELUCA et al., 2010; CHAVES et al., 2015; MCDONALD et al., 2016). Um indicador de considerável importância na fase inicial de projetos de RF é a cobertura de dossel, que deve atingir ao menos 70-80% (VIANI et al., 2017). Ao atingir esse objetivo, o dossel fechado inibe o crescimento de gramíneas, atrai dispersores de sementes e modifica o microclima de modo a favorecer o crescimento de novas árvores (VIANI et al., 2017; FREITAS et al., 2019). Assim, após o fechamento do dossel, outros indicadores ganham importância no monitoramento, como a densidade e diversidade dos regenerantes. Os regenerantes irão substituir as árvores do dossel, de forma a propiciar a diversidade de espécies e de estrutura necessárias ao pleno retorno da floresta (VIANI et al., 2017; FREITAS et al., 2019).

Remotely Piloted Aircraft (RPA), popularmente conhecidos como drones, apresentam grande potencial para o monitoramento da RF (ZAHAWI et al., 2015; ALBUQUERQUE et al., 2021). RPA podem registrar áreas inteiras de RF em visão panorâmica através de imagem de alta resolução e nuvem de pontos georreferenciados (BERNI et al., 2009; OLTMANNNS et al., 2012; AASEN et al., 2015). Ao registrar toda a área de interesse, o uso dessa tecnologia é capaz de acessar informações relevantes em áreas de RF não

amostradas por parcelas de campo (ALMEIDA et al., 2019; ALBUQUERQUE et al., 2021).

Câmeras digitais acopladas a RPA mostraram-se capazes de medir de forma acurada a cobertura de dossel quando o dossel não está fechado (CHEN et al., 2017; WU et al., 2019; BELMONTE et al., 2020; ALBUQUERQUE et al., 2021). Já a capacidade dos RPA de baixo custo monitorarem este indicador também em situações de dossel fechado no contexto da RF brasileira deve ser avaliada para o aprimoramento de políticas públicas. Logo, considerando o potencial de RPA para o monitoramento da RF, a criação e divulgação de um protocolo amigável de medição da cobertura de dossel em diferentes estágios de desenvolvimento da vegetação é relevante. Em tal protocolo, a sociedade deve ser capaz de mensurar a cobertura de dossel de forma acurada e sem a necessidade de especialização em Sensoriamento Remoto. Mohan et al. (2021), por exemplo, publicaram um guia passo a passo de detecção automática de árvores que não requer grandes conhecimentos em Sensoriamento Remoto. Em relação à cobertura de dossel, sabe-se que é possível a medição através de machine learning (REIS et al., 2019a), mas neste caso deve haver a presença de um especialista em Sensoriamento Remoto.

Este trabalho tem o objetivo de apresentar um protocolo de medição do indicador cobertura de dossel através de RPA de baixo custo no qual grandes conhecimentos de Sensoriamento Remoto não são necessários. Para testar e ilustrar o protocolo, nós avaliamos sua acurácia em seis diferentes projetos de RF que apresentavam diferentes situações de reestabelecimento das florestas.

## 4.2.4 Materiais e Métodos do artigo submetido

### 4.2.4.1 Materiais

O RPA deve apresentar sensores *Red-Green-Blue* (RGB) com ao menos 1/2.3-polegadas e 12-megapixel CMOS (*complementary metal oxide semiconductor*). Com essas especificações, o RPA captura fotos que apresentarão detalhes mínimos ao serem processadas por *Structure from Motion - Multi View Stereo* (SfM-MVS) (COLOMINA; MOLINA, 2014; SCHONBERGER; FRAHM, 2016) para gerar informações cartográficas. No caso do presente trabalho, usamos um Phantom 4 Pro (RPA do tipo asa-rotativa), que possui câmera RGB com 1-polegada e 20megapixel CMOS. Mais informações sobre este modelo estão disponíveis em DJI (2022).

Em relação ao software, mencionamos aqui aqueles que utilizamos nos estudos de

caso do presente trabalho, mas outros softwares com funcionalidades similares podem ser usados. Usamos o Map Pilot (DRONESMADEEASY, 2020) para planejar o voo e o Agisoft Metashape (AGISOFT, 2020) para gerar o Modelo Digital de Superfície (MDS), o Modelo Digital de Terreno (MDT) e os mosaicos ortorretificados. Usamos o software QGIS para os demais processamentos de imagens e para gerar os *layouts* dos mapas.

#### 4.2.4.2 Padrões de voo

Todos os voos devem ser realizados de acordo com as normas legais brasileiras, ou seja, com alturas menores que 120 metros. O responsável pelo RPA deve definir a altura de voo considerando: o valor desejado do *Ground Sampling Distance* (GSD), que é a resolução espacial do pixel da imagem; e a altura dos objetos da superfície (no caso de áreas de RF tais objetos geralmente são árvores) para evitar colisões.

Nos planos de voo do RPA, o ângulo da câmera deve ser igual a zero graus (Nadir) e as sobreposições longitudinal e lateral mínimas das fotos iguais a 90% e 80%, respectivamente. Estes valores de sobreposição de fotos aumentam o tempo de processamento de imagens para produção dos dados cartográficos, mas fornecem quantidade mínima de detalhes necessários ao processamento da nuvem de pontos dos projetos de RF sobrevoados (ALBUQUERQUE et al., 2020).

#### 4.2.4.3 Cobertura de dossel medida por RPA

Pontos de controle não são obrigatórios para a mensuração da cobertura de dossel via câmeras fotográficas a bordo de RPA. Isso torna a precisão dos dados cartográficos equivalente a aproximadamente três metros (JÚNIOR et al., 2018). A não obrigatoriedade de pontos de controle é uma vantagem porque reduz os custos devido ao: menor tempo dispendido nos trabalhos de campo (FERRER-GONZÁLEZ et al., 2020); e ao elevado preço dos equipamentos Global Navigation Satellite System (GNSS) geodésicos dispensados (NIE; LIU; GAO, 2020).

Após o voo do RPA e geração do ortomosaico e MDS via SfM-MVS, a cobertura de dossel é obtida utilizando-se o *Canopy Height Model* (CHM), que é obtido pela diferença entre o MDS e o MDT (LIU; DONG, 2014). Para obter o MDT, é necessário classificar a ocorrência de solo na nuvem de pontos. Tal classificação é feita por um algoritmo que requer a definição de valores a alguns de seus parâmetros por parte do usuário. Logo, o usuário deve calibrar os valores do algoritmo de identificação de terreno para cada RF sobrevoada. No intuito de facilitar a definição dos valores dos parâmetros

deste algoritmo a serem definidos pelos usuários, a Tabela 1 na seção 4.2.5 apresenta os valores utilizados nos estudos de caso do presente trabalho.

Nos estudos de caso foi utilizado o algoritmo *Classify Ground Points*, presente no software Agisoft Metashape. Tal algoritmo requer definição dos valores dos parâmetros ângulo máximo, distância máxima e tamanho da célula para detectar mudanças bruscas de elevação que caracterizam elementos da superfície. O parâmetro ângulo máximo define a declividade do terreno, ou seja, ângulos maiores que determinado valor caracterizam um elemento da superfície. O parâmetro distância máxima define a distância máxima entre dois pontos no qual o ângulo de declividade (entre esses dois pontos) é avaliado. Já o parâmetro tamanho da célula corresponde ao tamanho máximo da área que não contém terreno, ou a área máxima ocupada por elementos da superfície. Assim, o algoritmo divide a área em células (parâmetro tamanho da célula) e avalia em cada uma se a declividade (parâmetro ângulo máximo) e distância (parâmetro distância máxima) entre dois pontos satisfazem os valores definidos pelo usuário. Mais informações sobre o algoritmo *Classify Ground Points* podem ser vistas em Zhang e Lin (2013).

Após a geração do DTM, o CHM é obtido pela diferença entre a camada do DSM e a camada do DTM correspondente. Nos estudos de caso do presente trabalho, essa operação foi realizada através da ferramenta "Calculadora Raster" do software QGIS. Na sequência, obtidas as camadas CHM para cada RF sobrevoada, é necessário definir o valor limiar de altura em cada camada. Tal valor de limiar separa o que é árvore e o que é gramínea (pode haver locais com gramíneas volumosas, então este limiar de altura varia em cada RF). No QGIS, o valor limiar de altura pode ser definido através da ferramenta "Calculadora Raster" digitando-se, por exemplo, "CHM\_layer > 0.5", onde "CHM\_layer" é o nome da camada referente ao CHM e "0.5" corresponde ao valor de altura das gramíneas. Ressalta-se que a altura das gramíneas varia em cada projeto de RF, devendo o usuário deste protocolo verificar o valor do limiar de altura capaz gerar resultados acurados conforme cada caso. Nos estudos de caso deste protocolo, a altura das gramíneas nas diferentes RFs variou entre 0 e 1 metro.

Após definição do valor limiar de altura do CHM que incorpora apenas árvores, a ferramenta "Calculadora Raster" do QGIS gera uma máscara binária na qual pixels representantes de árvores possuem valor 1 e pixels referentes a não-árvores valor 0. Para verificar os valores de área (em metros quadrados) cobertos por pixels correspondentes a árvores e a não-árvores, a ferramenta "*Raster layer unique values report*" do QGIS pode ser utilizada. A cobertura de dossel é então obtida conforme a Equação 4.1.

$$CD = \frac{APA}{(APA + APNA)} \quad (4.1)$$

Onde: CD = cobertura de dossel, APA = área dos pixels correspondentes a árvores, APNA = área dos pixels correspondentes a não-árvores.

Abaixo o fluxo de procedimentos para obtenção da cobertura de dossel:

Voo do RPA (1) -> Geração de MDS e ortomosaico (2) -> Geração do MDT (3) -> Geração do CHM (4) -> Verificação do limiar CHM que envolve apenas árvores (5) -> Cálculo do percentual de pixels que representam árvores na máscara binária (6).

#### 4.2.4.4 Estudos de caso

Nós avaliamos seis projetos de RF na Mata Atlântica brasileira. Três localizam-se no município de Extrema, estado de Minas Gerais (MG), e fazem parte da área de proteção ambiental Fernão Dias. Os outros três projetos de RF localizam-se no município de São José dos Campos, estado de São Paulo (SP), e fazem parte da área de proteção ambiental Bacia do Rio Paraíba do Sul (Figura 11).

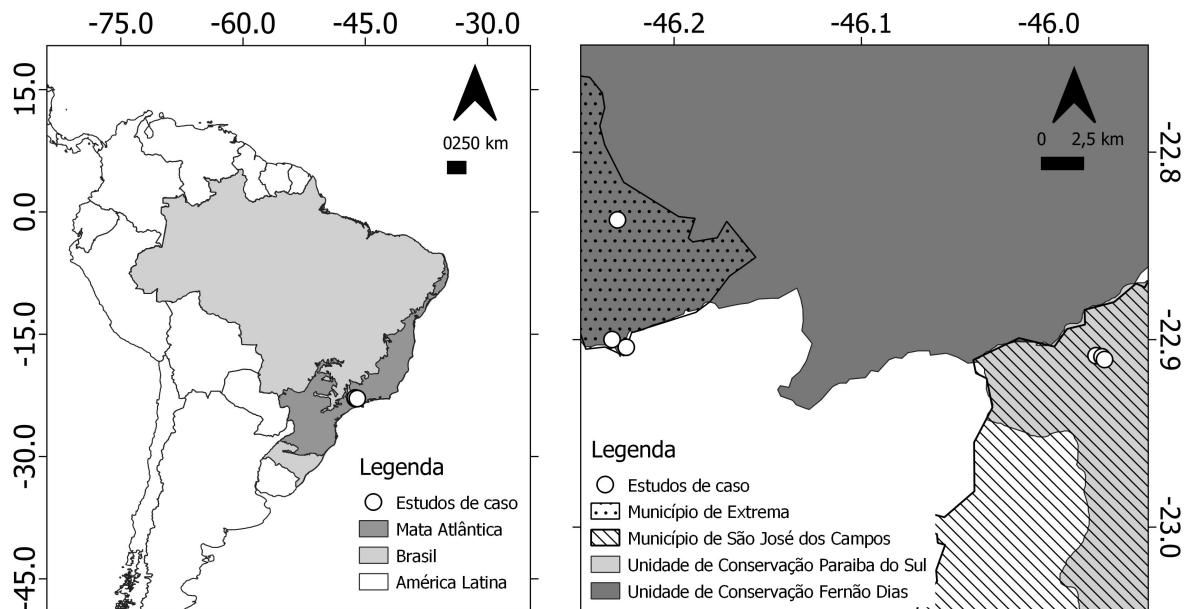


Figura 11: Localização dos estudos de caso na Mata Atlântica brasileira.

Os estudos de caso envolveram métodos de restauração ativa e passiva (MORRISON; LINDELL, 2011; BRANCALION et al., 2016b). A área 1 (Figura 12a) é uma restauração ativa em topo de morro com trechos que apresentavam seis anos e trecho que apresentava 1 ano de idade à época do voo. A área 2 (Figura 12b) é uma restauração ativa com trechos que apresentavam entre quatro e dezesseis anos de idade à época do voo. A área 3 (Figura 12c) apresentava restauração ativa e passiva simultaneamente de um ano de idade à época do voo, além de trechos de floresta madura. A área 4 (Figure 12d) possuía 40 anos de restauração ativa à época do voo com alguns trechos de gramíneas. A área 5 (Figure 12e) é uma floresta madura com trechos de gramíneas. A área 6 (Figure 12f) é uma floresta madura com trechos de restauração ativa que tinham um ano de idade à época do voo.

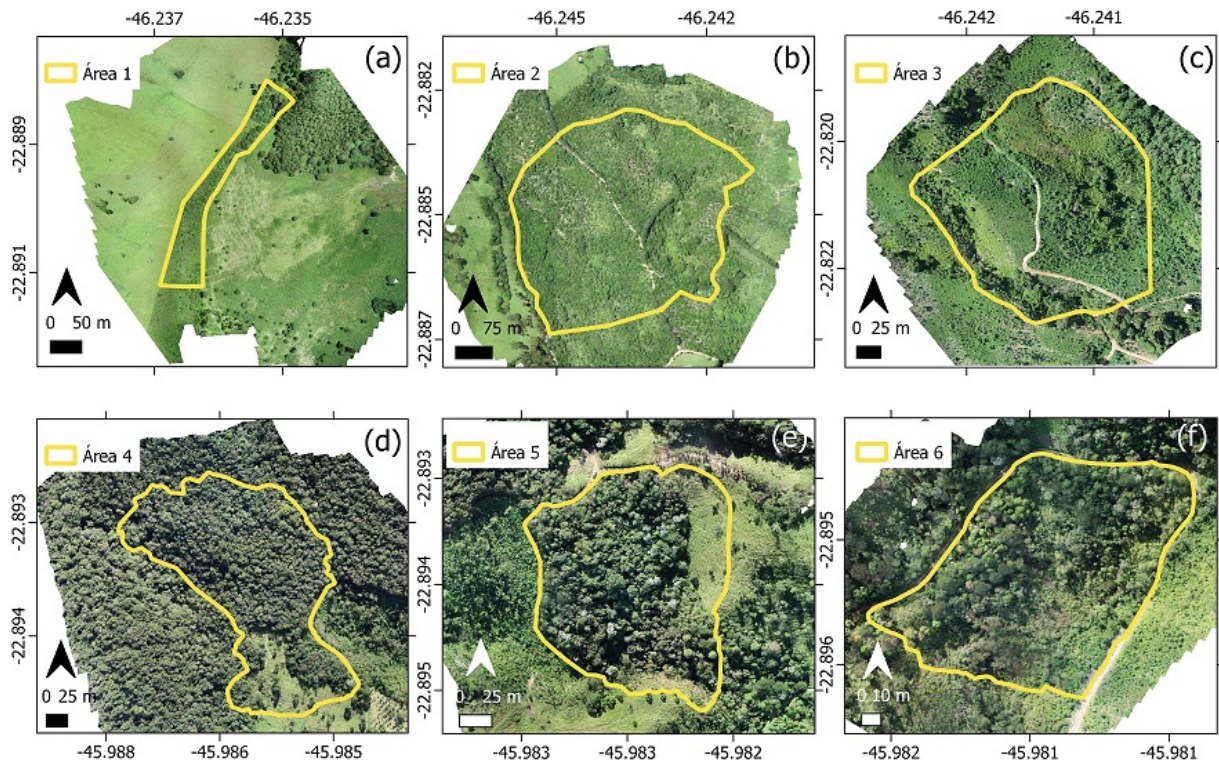


Figura 12: Ortomosaicos obtidos por sensor RGB a bordo de RPA referentes aos seis diferentes projetos de RF sobrevoados: restauração ativa em topo de morro com trechos de 6 anos de idade e trecho de 1 ano de idade (a); restauração ativa com trechos variando entre 4 e 16 anos de idade (b); trechos de restauração ativa e passiva de um ano de idade e trechos de floresta madura (c); restauração ativa de 40 anos com trechos de gramíneas (d); floresta madura com trechos de gramíneas (e); e floresta madura com com trechos de restauração ativa de um ano de idade (f).

Os voos nas áreas localizadas no município de Extrema ocorreram em janeiro de 2019, enquanto os voos nas áreas do município de São José dos Campos ocorreram em junho



de 2019. Todos os voos ocorreram seguindo a normativa legal brasileira (ANAC, 2017a), apresentando 100 metros de altura e gerando GSD de aproximadamente 3 centímetros. As sobreposições longitudinal e lateral das fotos durante os voos foram iguais a 90% e 80%, respectivamente.

Para a avaliação da acurácia da máscara binária referente à cobertura de dossel, cada área apresentou 200 amostras de teste obtidas por fotointerpretação (análise visual das feições das imagens): 100 amostras para a classe árvores e 100 para a classe não-árvores. Calculamos então a Acurácia Geral (CONGALTON, 1991), além dos índices Recall, Precision e F1 (GOUTTE; GAUSSIÉ, 2005) conforme as Equações 4.2, 4.3 e 4.4, respectivamente.

$$r = \frac{VP}{(VP + FN)} \quad (4.2)$$

$$p = \frac{VP}{(VP + FP)} \quad (4.3)$$

$$F1 = 2 * \frac{(r * p)}{(r + p)} \quad (4.4)$$

Onde: VP = Verdadeiro Positivo, FN = Falso Negativo, FP = Falso Positivo, r = recall, p = precision

#### 4.2.5 Resultados do artigo submetido

Os resultados das áreas com cobertura de dossel são mostrados na Figura 13.

A Tabela 1 apresenta os valores dos parâmetros do algoritmo “*Classify Ground Points*” do software Agisoft Metashape para a geração do MDT em cada RF sobrevoada. A Tabela 1 também mostra os resultados da acurácia da obtenção do indicador cobertura de dossel em cada RF dos estudos de caso. Os valores de acurácia foram altos em todos os casos, comprovando a robustez do método de medição da cobertura de dossel descrito nesse protocolo. Todos os valores F1 foram maiores que 0,9, enquanto as médias de Acurácia Geral, Precision, Recall e F1 dos estudos de caso foram equivalentes a 0.97, 0.96, 0.98, and 0.97, respectivamente, reforçando a robustez do método.

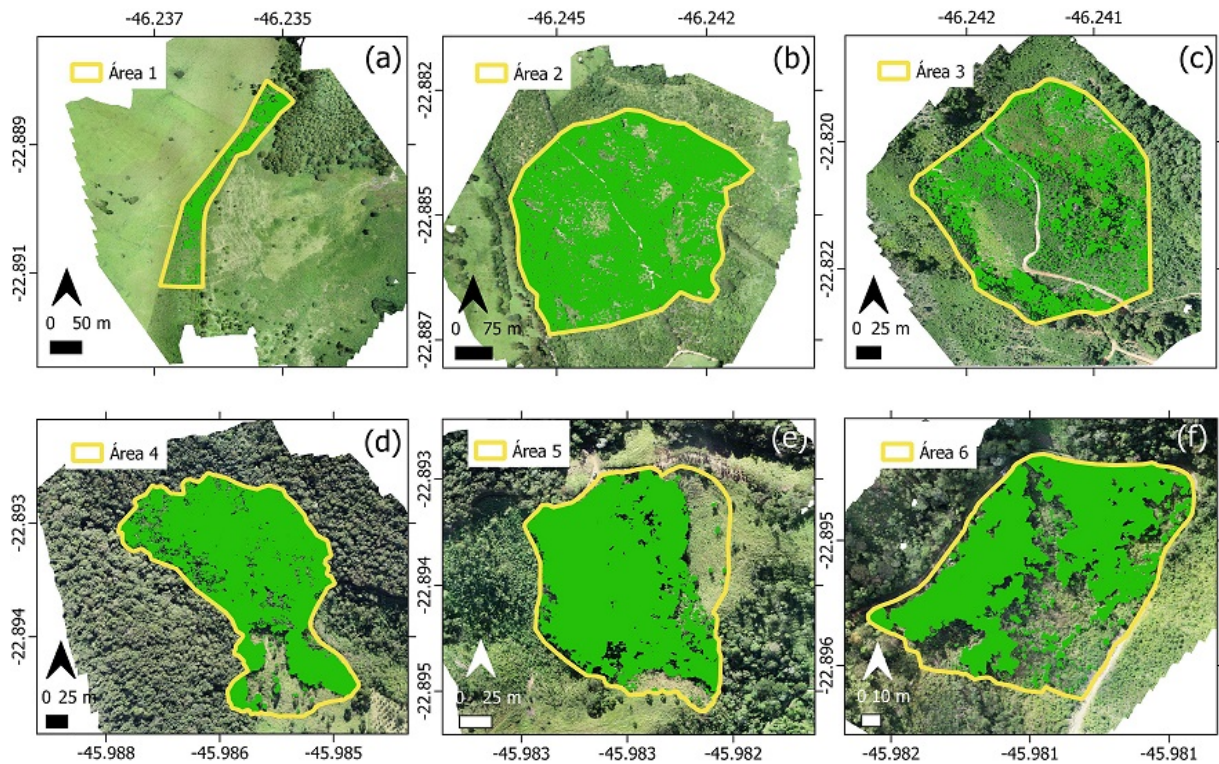


Figura 13: Resultados do mapeamento da cobertura de dossel destacados na cor verde em cada RF sobrevoada.

#### 4.2.6 Discussão do artigo submetido

O protocolo de monitoramento da cobertura de dossel via RPA de baixo custo mapeou de forma acurada um importante indicador de RF. Destaca-se o ambiente computacional amigável, pois não é necessária ampla especialização em Sensoriamento Remoto ou Ciência da Computação para utilizar o método apresentado, mas sim conhecimentos básicos de Geoprocessamento. É necessário saber voar o RPA, fazer análise visual das imagens - fotointerpretação (FLORENZANO, 2002), gerar o ortomosaico e o DSM, além do DTM e do CHM. Tais conhecimentos já são amplamente difundidos e aplicados pela sociedade, sendo a geração do ortomosaico, DSM, DTM e CHM facilitados devido à automatização destes processos. Caso uma pessoa não possua esses conhecimentos, é possível aprender em poucos dias mediante um treinamento que não exige pré-requisitos específicos.

Pontos de controle não são obrigatórios no protocolo aqui apresentado. Conforme mencionado na seção 4.2.4.3, a não-obrigatoriedade dos pontos de controle reduz os custos da operação do RPA: gasta-se menos tempo no campo (FERRER-GONZÁLEZ et al., 2020); e evita-se a utilização de equipamentos GNSS geodésicos, que são considerados

Tabela 1: Valores utilizados nos parâmetros do algoritmo “Classify Ground Points” e acurácia da cobertura de dossel dos estudos de caso.

Área de RF	Parâmetros do algoritmo "Classify Ground Points"			Acurácia da cobertura de dossel				
	Ângulo max (graus)	Distância max (metros)	Tamanho célula (meters)	Cobertura dossel	Acurácia Geral	Precision	Recall	F1
FR ativa de 6 anos com trecho de FR ativa de 1 ano	11	0.6	35	0,417	0,935	0,892	0,99	0,938
RF ativa de 4 a 16 anos variando em diferentes trechos	2.5	0.5	10	0,735	0,97	0,99	0,95	0,969
RF ativa e passiva de 1 ano com trechos de floresta madura	1	0.1	3	0,353	0,965	1	0,93	0,964
RF ativa de 40 anos com trechos de gramíneas	5	0.2	20	0,698	0,985	0,98	0,99	0,985
Floresta madura com trechos de gramíneas	11	0.6	35	0,646	0,985	0,971	1	0,985
Floresta madura com trechos de RF ativa de 1 ano	15	1	50	0,518	0,975	0,952	1	0,976

caros (NIE; LIU; GAO, 2020). Além de aumentar os custos da operação do RPA, o correto manuseio de equipamentos GNSS geodésicos e o adequado processamento dos seus dados demandam conhecimentos específicos mediante treinamento direcionado.

Em relação ao ambiente computacional amigável do protocolo aqui descrito, cabe ressaltar a não utilização de procedimentos de machine learning. Ao utilizar o protocolo, não são necessários conhecimentos de códigos de programação e o cálculo da cobertura de dossel pode ser feito em um software amigável de licença livre. Outras soluções ao mapeamento da cobertura de dossel envolveram hardwares de alto custo de aquisição (sensor multiespectral e LiDAR - *Light Detection And Ranging*) e classificação supervisionada (REIS et al., 2019b; REIS et al., 2019a; ALBUQUERQUE et al., 2021). No caso do protocolo aqui apresentado, foi demonstrada uma metodologia envolvendo RPA de baixo custo que não requer coleta de amostras na imagem, coleta esta que demanda considerável quantidade de tempo (ALBUQUERQUE et al., 2020). Há vantagem em métodos de mineração de dados que não demandam a coleta de amostras nas imagens, pois tais procedimentos têm maior grau de automatização do que os de classificação supervisionada (BELGIU; DRĂGUȚ, 2014; DUARTE; SILVA; TEODORO, 2018).

Outra vantagem do protocolo descrito neste trabalho é a utilização apenas da nuvem de pontos de uma mesma área sobrevoada. Tal sobrevoo gera uma única imagem que não depende de condições de luz solar para geração de um modelo com ampla capacidade de generalização. Afinal, a nuvem de pontos possui valores que não representam a reflectância dos alvos da superfície, mas sim a altitude dos alvos. Procedimentos de machine learning em trabalhos de Sensoriamento Remoto que dependem de valores de reflectância têm a conhecida desvantagem de depender de condições de luz solar para geração de modelos generalizáveis a outras áreas (ZHANG et al., 2020). Tal desvantagem muitas vezes requer

trabalhos de Domínio de Adaptação (VENATOR et al., 2021) para aprimoramento dos modelos.

Além das vantagens descritas no parágrafo anterior sobre o uso apenas da nuvem de pontos, verificou-se que situações de dossel fechado não degradaram a acurácia da medição da cobertura de dossel via RPA e SfM-MVS. Tal fato é relevante porque situações de dossel fechado degradam a acurácia da medição da altura de dossel via SfM-MVS (CHEN et al., 2017; WU et al., 2019; BELMONTE et al., 2020). Porém, essa queda de acurácia na medição da altura do dossel não se refletiu na medição da cobertura do dossel. Em outras palavras, situações de dossel fechado mostraram-se obstáculo para a medição da estrutura vertical do dossel, mas não para a medição da estrutura horizontal do dossel.

Neste trabalho nós geramos o ortomosaico e o CHM utilizando um software comercial, mas softwares de licença livre são mais democráticos (POWELL, 2012). Se iniciativas de licença livre, a exemplo do OpenDroneMap (ODM, 2022), mostrarem-se capazes de gerar estes dados de forma acurada, o uso de RPA e SfM-MVS ao monitoramento de RF se tornará ainda mais acessível. Neste caso, somente a aquisição de hardware (RPA e computador com capacidade de processamento) seria necessária. Cabe também ressaltar que há iniciativas, como o OpenDroneMap, que oferecem a possibilidade de processamento de dados SfM-MVS na nuvem. Essa possibilidade de processamento na nuvem poderia viabilizar a aquisição e uso de computadores com menor capacidade de processamento para tratar os dados obtidos via RPA e SfM-MVS.

Apesar de utilizar um ambiente amigável de hardware e software, o método de obtenção da cobertura de dossel descrito neste trabalho funciona somente quando as árvores tornam-se mais altas que as gramíneas. Albuquerque et al. (2021) utilizaram um método não amigável de mapeamento de cobertura de dossel para aprimorar o resultado em trechos onde as árvores eram pouco mais altas que as gramíneas. Ou seja, a aplicação deste protocolo pode ser inviável nos primeiros anos de RF em fitofisionomias como o Cerrado brasileiro, onde há infestação de gramíneas significativamente altas que prejudicam o crescimento de árvores (DAMASCENO et al., 2018). Entretanto, outros biomas relevantes, como a Amazônia e a Mata Atlântica, podem se beneficiar do protocolo aqui apresentado na maior parte das diferentes fases da RF.

Alem de 90% de sobreposição longitudinal e lateral de fotos, Swayze et al. (2021) recomendam a realização de voos cruzados para o aprimoramento dos detalhes da nuvem de pontos de áreas florestadas. Os autores constataram que voos cruzados aprimoraram a acurácia de determinadas medidas da vegetação feitas através de imagens obtidas por

RPA e SfM-MVS, como Diâmetro à Altura do Peito (DAP) e altura das árvores. O presente protocolo, no entanto, avaliou apenas a cobertura do dossel.

Em situações de dossel fechado, as clareiras são uma importante métrica de biodiversidade (GETZIN; WIEGAND; SCHÖNING, 2012) que podem ser avaliadas em etapa posterior à obtenção da cobertura de dossel descrita neste protocolo. Também em situações de dossel fechado, a altura do dossel se torna um importante indicador porque tem relação com a sustentabilidade da comunidade ecológica (MARTINS et al., 2017), estocagem de biomassa/carbono (KRAUSE et al., 2019) e diversidade de espécies (FERREIRA et al., 2018). Apesar de importante em situação de dossel fechado, a altura de dossel requer pontos de controle para ser medida de forma acurada via RPA de baixo custo (ALBUQUERQUE et al., 2021). Trabalhos futuros deverão, portanto, avaliar a criação de protocolos detalhados de medição de altura de dossel via RPA de baixo custo no contexto da RF brasileira. Outros indicadores que se mostrarem viáveis de serem mensurados de forma generalizada pela sociedade utilizando RPA de baixo custo também deverão apresentar protocolos detalhados.

#### 4.2.7 Conclusões do artigo submetido

Este estudo apresenta um protocolo de monitoramento da cobertura de dossel de projetos de RF utilizando-se RPA de baixo custo e ambiente computacional amigável. O método mostrou-se acurado em todos os seis estudos de caso, que abrangeram um conjunto abrangente de condições de cobertura de dossel. Logo, o protocolo aqui apresentado pode aprimorar políticas de ampliação da escala da RF, como as do Pacto pela Restauração da Mata Atlântica. Uma vez que conhecimentos específicos não são necessários, técnicos de RF podem usar este protocolo para monitorar a cobertura de dossel de seus projetos. Caso não possuam conhecimentos sobre utilização de RPA e geração de CHM, treinamentos não demorados e sem pré-requisitos de formação específica são suficientes ao aprendizado. Ou seja, gestores de projetos de RF devem avaliar, além da aquisição de RPA e de um eventual computador (caso a organização não possa aproveitar os computadores que já possuem), o tempo demandado para a realização de voos e para o processamento dos dados coletados pelo sensor a bordo do RPA. O protocolo aqui descrito pode ser útil nas fases iniciais da RF, em que a cobertura de dossel é inferior a 70%, e nas fases avançadas da RF, em que clareiras são uma importante métrica.

## 5 AVALIAÇÃO DOS ASPECTOS DE BIODIVERSIDADE DA RESTAURAÇÃO FLORESTAL VIA RPA-SfM

Em Albuquerque et al. (2021) foi reforçado o desafio de se medir a biodiversidade através de SR. As imagens obtidas via RPA-SfM, mesmo apresentando alta resolução, mostram que diferentes espécies arbóreas são visualmente muito semelhantes entre si. Tal constatação tornou necessário o uso de coordenadas GNSS precisas tanto no ortomosaico quanto nos locais em que se situam os exemplares de cada espécie. Este procedimento foi utilizado nos trabalhos seguintes para avaliar a biodiversidade em RF.

No âmbito desta tese foi publicado o trabalho Albuquerque et al. (2022), que corresponde ao capítulo que trata do uso de RPA de baixo custo para obter indicadores voltados à biodiversidade da vegetação. O trabalho de Albuquerque et al. (2022) encontra-se anexo à esta tese na seção C.

No artigo intitulado "*Mapping Key Indicators of Forest Restoration in the Amazon Using a Low-Cost Drone and Artificial Intelligence*" (ALBUQUERQUE et al., 2022), foram avaliadas técnicas de *deep learning* para detecção de duas espécies relevantes para a RF na Amazônia (*Vismia* sp e *Cecropia* sp) e para a Detecção de Copa de Árvores (DCA). Os procedimentos de *deep learning* envolveram a rede Mask-RCNN porque seus resultados geram segmentação de instâncias (ao invés de segmentação semântica) e mostraram potencial para análises da vegetação em outros trabalhos, conforme mostra Albuquerque et al. (2022).

Para certificar a aparência visual de *Vismia* sp e de *Cecropia* sp nas imagens obtidas por RPA-SfM, foram coletadas coordenadas GNSS precisas dessas espécies em campo. As coordenadas precisas das espécies junto aos pontos de controle do ortomosaico neutralizaram as incertezas cartográficas, conforme sugerido em Albuquerque et al. (2021). Há diversas espécies a serem estudadas, mas *Vismia* sp e *Cecropia* sp foram escolhidas porque são indicadores de biodiversidade relevantes para a RF da Amazônia. A predominância de *Vismia* sp indica que a RF não apresentará biodiversidade no futuro, tampouco biomassa,

o que é diferente da predominância de *Cecropia* sp, considerada um bom indicador.

Já o DCA foi utilizado para avaliação de métricas de heterogeneidade do CHM dentro dos polígonos que representam as copas das árvores, afinal RFs mais biodiversas possuem um dossel mais heterogêneo. Tal avaliação de heterogeneidade das copas das árvores visou à proposição do *Tree Crown Heterogeneity Index* (TCHI), um índice cujo intuito é estimar a diversidade de espécies da RF via RPA-SfM. Para obter o TCHI, foi feita uma análise de regressão considerando como variável independente os valores de heterogeneidade obtidos por RPA-SfM (dentro do resultado do DCA) e como variável dependente o índice Shannon medido em campo por inventário florestal.

O *deep learning* mostrou-se adequado para identificar as duas espécies (*Vismia* sp e *Cecropia* sp) e para realizar o DCA. Já o TCHI apresentou valores robustos na análise de regressão, principalmente quando associados às séries de Fourier. Entretanto, a quantidade de dados na análise de regressão foi considerada escassa. Ou seja, o modelo gerado para o TCHI, apesar do potencial, precisa de mais dados para abordar diferentes situações. Logo, trabalhos futuros deverão aprimorar a capacidade de generalização do TCHI analisando diferentes projetos de RF de forma a abranger as mais diversas situações possíveis. A análise futura de diferentes projetos de RF também buscará aprimorar a capacidade de generalização da detecção automática das espécies *Vismia* sp e *Cecropia* sp e da realização do DCA. A detecção automática de outras espécies relevantes à RF também deverão ser avaliadas. A Figura 14 apresenta uma síntese dos resultados obtidos em Albuquerque et al. (2022).

O mapeamento da biodiversidade por SR é de fato um desafio. A geração de modelos robustos de mapeamento de espécies passa não apenas pelos desafios de *machine learning* em si, mas também pela coleta de dados. Afinal, os modelos devem ser capazes de lidar com variações de luz ao longo do dia e ao longo das diferentes estações do ano, além das variações de nebulosidade. É possível recorrer à Adaptação de Domínio (ZHANG et al., 2020) para ampliar a capacidade de generalização dos modelos de SR, mas ainda assim coletar dados de espécies requer algum esforço. Além dos custos de coleta em campo e processamento de dados em escritório, o delineamento manual das amostras das espécies sobre as imagens requer grande quantidade de tempo. Ainda, procedimentos de *machine learning* requerem mão-de-obra especializada. Tal fato inviabiliza a realização de trabalhos como o de Albuquerque et al. (2022) para cada projeto de RF. Intui-se que investimentos financeiros são melhor aplicados aumentando-se a quantidade de parcelas de campo do que contratando-se um serviço de *machine learning* para mapeamento de poucas espécies do dossel. Essa tese não pretende avaliar financeiramente as alternativas

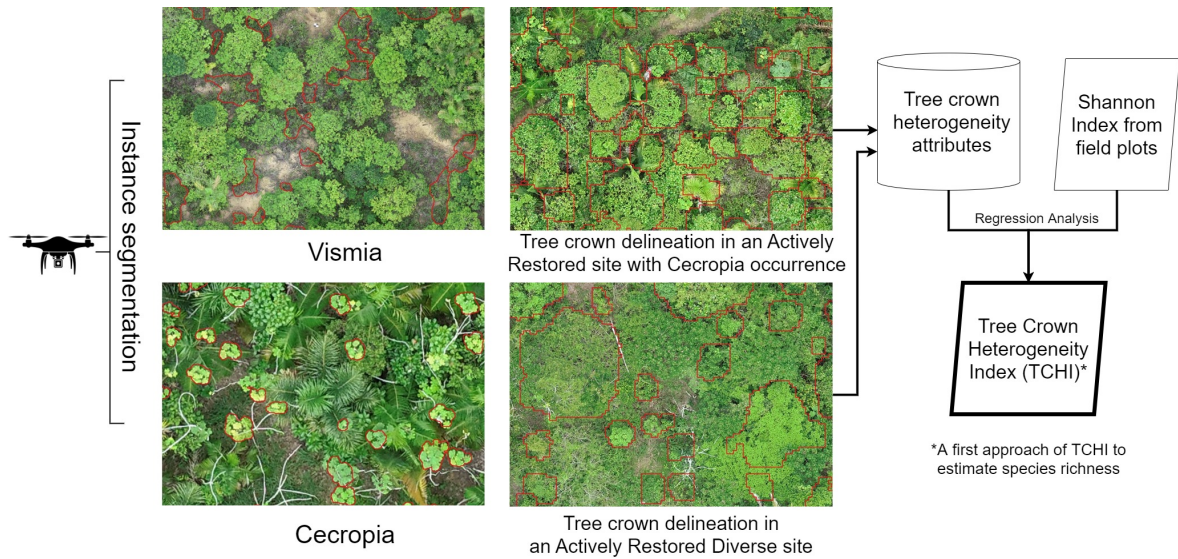


Figura 14: Figura síntese do artigo "*Mapping Key Indicators of Forest Restoration in the Amazon Using a Low-Cost Drone and Artificial Intelligence*", publicado no âmbito desta tese para avaliar a detecção automática de indicadores de biodiversidade de RF em imagens obtidas via RPA-SfM. Fonte: Albuquerque et al. (2022)

de monitoramento de RF, mas ressalta-se essa intuição porque somente o campo é capaz de levantar a riqueza de regenerantes, um importante indicador. Frente às possibilidades de SR já existentes, provavelmente o campo seguirá sendo a única alternativa para levantamento da riqueza de regenerantes no longo prazo.

Ou seja, a idéia intuitiva de que RPA-SfM, ou qualquer outra tecnologia de SR, substituirá o campo não deve ser alimentada. Ao invés de substituição, poderá haver complementação. Num futuro não distante pode ser que determinados indicadores de RF sejam levantados por SR e outros por trabalhos de campo. Conforme mencionado na seção 3.2, tal complementação entre diferentes métodos já foi há muito antecipada por Shuman e Ambrose (2003): SR fornece a cobertura de vegetação e o campo as espécies. No caso de RPA-SfM, mais pesquisas são necessárias para a geração de uma ferramenta amigável de identificação automática de espécies capaz de ser utilizada por profissionais de RF não especializados em SR.



## 6 CONCLUSÕES

RPA-SfM mostraram-se promissores para aprimorar o monitoramento da RF, pois tanto os aspectos estruturais quanto os de biodiversidade apresentaram resultados acurados. A cobertura de dossel e altura do dossel são indicadores importantes e podem ser mensurados de forma acurada e generalizada utilizando-se a nuvem de pontos como principal base de dados. A nuvem de pontos é uma base não afetada por diferentes condições de luminosidade, o que permite a geração de modelos com capacidade de generalização a outras áreas. Outra vantagem do uso da nuvem de pontos é que, para medir a cobertura de dossel, o seu processamento não demanda ampla capacitação, o que torna a metodologia de uso de RPA-SfM mais democrática. Já a altura de dossel medida por SfM-MVS em situações de dossel fechado requer um voo realizado com pontos de controle via GNSS geodésico antes da RF começar. Esse voo inicial permite um levantamento preciso do MDT, devendo os voos posteriores serem realizados também com coordenadas GNSS precisas. O uso de pontos de controle em imagens obtidas por RPA-SfM requer capacitação específica, mas passível de aplicação de forma generalizada por parte da sociedade.

Já os indicadores voltados à biodiversidade, apesar de acurados neste trabalho, necessitam de mais dados para serem mensurados de forma generalizada pela sociedade. Trabalhos futuros deverão coletar mais dados para que um *plugin* amigável de software SIG contendo modelos robustos de biodiversidade com ampla capacidade de generalização possa ser utilizado pela sociedade. Por ora, a utilização de RPA-SfM para medição dos indicadores cobertura de dossel e altura de dossel mostra-se viável, devendo os demais indicadores serem mensurados por trabalhos convencionais de campo.

Frente ao potencial de RPA-SfM para identificação de espécies, trabalhos futuros deverão contribuir também para a medição de biomassa dos projetos de RF. Caso seja possível mapear ao menos algumas espécies chave do dossel, o cálculo da biomassa lenhosa acima do solo poderá tornar-se mais acurado. Afinal, nestes casos poder-se-á considerar não apenas a altura do dossel no cálculo da biomassa via RPA-SfM, mas também diferentes grupos de espécies, que estariam separadas de acordo com a similaridade de estocagem

de carbono. Ou seja, quando associados a dados de campo, o uso de RPA-SfM poderá ampliar a escala do cálculo preciso da biomassa lenhosa acima do solo em projetos de RF.

## REFERÊNCIAS

- AASEN, H.; BURKART, A.; BOLTEN, A.; BARETH, G. Generating 3d hyperspectral information with lightweight uav snapshot cameras for vegetation monitoring: From camera calibration to quality assurance. **ISPRS Journal of Photogrammetry and Remote Sensing**, Elsevier, v. 108, n. 10, p. 245–259, 2015.
- AB’SÁBER, A. N. **Os domínios de natureza no Brasil: potencialidades paisagísticas**. [S.l.]: Ateliê Editorial, 2003. v. 1.
- ADAMS, C.; RODRIGUES, S. T.; CALMON, M.; KUMAR, C. Impacts of large-scale forest restoration on socioeconomic status and local livelihoods: what we know and do not know. **Biotropica**, Wiley Online Library, v. 48, n. 6, p. 731–744, 2016.
- AERTS, R.; HONNAY, O. Forest restoration, biodiversity and ecosystem functioning. **BMC ecology**, BioMed Central, v. 11, n. 1, p. 29, 2011.
- AGISOFT. **Discover intelligent photogrammetry with Metashape**. 2020. Disponível em: <<https://www.agisoft.com/>>.
- ALBUQUERQUE, R. W.; COSTA, M. O.; FERREIRA, M. E.; JORGE, L. A. C.; SARRACINI, L. H.; ROSA, E. O.; TAVARES, L. F. S. Qualitative effectiveness of unmanned aerial vehicles for monitoring forest restoration in brazil: a brief review. **International Journal of Current Research**, v. 9, n. 5, p. 50802–50806, 2017.
- ALBUQUERQUE, R. W.; COSTA, M. O.; FERREIRA, M. E.; CARRERO, G. C.; GROHMANN, C. H. Remotely piloted aircraft imagery for automatic tree counting in forest restoration areas: a case study in the amazon. **Journal of Unmanned Vehicle Systems**, NRC Research Press 1840 Woodward Drive, Suite 1, Ottawa, ON K2C 0P7, v. 8, n. 3, p. 207–223, 2020.
- ALBUQUERQUE, R. W.; FERREIRA, M. E.; OLSEN, S. I.; TYMUS, J. R. C.; BALIEIRO, C. P.; MANSUR, H.; MOURA, C. J. R.; COSTA, J. V. S.; BRANCO, M. R. C.; GROHMANN, C. H. Forest restoration monitoring protocol with a low-cost remotely piloted aircraft: Lessons learned from a case study in the brazilian atlantic forest. **Remote Sensing**, v. 13, n. 12, 2021. ISSN 2072-4292. Disponível em: <<https://www.mdpi.com/2072-4292/13/12/2401>>.
- ALBUQUERQUE, R. W.; VIEIRA, D. L. M.; FERREIRA, M. E.; SOARES, L. P.; OLSEN, S. I.; ARAUJO, L. S.; VICENTE, L. E.; TYMUS, J. R. C.; BALIEIRO, C. P.; MATSUMOTO, M. H.; GROHMANN, C. H. Mapping key indicators of forest restoration in the amazon using a low-cost drone and artificial intelligence. **Remote Sensing**, v. 14, n. 4, 2022. ISSN 2072-4292. Disponível em: <<https://www.mdpi.com/2072-4292/14/4/830>>.
- ALMEIDA, D.; BROADBENT, E.; ZAMBRANO, A.; WILKINSON, B.; FERREIRA, M.; CHAZDON, R.; MELI, P.; GORGENS, E.; SILVA, C.; STARK, S.; VALBUENA, R.;

PAPA, D.; BRANCALION, P. Monitoring the structure of forest restoration plantations with a drone-lidar system. **International Journal of Applied Earth Observation and Geoinformation**, v. 79, p. 192–198, 2019. ISSN 0303-2434. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0303243418311954>>.

ALMEIDA, D. R. de; STARK, S. C.; VALBUENA, R.; BROADBENT, E. N.; SILVA, T. S.; RESENDE, A. F. de; FERREIRA, M. P.; CARDIL, A.; SILVA, C. A.; AMAZONAS, N. et al. A new era in forest restoration monitoring. **Restoration Ecology**, Wiley Online Library, v. 28, n. 1, p. 8–11, 2020.

ALONZO, M.; BOOKHAGEN, B.; ROBERTS, D. A. Urban tree species mapping using hyperspectral and lidar data fusion. **Remote Sensing of Environment**, Elsevier, v. 148, p. 70–83, 2014.

ANAC. **Agência Nacional de Aviação Civil. Requisitos gerais para aeronaves não tripuladas de uso civil. Resolução número 419, de 2 de maio de 2017. Regulamento Brasileiro da Aviação Civil Especial, RBAC-E número 94.** 2017. Available at <<[https://www.anac.gov.br/assuntos/legislacao/legislacao-1/rbha-e-rbac/rbac/rbac-e-94/@@display-file/arquivo\\_norma/RBACE94EMD00.pdf](https://www.anac.gov.br/assuntos/legislacao/legislacao-1/rbha-e-rbac/rbac/rbac-e-94/@@display-file/arquivo_norma/RBACE94EMD00.pdf)>>, Accessed on 2021-06-17.

ANAC. **Orientações para usuários de Drones.** [S.l.], 2017. Available at <<[https://www.anac.gov.br/assuntos/paginas-tematicas/drones/orientacoes\\_para\\_usuarios.pdf](https://www.anac.gov.br/assuntos/paginas-tematicas/drones/orientacoes_para_usuarios.pdf)>>, Accessed on 2019-09-01.

ANDERSEN, R.; FARRELL, C.; GRAF, M.; MULLER, F.; CALVAR, E.; FRANKARD, P.; CAPORN, S.; ANDERSON, P. An overview of the progress and challenges of peatland restoration in western europe. **Restoration Ecology**, Wiley Online Library, v. 25, n. 2, p. 271–282, 2017.

ANDRADE, C. F. S.; RODACOSKI, J. L.; COLLESI, G. S. P.; FARIA, S. P. Recuperação da cobertura vegetal do quilombo do cabral em paraty, rj—bases de um projeto socio-ambiental de extensão. **Revista Ciência em Extensão**, v. 9, n. 3, p. 7–20, 2013.

ANDRADE, G. F.; SANCHEZ, G. F.; ALMEIDA, J. R. Monitoramento e avaliação em projetos de recuperação de áreas degradadas. **Revista Internacional de Ciências**, v. 4, n. 2, p. 13–26, 2014.

ARONSON, J.; BRANCALION, P. H.; DURIGAN, G.; RODRIGUES, R. R.; ENGEL, V. L.; TABARELLI, M.; TOREZAN, J. M.; GANDOLFI, S.; MELO, A. C. de; KAGEYAMA, P. Y. et al. What role should government regulation play in ecological restoration? ongoing debate in são paulo state, brazil. **Restoration Ecology**, Wiley Online Library, v. 19, n. 6, p. 690–695, 2011.

ARONSON, J.; DURIGAN, G.; BRANCALION, P. Conceitos e definições correlatos à ciência e à prática da restauração ecológica. **IF Série Registros**, v. 44, p. 1–38, 2011. Accessed on 2016-10-20. Disponível em: <<http://www.lerf.esalq.usp.br/divulgacao/recomendados/artigos/aronson2011.pdf>>.

ARROYO-MORA, J. P.; SÁNCHEZ-AZOFEIFA, G. A.; KALACSKA, M. E.; RIVARD, B.; CALVO-ALVARADO, J. C.; JANZEN, D. H. Secondary forest detection in a neotropical dry forest landscape using landsat 7 etm+ and ikonos imagery 1. **Biotropica: The**

**Journal of Biology and Conservation**, Wiley Online Library, v. 37, n. 4, p. 497–507, 2005.

ARROYO-RODRÍGUEZ, V.; MELO, F. P.; MARTÍNEZ-RAMOS, M.; BONGERS, F.; CHAZDON, R. L.; MEAVE, J. A.; NORDEN, N.; SANTOS, B. A.; LEAL, I. R.; TABARELLI, M. Multiple successional pathways in human-modified tropical landscapes: new insights from forest succession, forest fragmentation and landscape ecology research. **Biological Reviews**, Wiley Online Library, v. 92, n. 1, p. 326–340, 2017.

ARVOR, D.; DUBREUIL, V.; SIMOES, M.; BÉGUÉ, A. Mapping and spatial analysis of the soybean agricultural frontier in mato grosso, brazil, using remote sensing data. **GeoJournal**, Springer, v. 78, n. 5, p. 833–850, 2013.

ASSUNÇÃO, S. L.; FELFILI, J. M. Fitossociologia de um fragmento de cerrado sensu stricto na apa do paranoá, df, brasil. **Acta botanica brasílica**, SciELO Brasil, v. 18, n. 4, p. 903–909, 2004.

BACCINI, A.; GOETZ, S.; WALKER, W.; LAPORTE, N.; SUN, M.; SULLAMENASHE, D.; HACKLER, J.; BECK, P.; DUBAYAH, R.; FRIEDL, M. et al. Estimated carbon dioxide emissions from tropical deforestation improved by carbon-density maps. **Nature climate change**, Nature Publishing Group, v. 2, n. 3, p. 182–185, 2012.

BAENA, S.; MOAT, J.; WHALEY, O.; BOYD, D. S. Identifying species from the air: Uavs and the very high resolution challenge for plant conservation. **PloS one**, Public Library of Science, v. 12, n. 11, p. e0188714, 2017.

BELGIU, M.; DRĂGUȚ, L. Comparing supervised and unsupervised multiresolution segmentation approaches for extracting buildings from very high resolution imagery. **ISPRS Journal of Photogrammetry and Remote Sensing**, Elsevier, v. 96, p. 67–75, 2014.

BELMONTE, A.; SANKEY, T.; BIEDERMAN, J. A.; BRADFORD, J.; GOETZ, S. J.; KOLB, T.; WOOLLEY, T. **Remote Sensing in Ecology and Conservation**, Wiley Online Library, v. 6, n. 2, p. 181–197, 2020.

BENAYAS, J. M. R.; BULLOCK, J. M.; NEWTON, A. C. Creating woodland islets to reconcile ecological restoration, conservation, and agricultural land use. **Frontiers in Ecology and the Environment**, Wiley Online Library, v. 6, n. 6, p. 329–336, 2008.

BERGADO, J. R.; PERSELLO, C.; GEVAERT, C. A deep learning approach to the classification of sub-decimetre resolution aerial images. In: IEEE. **2016 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)**. [S.l.], 2016. p. 1516–1519.

BERNI, J. A.; ZARCO-TEJADA, P. J.; SUÁREZ, L.; FERERES, E. Thermal and narrowband multispectral remote sensing for vegetation monitoring from an unmanned aerial vehicle. **IEEE Transactions on Geoscience and Remote Sensing**, IEEE, v. 47, n. 3, p. 722–738, 2009.

BLASCHKE, T. Object based image analysis for remote sensing. **ISPRS journal of photogrammetry and remote sensing**, Elsevier, v. 65, n. 1, p. 2–16, 2010.

BOURGOIN, C.; BETBEDER, J.; COUTERON, P.; BLANC, L.; DESSARD, H.; OSZWALD, J.; ROUX, R. L.; CORNU, G.; REYMONDIN, L.; MAZZEI, L. et al. Uav-based canopy textures assess changes in forest structure from long-term degradation. **Ecological Indicators**, Elsevier, v. 115, p. 106386, 2020.

BRAGA, J.; PERIPATO, V.; DALAGNOL, R.; FERREIRA, M.; TARABALKA, Y.; ARAGÃO, L.; VELHO, H. de C.; SHIGUEMORI, E.; WAGNER, F. Tree crown delineation algorithm based on a convolutional neural network. **Remote Sensing**, Multidisciplinary Digital Publishing Institute, v. 12, n. 8, p. 1288, 2020.

BRAGA, J. R. G.; VELHO, H. F. C.; SHIGUEMORI, E. H.; WAGNER, F. H. Algoritmo de delimitação de copas baseado em deep learning. In: GHERARDI, D. F. M.; SANCHES, I. D.; ARAGÃO, L. E. O. e Cruz de (Ed.). **Proceedings of Simpósio Brasileiro de Sensoriamento Remoto (SBSR)**, 19. [S.l.]: São José dos Campos: INPE, 2019. p. 1366–1369.

BRANCALION, P. H.; PINTO, S. R.; PUGLIESE, L.; PADOVEZI, A.; RODRIGUES, R. R.; CALMON, M.; CARRASCOSA, H.; CASTRO, P.; MESQUITA, B. Governance innovations from a multi-stakeholder coalition to implement large-scale forest restoration in Brazil. **World Development Perspectives**, Elsevier, v. 3, p. 15–17, 2016.

BRANCALION, P. H.; SCHWEIZER, D.; GAUDARE, U.; MANGUEIRA, J. R.; LAMONATO, F.; FARAH, F. T.; NAVE, A. G.; RODRIGUES, R. R. Balancing economic costs and ecological outcomes of passive and active restoration in agricultural landscapes: the case of Brazil. **Biotropica**, Wiley Online Library, v. 48, n. 6, p. 856–867, 2016.

BRANCALION, P. H. S.; RODRIGUES, R. R.; GANDOLFI, S.; KAGEYAMA, P. Y.; NAVE, A. G.; GANDARA, F. B.; BARBOSA, L. M.; TABARELLI, M. Instrumentos legais podem contribuir para a restauração de florestas tropicais biodiversas. **Revista Árvore**, SciELO Brasil, v. 34, n. 3, p. 455–470, 2010.

BRANCALION, P. H. S.; VIANI, R. A. G.; RODRIGUES, R. R.; GANDOLFI, S. Avaliação e monitoramento de áreas em processo de restauração. In: MARTINS, S. (Ed.). **Restauração ecológica de ecossistemas degradados**. Viçosa, MG: Editora UFV, 2012. p. 262–293. Available at <<[http://www.esalqlastrop.com.br/img/aulas/Cumbuca%206\(2\).pdf](http://www.esalqlastrop.com.br/img/aulas/Cumbuca%206(2).pdf)>>, Accessed on 2017-10-31.

BRANDT, M.; TUCKER, C. J.; KARIRYAA, A.; RASMUSSEN, K.; ABEL, C.; SMALL, J.; CHAVE, J.; RASMUSSEN, L. V.; HIERNAUX, P.; DIOUF, A. A. et al. An unexpectedly large count of trees in the west African Sahara and Sahel. **Nature**, Nature Publishing Group, v. 587, n. 7832, p. 78–82, 2020.

BREIMAN, L. Out-of-bag estimation. Citeseer, 1996. Available at <<<http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.45.3712&rep=rep1&type=pdf>>>, Accessed on 2019-09-07.

BURSLEM, D. F. R. P.; SWAINE, M. D. Forest dynamics and regeneration. In: **Foundations of Tropical Forest Biology** (eds. Chazdon, RL; Whitmore, TC), University of Chicago Press. [S.l.: s.n.], 2002. p. 577–583.

BURTON, P. J.; MACDONALD, S. E. The restorative imperative: challenges, objectives and approaches to restoring naturalness in forests. **Silva Fennica**, v. 45, n. 5, 2011.

CALMON, M.; BRANCALION, P. H.; PAESE, A.; ARONSON, J.; CASTRO, P.; SILVA, S. C. da; RODRIGUES, R. R. Emerging threats and opportunities for large-scale ecological restoration in the atlantic forest of brazil. **Restoration Ecology**, Wiley Online Library, v. 19, n. 2, p. 154–158, 2011.

CAMARRETTA, N.; HARRISON, P. A.; BAILEY, T.; POTTS, B.; LUCIEER, A.; DAVIDSON, N.; HUNT, M. Monitoring forest structure to guide adaptive management of forest restoration: a review of remote sensing approaches. **New Forests**, Springer, v. 51, n. 4, p. 573–596, 2020.

CASTILLO, M.; RIVARD, B.; SÁNCHEZ-AZOFEIFA, A.; CALVO-ALVARADO, J.; DUBAYAH, R. Lidar remote sensing for secondary tropical dry forest identification. **Remote sensing of environment**, Elsevier, v. 121, p. 132–143, 2012.

CASTRO, J.; MORALES-RUEDA, F.; NAVARRO, F. B.; LÖF, M.; VACCHIANO, G.; ALCARAZ-SEGURA, D. Precision restoration: a necessary approach to foster forest recovery in the 21st century. **Restoration Ecology**, v. 29, n. 7, p. e13421, 2021. Disponível em: <<https://onlinelibrary.wiley.com/doi/abs/10.1111/rec.13421>>.

CHAVES, R. B.; DURIGAN, G.; BRANCALION, P. H.; ARONSON, J. On the need of legal frameworks for assessing restoration projects success: new perspectives from são paulo state (brazil). **Restoration Ecology**, Wiley Online Library, v. 23, n. 6, p. 754–759, 2015.

CHAZDON, R. L. Beyond deforestation: restoring forests and ecosystem services on degraded lands. **science**, American Association for the Advancement of Science, v. 320, n. 5882, p. 1458–1460, 2008.

CHAZDON, R. L.; BRANCALION, P. H.; LAESTADIUS, L.; BENNETT-CURRY, A.; BUCKINGHAM, K.; KUMAR, C.; MOLL-ROCEK, J.; VIEIRA, I. C. G.; WILSON, S. J. When is a forest a forest? forest concepts and definitions in the era of forest and landscape restoration. **Ambio**, Springer, v. 45, n. 5, p. 538–550, 2016.

CHAZDON, R. L.; BRANCALION, P. H.; LAMB, D.; LAESTADIUS, L.; CALMON, M.; KUMAR, C. A policy-driven knowledge agenda for global forest and landscape restoration. **Conservation Letters**, Wiley Online Library, v. 10, n. 1, p. 125–132, 2017.

CHAZDON, R. L.; GUARIGUATA, M. R. Natural regeneration as a tool for large-scale forest restoration in the tropics: prospects and challenges. **Biotropica**, Wiley Online Library, v. 48, n. 6, p. 716–730, 2016.

CHEN, H.; CAI, Q. Impact of hillslope vegetation restoration on gully erosion induced sediment yield. **Science in China Series D**, Springer, v. 49, n. 2, p. 176–192, 2006.

CHEN, S.; MCDERMID, G.; CASTILLA, G.; LINKE, J. Measuring vegetation height in linear disturbances in the boreal forest with uav photogrammetry. **Remote Sensing**, Multidisciplinary Digital Publishing Institute, v. 9, n. 12, p. 1257, 2017.

CHOKKALINGAM, U.; JONG, W. D. Secondary forest: a working definition and typology. **The International Forestry Review**, JSTOR, p. 19–26, 2001.

- CHRISTAKOPOULOS, P.; PARONIS, D.; SCARVELIS, M.; KALABOKIDES, K.; HATZOPOULOS, I. Comparative evaluation of restoration practices applied to mediterranean forest ecosystems using remote sensing and gis: Natural regeneration versus reforestation. In: AYANZ, J. S.-M.; GITAS, I.; CAMIA, A.; OLIVEIRA, S. (Ed.). **Advances in Remote Sensing and GIS applications in Forest Fire Management From local to global assessments**. [S.l.]: European Commission: JRC Scientific and Technical Reports, 2011. p. 231–235.
- CIRNE, M. B.; SOUZA, A. G. S. M. de. Pousio: O que ee quais sao os seus possiveis reflexos nas questoes aamentais. **Veredas do Direito**, HeinOnline, v. 11, p. 75, 2014.
- CLAPUYT, F.; VANACKER, V.; OOST, K. V. Reproducibility of uav-based earth topography reconstructions based on structure-from-motion algorithms. **Geomorphology**, Elsevier, v. 260, p. 4–15, 2016.
- COLOMINA, I.; MOLINA, P. Unmanned aerial systems for photogrammetry and remote sensing: A review. **ISPRS Journal of photogrammetry and remote sensing**, Elsevier, v. 92, p. 79–97, 2014.
- CONGALTON, R. G. A review of assessing the accuracy of classifications of remotely sensed data. **Remote sensing of environment**, Elsevier, v. 37, n. 1, p. 35–46, 1991.
- CONGALTON, R. G.; MEAD, R. A. A quantitative method to test for consistency and correctness in photointerpretation. **Photogrammetric Engineering and Remote Sensing**, Maryland, v. 49, n. 1, p. 69–74, 1983.
- CROUZEILLES, R.; SANTIAMI, E.; ROSA, M.; PUGLIESE, L.; BRANCALION, P. H.; RODRIGUES, R. R.; METZGER, J. P.; CALMON, M.; SCARAMUZZA, C. A. d. M.; MATSUMOTO, M. H. et al. There is hope for achieving ambitious atlantic forest restoration commitments. **Perspectives in Ecology and Conservation**, Elsevier, v. 17, n. 2, p. 80–83, 2019.
- DALLING, J. W.; HUBBELL, S. P. Seed size, growth rate and gap microsite conditions as determinants of recruitment success for pioneer species. **Journal of Ecology**, Wiley Online Library, v. 90, n. 3, p. 557–568, 2002.
- DALPONTE, M. **itcSegment: individual tree crowns segmentation**. 2018. Available at <<https://cran.r-project.org/web/packages/itcSegment/index.html>>, Accessed on 2019-09-03.
- DALPONTE, M.; FRIZZERA, L.; GIANELLE, D. Individual tree crown delineation and tree species classification with hyperspectral and lidar data. **PeerJ**, PeerJ Inc., v. 6, p. e6227, 2019.
- DAMASCENO, G.; SOUZA, L.; PIVELLO, V. R.; GORGONE-BARBOSA, E.; GIROLDO, P. Z.; FIDELIS, A. Impact of invasive grasses on cerrado under natural regeneration. **Biological Invasions**, Springer, v. 20, n. 12, p. 3621–3629, 2018.
- DANDOIS, J.; OLANO, M.; ELLIS, E. Optimal altitude, overlap, and weather conditions for computer vision uav estimates of forest structure. **Remote Sensing**, Multidisciplinary Digital Publishing Institute, v. 7, n. 10, p. 13895–13920, 2015.



DELLASALA, D.; MARTIN, A.; SPIVAK, R.; SCHULKE, T.; BIRD, B.; CRILEY, M.; DAALEN, C. van; KREILICK, J.; BROWN, R.; APLET, G. A citizen's call for ecological forest restoration: Forest restoration principles and criteria. **Ecological Restoration**, University of Wisconsin Press, v. 21, n. 1, p. 15, 2003.

DELUCA, T. H.; APLET, G. H.; WILMER, B.; BURCHFIELD, J. The unknown trajectory of forest restoration: a call for ecosystem monitoring. **Journal of Forestry**, Oxford University Press, v. 108, n. 6, p. 288–295, 2010.

DENSLOW, J. S.; CHAZDON, R. L. Ecosystem ecology in the tropics. In: **In: Foundations of Tropical Forest Biology (eds. Chazdon, RL; Whitmore, TC)**, University of Chicago Press. [S.l.: s.n.], 2002. p. 639–645.

DICK, G.; SCHUMACHER, M. V.; MOMOLLI, D. R. **Estratégias para a restauração de área de preservação permanente no bioma Pampa**. 2016. Available at <[https://www.researchgate.net/publication/315774871 ESTRATEGIAS\\_PARA\\_A\\_RESTAURACAO\\_DE\\_AREA\\_DE\\_PRESERVACAO\\_PERMANENTE\\_NO\\_BIOMA\\_PAMPA](https://www.researchgate.net/publication/315774871 ESTRATEGIAS_PARA_A_RESTAURACAO_DE_AREA_DE_PRESERVACAO_PERMANENTE_NO_BIOMA_PAMPA)>, Accessed on 2019-08-09.

DICKINSON, Y.; PELZ, K.; GILES, E.; HOWIE, J. Have we been successful? monitoring horizontal forest complexity for forest restoration projects. **Restoration ecology**, Wiley Online Library, v. 24, n. 1, p. 8–17, 2016.

DIEESE. **ESTATÍSTICAS, DO MEIO RURAL 2010-2011**. [S.l.], 2011. Available at <<[http://bibspi.planejamento.gov.br/bitstream/handle/iditem/707/Estatisticas\\_Meio\\_Rural\\_2011.pdf?sequence=3](http://bibspi.planejamento.gov.br/bitstream/handle/iditem/707/Estatisticas_Meio_Rural_2011.pdf?sequence=3)>>, Accessed on 2019-07-10.

DING, Z.; LI, R.; O'CONNOR, P.; ZHENG, H.; HUANG, B.; KONG, L.; XIAO, Y.; XU, W.; OUYANG, Z. An improved quality assessment framework to better inform large-scale forest restoration management. **Ecological Indicators**, Elsevier, v. 123, p. 107370, 2021.

DJI. **Phantom 4PRO**. 2022. <<https://www.dji.com/br/phantom-4-pro>>. Accessed: 2022-01-12.

DRONESMADEEASY. **Map Pilot for DJI**. 2020. Disponível em: <<https://support.dronesmadeeasy.com/hc/en-us/categories/200739936-Map-Pilot-for-iOS>>.

DUARTE, L.; SILVA, P.; TEODORO, A. Development of a qgis plugin to obtain parameters and elements of plantation trees and vineyards with aerial photographs. **ISPRS International Journal of Geo-Information**, Multidisciplinary Digital Publishing Institute, v. 7, n. 3, p. 109, 2018.

DUBAYAH, R. O.; DRAKE, J. B. Lidar remote sensing for forestry. **Journal of Forestry**, Oxford University Press, v. 98, n. 6, p. 44–46, 2000.

DUFOUR, S.; BERNEZ, I.; BETBEDER, J.; CORGNE, S.; HUBERT-MOY, L.; NABUCET, J.; RAPINEL, S.; SAWTSCHUK, J.; TROLLÉ, C. Monitoring restored riparian vegetation: how can recent developments in remote sensing sciences help? **Knowledge and Management of Aquatic Ecosystems**, EDP Sciences, n. 410, p. 10, 2013.

DULTRA, F. A.; SAMPAIO, J. A. B.; JR, A. T. A.; MATOS, M. C. L.; SANTOS, É. M.; LIMA, D. S. V.; CARVALHO, F. P. **Plano de Recuperação da Área Degradada como condicionante da Implantação do Hospital do Subúrbio - Salvador, Bahia.** [S.l.], 2009. Available at <<[http://www1.saude.ba.gov.br/hospitaldosuburbio/docs/PRAD\\_COSMOS\\_FINAL\\_V1.pdf](http://www1.saude.ba.gov.br/hospitaldosuburbio/docs/PRAD_COSMOS_FINAL_V1.pdf)>>, Accessed on 2019-07-10.

DURIGAN, G.; ENGEL, V. L.; TOREZAN, J. M.; MELO, A. C. G. de; MARQUES, M. C. M.; MARTINS, S. V.; REIS, A.; SCARANO, F. R. Normas jurídicas para a restauração ecológica: uma barreira a mais a dificultar o êxito das iniciativas? **Revista Árvore**, SciELO Brasil, v. 34, n. 3, p. 471–485, 2010.

DURIGAN, G.; GUERIN, N.; COSTA, J. N. M. N. da. Ecological restoration of xingu basin headwaters: motivations, engagement, challenges and perspectives. **Philosophical Transactions of the Royal Society B: Biological Sciences**, The Royal Society, v. 368, n. 1619, p. 20120165, 2013.

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. d. C.; JUNIOR, L.; ALBUQUERQUE, R. W.; BRANCALION, P. H. S.; WILKINSON, B.; COSTA, M. Oliveira-da. Aboveground biomass estimation in amazonian tropical forests: a comparison of aircraft- and gatereye uav-borne lidar data in the chico mendes extractive reserve in acre, brazil. **Remote Sensing**, v. 12, n. 11, 2020. ISSN 2072-4292. Disponível em: <<https://www.mdpi.com/2072-4292/12/11/1754>>.

EISENBEISS, H. **UAV photogrammetry.** Tese (Doutorado) — ETH Zurich, Suíça, 2009.

ELLIOTT, S. The potential for automating assisted natural regeneration of tropical forest ecosystems. **Biotropica**, Wiley Online Library, v. 48, n. 6, p. 825–833, 2016.

EVANS, J. Soil and water management aspects of forestation. **Strategies and designs for afforestation, reforestation and tree planting**, p. 96–114, 1984.

FERNANDES, R. T. V. **Recuperação de Manguezais.** 1. ed. [S.l.]: Rio de Janeiro: Interciência, 2012. 78 p.

FERREIRA, J.; LENNOX, G. D.; GARDNER, T. A.; THOMSON, J. R.; BERENQUER, E.; LEES, A. C.; NALLY, R. M.; ARAGÃO, L. E.; FERRAZ, S. F.; LOUZADA, J. et al. Carbon-focused conservation may fail to protect the most biodiverse tropical forests. **Nature Climate Change**, Nature Publishing Group, v. 8, n. 8, p. 744–749, 2018.

FERREIRA, M. P.; ALMEIDA, D. R. A. de; PAPA, D. de A.; MINERVINO, J. B. S.; VERAS, H. F. P.; FORMIGHIERI, A.; SANTOS, C. A. N.; FERREIRA, M. A. D.; FIGUEIREDO, E. O.; FERREIRA, E. J. L. Individual tree detection and species classification of amazonian palms using uav images and deep learning. **Forest Ecology and Management**, Elsevier, v. 475, p. 118397, 2020.

FERRER-GONZÁLEZ, E.; AGÜERA-VEGA, F.; CARVAJAL-RAMÍREZ, F.; MARTÍNEZ-CARRICONDO, P. Uav photogrammetry accuracy assessment for corridor mapping based on the number and distribution of ground control points. **Remote Sensing**, Multidisciplinary Digital Publishing Institute, v. 12, n. 15, p. 2447, 2020.

FERRETTI, A. Fundamentos ecológicos para o planejamento da restauração florestal. In: GALVÃO, A. P. M.; MEDEIROS, A. C. d. S. (Ed.). **A restauração da mata atlântica em áreas de sua primitiva ocorrência natural**. Colombo, PR: Embrapa Florestas, 2002. p. 21–26.

FIGUEIREDO, E. O.; D'OLIVEIRA, M. V. N.; BRAZ, E. M.; PAPA, D. de A.; FEARNside, P. M. Lidar-based estimation of bole biomass for precision management of an amazonian forest: Comparisons of ground-based and remotely sensed estimates. **Remote Sensing of Environment**, Elsevier, v. 187, p. 281–293, 2016.

FIGUEIREDO, E. O.; FIGUEIREDO, S. d. M. **Planos de voo semiautônomos para fotogrametria com aeronaves remotamente pilotadas de classe 3**. [S.l.], 2018. Available at <<<https://ainfo.cnptia.embrapa.br/digital/bitstream/item/187874/1/26750.pdf>>>, Accessed on 2021-03-23.

FILOTAS, E.; PARROTT, L.; BURTON, P. J.; CHAZDON, R. L.; COATES, K. D.; COLL, L.; HAEUSSLER, S.; MARTIN, K.; NOCENTINI, S.; PUETTMANN, K. J. et al. Viewing forests through the lens of complex systems science. **Ecosphere**, Wiley Online Library, v. 5, n. 1, p. 1–23, 2014.

FLORENZANO, T. G. **Imagens de satélite para estudos ambientais**. São Paulo: Oficina de Textos, 2002. 97 p.

FORTIN, M.; DEBLOIS, J. A statistical estimator to propagate height prediction errors into a general volume model. **Canadian journal of forest research**, NRC Research Press, v. 40, n. 10, p. 1930–1939, 2010.

FRASER, E. D.; DOUGILL, A. J.; MABEE, W. E.; REED, M.; MCALPINE, P. Bottom up and top down: Analysis of participatory processes for sustainability indicator identification as a pathway to community empowerment and sustainable environmental management. **Journal of environmental management**, Elsevier, v. 78, n. 2, p. 114–127, 2006.

FREITAS, M. G.; RODRIGUES, S. B.; CAMPOS-FILHO, E. M.; CARMO, G. H. P. do; VEIGA, J. M. da; JUNQUEIRA, R. G. P.; VIEIRA, D. L. M. Evaluating the success of direct seeding for tropical forest restoration over ten years. **Forest ecology and management**, Elsevier, v. 438, p. 224–232, 2019.

GADELHA, B. de Q.; FERRAZ, A. C. P.; AGUIAR, V. M. A importância dos me-sembrinelíneos (diptera: Calliphoridae) e seu potencial como indicadores de preservação ambiental. **Oecologia Brasiliensis**, Universidade Federal do Estado do Rio de Janeiro (UNIRIO), v. 13, n. 4, p. 660–664, 2009.

GAGEIK, N.; BENZ, P.; MONTENEGRO, S. Obstacle detection and collision avoidance for a uav with complementary low-cost sensors. **IEEE Access**, IEEE, v. 3, p. 599–609, 2015.

GETZIN, S.; WIEGAND, K.; SCHÖNING, I. Assessing biodiversity in forests using very high-resolution images and unmanned aerial vehicles. **Methods in ecology and evolution**, Wiley Online Library, v. 3, n. 2, p. 397–404, 2012.

- GINI, R.; PASSONI, D.; PINTO, L.; SONA, G. Aerial images from an uav system: 3d modeling and tree species classification in a park area. **International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. 39, n. B1, p. 361–366, 2012.
- GINI, R.; PASSONI, D.; PINTO, L.; SONA, G. Use of unmanned aerial systems for multispectral survey and tree classification: A test in a park area of northern italy. **European Journal of Remote Sensing**, Taylor & Francis, v. 47, n. 1, p. 251–269, 2014.
- GISLASON, P. O.; BENEDIKTSSON, J. A.; SVEINSSON, J. R. Random forests for land cover classification. **Pattern Recognition Letters**, Elsevier, v. 27, n. 4, p. 294–300, 2006.
- GODFRAY, H. C. J. Challenges for taxonomy. **Nature**, Nature Publishing Group, v. 417, n. 6884, p. 17–19, 2002.
- GODOY, R.; LUBOWSKI, R.; MARKANDYA, A. A method for the economic valuation of non-timber tropical forest products. **Economic botany**, Springer, v. 47, n. 3, p. 220–233, 1993.
- GOODBODY, T. R.; COOPS, N. C.; HERMOSILLA, T.; TOMPALSKI, P.; CRAWFORD, P. Assessing the status of forest regeneration using digital aerial photogrammetry and unmanned aerial systems. **International journal of remote sensing**, Taylor & Francis, v. 39, n. 15-16, p. 5246–5264, 2018.
- GOUTTE, C.; GAUSSIER, E. A probabilistic interpretation of precision, recall and f-score, with implication for evaluation. In: SPRINGER. **European Conference on Information Retrieval**. Heidelberg, 2005. p. 345–359.
- GUARIGUATA, M.; BRANCALION, P. Current challenges and perspectives for governing forest restoration. **Forests**, Multidisciplinary Digital Publishing Institute, v. 5, n. 12, p. 3022–3030, 2014.
- GUARIGUATA, M. R.; OSTERTAG, R. Neotropical secondary forest succession: changes in structural and functional characteristics. **Forest ecology and management**, Elsevier, v. 148, n. 1-3, p. 185–206, 2001.
- GUTH, P. L.; NIEKERK, A. V.; GROHMANN, C. H.; MULLER, J.-P.; HAWKER, L.; FLORINSKY, I. V.; GESCH, D.; REUTER, H. I.; HERRERA-CRUZ, V.; RIAZANOFF, S.; LÓPEZ-VÁZQUEZ, C.; CARABAJAL, C. C.; ALBINET, C.; STROBL, P. Digital elevation models: Terminology and definitions. **Remote Sensing**, v. 13, n. 18, 2021. ISSN 2072-4292. Disponível em: <<https://www.mdpi.com/2072-4292/13/18/3581>>.
- HAALA, N.; CRAMER, M.; ROTHERMEL, M. Quality of 3d point clouds from highly overlapping uav imagery. **Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci.**, p. 183–188, 2013.
- HAMAMURA, C.; MENDES, F. H.; POLIZEL, J. L.; FILHO, D. F. da S. Identificação de espécies arbóreas a partir de imagem de sensoriamento remoto. In: GHERARDI, D. F. M.; SANCHES, I. D.; ARAGÃO, L. E. O. e Cruz de (Ed.). **Proceedings of Simpósio Brasileiro de Sensoriamento Remoto (SBSR)**, 19. [S.l.]: São José dos Campos: INPE, 2019. p. 3120–3123.

- HANDEL, S. N. The role of plant-animal mutualisms in the design and restoration of natural communities. In: URBANSKA, K. M.; WEBB, N. R.; EDWARDS, P. J. (Ed.). **Restoration ecology and sustainable development**. Cambridge, UK: Cambridge University Press, 1997. p. 111–132.
- HANSEN, M. C.; POTAPOV, P. V.; MOORE, R.; HANCHER, M.; TURUBANOVA, S.; TYUKAVINA, A.; THAU, D.; STEHMAN, S.; GOETZ, S.; LOVELAND, T. R. et al. High-resolution global maps of 21st-century forest cover change. **science**, American Association for the Advancement of Science, v. 342, n. 6160, p. 850–853, 2013.
- HARVEY, C. A.; MEDINA, A.; SÁNCHEZ, D. M.; VÍLCHEZ, S.; HERNÁNDEZ, B.; SAENZ, J. C.; MAES, J. M.; CASANOVES, F.; SINCLAIR, F. L. Patterns of animal diversity in different forms of tree cover in agricultural landscapes. **Ecological applications**, Wiley Online Library, v. 16, n. 5, p. 1986–1999, 2006.
- HASAN, A. F.; LAURENT, F.; BLANC, L.; MESSNER, F. The use of landsat time series for identification of forest degradation levels in the eastern brazilian amazon (paragominas). In: IEEE. **2017 9th International Workshop on the Analysis of Multitemporal Remote Sensing Images (MultiTemp)**. [S.l.], 2017. p. 1–4.
- HE, J.; LI, Y.; ZHANG, K. Research of uav flight planning parameters. **Positioning**, Scientific Research Publishing, v. 3, n. 04, p. 43, 2012.
- HE, K.; GKIOXARI, G.; DOLLÁR, P.; GIRSHICK, R. Mask r-cnn. In: COMPUTER VISION FOUNDATION (CVF). **Proceedings of the IEEE International Conference on Computer Vision (ICCV)**. Venice, Italy, 2017. p. 2961–2969.
- HIGGS, A. Island biogeography theory and nature reserve design. **Journal of Biogeography**, JSTOR, p. 117–124, 1981.
- HILDERBRAND, R. H.; WATTS, A. C.; RANDLE, A. M. The myths of restoration ecology. **Ecology and society**, Resilience Alliance, v. 10, n. 1, 2005.
- HOLL, K. D. Tropical moist forest restoration. **Handbook of ecological restoration**, Cambridge University Press Cambridge, UK, v. 2, p. 539–558, 2002.
- HONGYA, H.; LIHAI, W.; HUADONG, X.; SHIQUAN, S.; TIANYONG, S. Error analysis of tree height estimation based on eye measurement. **Forest Engineering**, v. 28, n. 2, p. 6–8, 2012.
- HOWE, H. F. Implications of seed dispersal by animals for tropical reserve management. **Biological Conservation**, Elsevier, v. 30, n. 3, p. 261–281, 1984.
- HUNT, E. R.; DORAISWAMY, P. C.; MCMURTREY, J. E.; DAUGHTRY, C. S.; PERRY, E. M.; AKHMEDOV, B. A visible band index for remote sensing leaf chlorophyll content at the canopy scale. **International Journal of Applied Earth Observation and Geoinformation**, Elsevier, v. 21, p. 103–112, 2013.
- HUNT, E. R.; HIVELY, W. D.; FUJIKAWA, S.; LINDEN, D.; DAUGHTRY, C. S.; MCCARTY, G. Acquisition of nir-green-blue digital photographs from unmanned aircraft for crop monitoring. **Remote Sensing**, Molecular Diversity Preservation International, v. 2, n. 1, p. 290–305, 2010.

III, F. S. C.; ZAVALA, E. S.; EVINER, V. T.; NAYLOR, R. L.; VITOUSEK, P. M.; REYNOLDS, H. L.; HOOPER, D. U.; LAVOREL, S.; SALA, O. E.; HOBBIE, S. E.; MACK, M. C.; DÍAZ, S. Consequences of changing biodiversity. **Nature**, Nature Publishing Group, v. 405, n. 6783, p. 234, 2000.

IVERSEN, G. R.; NORPOTH, H.; NORPOTH, H. P. **Analysis of variance**. [S.l.]: Sage, 1987.

JAAFAR, W. W. M.; WOODHOUSE, I.; SILVA, C.; OMAR, H.; MAULUD, K. A.; HUDAK, A.; KLAUBERG, C.; CARDIL, A.; MOHAN, M. Improving individual tree crown delineation and attributes estimation of tropical forests using airborne lidar data. **Forests**, Multidisciplinary Digital Publishing Institute, v. 9, n. 12, p. 759, 2018.

JAENICKE, J.; ENGLHART, S.; SIEGERT, F. Monitoring the effect of restoration measures in indonesian peatlands by radar satellite imagery. **Journal of Environmental Management**, Elsevier, v. 92, n. 3, p. 630–638, 2011.

JAIMES, A.; KOTA, S.; GOMEZ, J. An approach to surveillance an area using swarm of fixed wing and quad-rotor unmanned aerial vehicles uav (s). In: IEEE. **2008 IEEE International Conference on System of Systems Engineering**. [S.l.], 2008. p. 1–6.

JAKOVAC, C. C.; BONGERS, F.; KUYPER, T. W.; MESQUITA, R. C.; PEÑA-CLAROS, M. Land use as a filter for species composition in amazonian secondary forests. **Journal of Vegetation Science**, Wiley Online Library, v. 27, n. 6, p. 1104–1116, 2016.

JAMES, S. A.; SOLTIS, P. S.; BELBIN, L.; CHAPMAN, A. D.; NELSON, G.; PAUL, D. L.; COLLINS, M. Herbarium data: Global biodiversity and societal botanical needs for novel research. **Applications in plant sciences**, Wiley Online Library, v. 6, n. 2, p. e1024, 2018.

JENSEN, J. R. **Introductory digital image processing: a remote sensing perspective**. [S.l.]: Prentice Hall Press, 2015.

JING, L.; HU, B.; NOLAND, T.; LI, J. An individual tree crown delineation method based on multi-scale segmentation of imagery. **ISPRS Journal of Photogrammetry and Remote Sensing**, Elsevier, v. 70, p. 88–98, 2012.

JUCKER, T.; CASPERSEN, J.; CHAVE, J.; ANTIN, C.; BARBIER, N.; BONGERS, F.; DALPONTE, M.; EWIJK, K. Y. van; FORRESTER, D. I.; HAENI, M. et al. Allometric equations for integrating remote sensing imagery into forest monitoring programmes. **Global change biology**, Wiley Online Library, v. 23, n. 1, p. 177–190, 2017.

JUNIOR, C. H. S.; CELENTANO, D.; ROUSSEAU, G. X.; MOURA, E. G. de; VARGA, I. van D.; MARTINEZ, C.; MARTINS, M. B. Amazon forest on the edge of collapse in the maranhão state, brazil. **Land use policy**, Elsevier, v. 97, p. 104806, 2020.

JÚNIOR, L. R. A.; FERREIRA, M. E.; CÔRTEZ, J. B. R.; JORGE, L. A. de C. High accuracy mapping with cartographic assessment for a fixed-wing remotely piloted aircraft system. **Journal of Applied Remote Sensing**, International Society for Optics and Photonics, Bellingham, WA, v. 12, n. 1, p. 014003, 2018.

- KALLIOLA, S.; NAKARI, R.; PESONEN, I. Learning to make changes: Democratic dialogue in action. **Journal of Workplace Learning**, Emerald Group Publishing Limited, 2006.
- KEETON, W. S. Evaluation of tree seedling mortality and protective strategies in riparian forest restoration. **Northern Journal of Applied Forestry**, Oxford University Press, v. 25, n. 3, p. 117–123, 2008.
- KHUMAN, M. M. B. Classification of remote sensing data using k-nn method. **J. Inf. Knowl. Res. Electron. Commun. Eng**, v. 2, p. 817–821, 2013.
- KNOTH, C.; KLEIN, B.; PRINZ, T.; KLEINEBECKER, T. Unmanned aerial vehicles as innovative remote sensing platforms for high-resolution infrared imagery to support restoration monitoring in cut-over bogs. **Applied vegetation science**, Wiley Online Library, v. 16, n. 3, p. 509–517, 2013.
- KOVÁČSOVÁ, P.; ANTALOVÁ, M. Precision forestry—definition and technologies. **Šumarski list**, Hrvatsko šumarsko društvo, v. 134, n. 11-12, p. 603–610, 2010.
- KRAUSE, S.; SANDERS, T. G.; MUND, J.-P.; GREVE, K. Uav-based photogrammetric tree height measurement for intensive forest monitoring. **Remote sensing**, Multidisciplinary Digital Publishing Institute, v. 11, n. 7, p. 758, 2019.
- LAESTADIUS, L.; MAGINNIS, S.; MINNEMEYER, S.; POTAPOY, P.; SAINT-LAURENT, C.; SIZER, N. et al. Mapping opportunities for forest landscape restoration. **Unasylva (English ed.)**, Food and Agriculture Organization of the United Nations (FAO), v. 62, n. 238, p. 47–48, 2011.
- LALIBERTE, A. S.; BROWNING, D.; RANGO, A. A comparison of three feature selection methods for object-based classification of sub-decimeter resolution ultracam-l imagery. **International Journal of Applied Earth Observation and Geoinformation**, Elsevier, v. 15, p. 70–78, 2012.
- LAU, A.; CALDERS, K.; BARTHOLOMEUS, H.; MARTIUS, C.; RAUMONEN, P.; HEROLD, M.; VICARI, M.; SUKHDEO, H.; SINGH, J.; GOODMAN, R. C. Tree biomass equations from terrestrial lidar: A case study in guyana. **Forests**, Multidisciplinary Digital Publishing Institute, v. 10, n. 6, p. 527, 2019.
- LE, H. D.; SMITH, C.; HERBOHN, J.; HARRISON, S. More than just trees: assessing reforestation success in tropical developing countries. **Journal of Rural Studies**, Elsevier, v. 28, n. 1, p. 5–19, 2012.
- LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. **nature**, Nature Publishing Group, v. 521, n. 7553, p. 436–444, 2015.
- LEEUEWEN, W. V. Monitoring the effects of forest restoration treatments on post-fire vegetation recovery with modis multitemporal data. **Sensors**, Molecular Diversity Preservation International, v. 8, n. 3, p. 2017–2042, 2008.
- LEFSKY, M. A.; COHEN, W. B.; PARKER, G. G.; HARDING, D. J. Lidar remote sensing for ecosystem studies: Lidar, an emerging remote sensing technology that directly measures the three-dimensional distribution of plant canopies, can accurately estimate

vegetation structural attributes and should be of particular interest to forest, landscape, and global ecologists. **BioScience**, American Institute of Biological Sciences, v. 52, n. 1, p. 19–30, 2002.

LEWIS, R. Methods and criteria for successful mangrove forest restoration. **Coastal Wetlands: An Integrated Ecosystem Approach**, 1st edn. (Eds G. Perillo, E. Wolanski, D. Cahoon, and M. Brinson.) pp, Citeseer, p. 787–800, 2009.

LIEBSCH, D.; MARQUES, M. C.; GOLDENBERG, R. How long does the atlantic rain forest take to recover after a disturbance? changes in species composition and ecological features during secondary succession. **Biological Conservation**, Elsevier, v. 141, n. 6, p. 1717–1725, 2008.

LILLESAND, T.; KIEFER, R. W.; CHIPMAN, J. **Remote sensing and image interpretation**. New York: John Wiley & Sons, 2015.

LIM, K.; TREITZ, P.; WULDER, M.; ST-ONGE, B.; FLOOD, M. Lidar remote sensing of forest structure. **Progress in physical geography**, Sage Publications Sage CA: Thousand Oaks, CA, v. 27, n. 1, p. 88–106, 2003.

LISEIN, J.; MICHEZ, A.; CLAESSENS, H.; LEJEUNE, P. Discrimination of deciduous tree species from time series of unmanned aerial system imagery. **PLoS One**, Public Library of Science, v. 10, n. 11, p. e0141006, 2015.

LISEIN, J.; PIERROT-DESEILLIGNY, M.; BONNET, S.; LEJEUNE, P. A photogrammetric workflow for the creation of a forest canopy height model from small unmanned aerial system imagery. **Forests**, Multidisciplinary Digital Publishing Institute, v. 4, n. 4, p. 922–944, 2013.

LIU, H.; DONG, P. A new method for generating canopy height models from discrete-return lidar point clouds. **Remote sensing letters**, Taylor & Francis, v. 5, n. 6, p. 575–582, 2014.

MANSOURIAN, S.; VALLAURI, D. Restoring forest landscapes: important lessons learnt. **Environmental Management**, Springer, v. 53, n. 2, p. 241–251, 2014.

MARTIN, L. M.; WILSEY, B. J. Assessing grassland restoration success: relative roles of seed additions and native ungulate activities. **Journal of Applied Ecology**, Wiley Online Library, v. 43, n. 6, p. 1098–1109, 2006.

MARTINS, A. C.; WILLIG, M. R.; PRESLEY, S. J.; MARINHO-FILHO, J. Effects of forest height and vertical complexity on abundance and biodiversity of bats in amazonia. **Forest Ecology and Management**, Elsevier, v. 391, p. 427–435, 2017.

MARTINS, S. **Restauração ecológica de ecossistemas degradados**. [S.l.]: Viçosa: Editora UFV, 2012. 293 p.

MATZEK, V.; STELLA, J.; ROPION, P. Development of a carbon calculator tool for riparian forest restoration. **Applied Vegetation Science**, Wiley Online Library, v. 21, n. 4, p. 584–594, 2018.



- MAUS, V.; CÂMARA, G.; CARTAXO, R.; SANCHEZ, A.; RAMOS, F. M.; QUEIROZ, G. R. de. A time-weighted dynamic time warping method for land-use and land-cover mapping. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, IEEE, v. 9, n. 8, p. 3729–3739, 2016.
- MCDONALD, T.; GANN, G.; JONSON, J.; DIXON, K. **International standards for the practice of ecological restoration—including principles and key concepts**. [S.l.], 2016. Available at <<[http://www.seraustralasia.com/wheel/image/SER\\_International\\_Standards.pdf](http://www.seraustralasia.com/wheel/image/SER_International_Standards.pdf)>>, Accessed on 2019-08-09.
- MESQUITA, R. C.; ICKES, K.; GANADE, G.; WILLIAMSON, G. B. Alternative successional pathways in the amazon basin. **Journal of Ecology**, Wiley Online Library, v. 89, n. 4, p. 528–537, 2001.
- MESQUITA, R. d. C. G.; MASSOCA, P. E. d. S.; JAKOVAC, C. C.; BENTOS, T. V.; WILLIAMSON, G. B. Amazon rain forest succession: Stochasticity or land-use legacy? **BioScience**, Oxford University Press, v. 65, n. 9, p. 849–861, 2015.
- MEYER, T. H. **Introduction to geometrical and physical geodesy: foundations of geomatics**. [S.l.]: Esri Press, 2018.
- MEYFROIDT, P. Environmental cognitions, land change, and social–ecological feedbacks: An overview. **Journal of Land Use Science**, Taylor & Francis, v. 8, n. 3, p. 341–367, 2013.
- MICHELETTI, N.; CHANDLER, J. H.; LANE, S. N. Structure from motion (sfm) photogrammetry. British Society for Geomorphology, 2015.
- MICHEZ, A.; PIÉGAY, H.; LISEIN, J.; CLAESSENS, H.; LEJEUNE, P. Classification of riparian forest species and health condition using multi-temporal and hyperspatial imagery from unmanned aerial system. **Environmental monitoring and assessment**, Springer, v. 188, n. 146, 2016.
- MININGFACTS.ORG. **How can mining become more environmentally sustainable**. 2016. Disponível em: <<http://www.miningfacts.org/Environment/How-can-mining-become-more-environmentally-sustainable/>>.
- MIRANDA, E.; GUIMARÃES, M.; MIRANDA, J. Monitoramento do uso e cobertura das terras na região de barrinhas, jaboticabal e sertãozinho. **Embrapa Territorial-Séries anteriores (INFOTECA-E)**, Campinas: Embrapa Monitoramento por Satélite, 2002, 2002.
- MITRA, S.; PAL, S. K. Fuzzy multi-layer perceptron, inferencing and rule generation. **IEEE Transactions on Neural Networks**, IEEE, v. 6, n. 1, p. 51–63, 1995.
- MIYOSHI, G. T. **Caracterização espectral de espécies de Mata Atlântica de Interior em nível foliar e de copa**. Dissertação (Mestrado) — Universidade Estadual Paulista (UNESP), Brazil, 2016.
- MIYOSHI, G. T.; IMAI, N. N.; TOMMASELLI, A. M. G.; HONKAVAARA, E.; NÄSI, R.; MORIYA, É. A. S. Radiometric block adjustment of hyperspectral image blocks in the brazilian environment. **International journal of remote sensing**, Taylor & Francis, v. 39, n. 15-16, p. 4910–4930, 2018.

MOHAN, M.; LEITE, R. V.; BROADBENT, E. N.; JAAFAR, W. S. W. M.; SRINIVASAN, S.; BAJAJ, S.; CORTE, A. P. D.; AMARAL, C. H. do; GOPAN, G.; SAAD, S. N. M.; KAMARULZAMAN, A. M. M.; PRATA, G. A.; LEWELYN, E.; JOHNSON, D. J.; DOAEMO, W.; BOHLMAN, S.; ZAMBRANO, A. M. A.; CARDIL, A. Individual tree detection using uav-lidar and uav-sfm data: A tutorial for beginners. **Open Geosciences**, v. 13, n. 1, p. 1028–1039, 2021. Disponível em: <<https://doi.org/10.1515/geo-2020-0290>>.

MOHAN, M.; SILVA, C.; KLAUBERG, C.; JAT, P.; CATTS, G.; CARDIL, A.; HUDAK, A.; DIA, M. Individual tree detection from unmanned aerial vehicle (UAV) derived canopy height model in an open canopy mixed conifer forest. **Forests**, Multidisciplinary Digital Publishing Institute, v. 8, n. 9, p. 340, 2017.

MONICO, J. F. G. **Posicionamento pelo GNSS: descrição, fundamentos e aplicações**. [S.l.]: Editora Unesp, 2008.

MORAES, M. A. **Restauração de florestas e paisagens no Brasil. Brasília: UICN**. [S.l.], 2016. Available at <<<https://portals.iucn.org/library/sites/library/files/documents/2016-025.pdf>>>, Accessed on 2019-08-12.

MORAN, E. F.; PACKER, A.; BRONDIZIO, E.; TUCKER, J. Restoration of vegetation cover in the eastern amazon. **Ecological Economics**, Elsevier, v. 18, n. 1, p. 41–54, 1996.

MORRISON, E. B.; LINDELL, C. A. Active or passive forest restoration? assessing restoration alternatives with avian foraging behavior. **Restoration Ecology**, Wiley Online Library, v. 19, n. 201, p. 170–177, 2011.

MOURA, F. de B.; MALHADO, A. M.; LADLE, R. Nursing the caatinga back to health. **Journal of arid environments**, Elsevier, v. 90, p. 67–68, 2013.

MOURA, M. M.; OLIVEIRA, L. E. S. de; SANQUETTA, C. R.; BASTOS, A.; MOHAN, M.; CORTE, A. P. D. Towards amazon forest restoration: Automatic detection of species from uav imagery. **Remote Sensing**, v. 13, n. 13, 2021. ISSN 2072-4292. Disponível em: <<https://www.mdpi.com/2072-4292/13/13/2627>>.

MURADIAN, R.; CORBERA, E.; PASCUAL, U.; KOSOY, N.; MAY, P. H. Reconciling theory and practice: An alternative conceptual framework for understanding payments for environmental services. **Ecological economics**, Elsevier, v. 69, n. 6, p. 1202–1208, 2010.

MYERS, N.; MITTERMEIER, R. A.; MITTERMEIER, C. G.; FONSECA, G. A. D.; KENT, J. Biodiversity hotspots for conservation priorities. **Nature**, Nature Publishing Group, v. 403, n. 6772, p. 853, 2000.

NASCIMENTO, F. S.; GASTAUER, M.; SOUZA-FILHO, P. W. M.; NASCIMENTO, W. R.; SANTOS, D. C.; COSTA, M. F. Land cover changes in open-cast mining complexes based on high-resolution remote sensing data. **Remote Sensing**, v. 12, n. 4, 2020. ISSN 2072-4292. Disponível em: <<https://www.mdpi.com/2072-4292/12/4/611>>.

NÄSI, R.; HONKAVAARA, E.; LYYTIKÄINEN-SAARENMAA, P.; BLOMQVIST, M.; LITKEY, P.; HAKALA, T.; VILJANEN, N.; KANTOLA, T.; TANHUANPÄÄ, T.; HOLOPAINEN, M. Using uav-based photogrammetry and hyperspectral imaging for mapping bark beetle damage at tree-level. **Remote Sensing**, Multidisciplinary Digital Publishing Institute, v. 7, n. 11, p. 15467–15493, 2015.

NATIONAL SCIENCE FOUNDATION. **National Ecological Observatory Network (NEON)**. 2021. <<https://www.neonscience.org/resources/learning-hub/tutorials/introduction-light-detection-and-ranging-lidar-explore-point#toggle-0>>. Acesso em 2021-08-30.

NBL, E. A. L.; TNC, T. N. C. **Manual de restauração florestal: um instrumento de apoio à adequação ambiental de propriedades rurais do Pará**. [S.l.]: The Nature Conservancy, Belém, PA: TNC, 2013. 128 p. Disponível em <<<https://www.nature.org/media/brasil/manual-de-restauracao-florestal.pdf>>>, Acesso em 2021-10-05.

NERI, A. C.; SANCHEZ, L. E. **Guia de Boas Práticas de Recuperação Ambiental em Pedreiras e Minas de Calcário**. 1. ed. [S.l.]: São Paulo: Abge, 2012. 176 p.

NEVALAINEN, O.; HONKAVAARA, E.; TUOMINEN, S.; VILJANEN, N.; HAKALA, T.; YU, X.; HYYPPÄ, J.; SAARI, H.; PÖLÖNEN, I.; IMAI, N.; TOMMASSELLI, A. M. G. Individual tree detection and classification with uav-based photogrammetric point clouds and hyperspectral imaging. **Remote Sensing**, Multidisciplinary Digital Publishing Institute, v. 9, n. 3, p. 185, 2017.

NEZAMI, S.; KHORAMSHAHI, E.; NEVALAINEN, O.; PÖLÖNEN, I.; HONKAVAARA, E. Tree species classification of drone hyperspectral and rgb imagery with deep learning convolutional neural networks. **Remote Sensing**, Multidisciplinary Digital Publishing Institute, v. 12, n. 7, p. 1070, 2020.

NIE, Z.; LIU, F.; GAO, Y. Real-time precise point positioning with a low-cost dual-frequency gnss device. **Gps Solutions**, Springer, v. 24, n. 1, p. 1–11, 2020.

NORDSTROM, K. F. **Recuperação de praias e dunas**. 1. ed. [S.l.]: São Paulo: Oficina de textos, 2010. 263 p.

NOVO, E. de M. **Sensoriamento remoto: princípios e aplicações**. 3. ed. [S.l.]: São Paulo: Edgard Blücher, 2008. 372 p.

ODM. **OpenDroneMap - A command line toolkit to generate maps, point clouds, 3D models and DEMs from drone, balloon or kite images**. 2022. <<https://www.opendronemap.org/>>. Accessed: 2022-01-12.

OLIVEIRA, G. d. S.; CAVALCANTI, F. J. d. B.; MELO, L. A.; MONTE, M. A. O método de quadrantes para estimativa de variáveis quantitativas em planos de manejo na amazônia. **CERNE**, Universidade Federal de Lavras, v. 21, n. 4, p. 683–691, 2015.

OLTMANN, S. d'Oleire; MARZOLFF, I.; PETER, K.; RIES, J. Unmanned aerial vehicle (UAV) for monitoring soil erosion in morocco. **Remote Sensing**, Molecular Diversity Preservation International, v. 4, n. 11, p. 3390–3416, 2012.

OVERBECK, G. E.; VÉLEZ-MARTIN, E.; SCARANO, F. R.; LEWINSOHN, T. M.; FONSECA, C. R.; MEYER, S. T.; MÜLLER, S. C.; CEOTTO, P.; DADALT, L.; DURIGAN, G. et al. Conservation in Brazil needs to include non-forest ecosystems. **Diversity and Distributions**, Wiley Online Library, v. 21, n. 12, p. 1455–1460, 2015.

PARROTTA, J. A.; TURNBULL, J. W.; JONES, N. Catalyzing native forest regeneration on degraded tropical lands. **Forest Ecology and Management**, Elsevier, v. 99, n. 1-2, p. 1–7, 1997.

PEET, R. K. Changes in biomass and production during secondary forest succession. In: **Forest succession**. [S.l.]: Springer, 1981. p. 324–338.

PETTORELLI, N.; BÜHNE, H. Schulte to; TULLOCH, A.; DUBOIS, G.; MACINNIS-NG, C.; QUEIRÓS, A. M.; KEITH, D. A.; WEGMANN, M.; SCHRODT, F.; STELLMES, M. et al. Satellite remote sensing of ecosystem functions: opportunities, challenges and way forward. **Remote Sensing in Ecology and Conservation**, Wiley Online Library, v. 4, n. 2, p. 71–93, 2018.

PLANAVEG. **PLANO NACIONAL DE RECUPERAÇÃO DA VEGETAÇÃO NATIVA**. [S.l.], 2017. Available at <<[http://snif.florestal.gov.br/images/pdf/publicacoes/planaveg\\_publicacao.pdf](http://snif.florestal.gov.br/images/pdf/publicacoes/planaveg_publicacao.pdf)>>, Accessed on 2019-08-12.

POLEY, L. G.; MCDERMID, G. J. A systematic review of the factors influencing the estimation of vegetation aboveground biomass using unmanned aerial systems. **Remote Sensing**, Multidisciplinary Digital Publishing Institute, v. 12, n. 7, p. 1052, 2020.

POWELL, A. Democratizing production through open source knowledge: from open software to open hardware. **Media, Culture & Society**, Sage Publications Sage UK: London, England, v. 34, n. 6, p. 691–708, 2012.

PRANCE, G. T. A comparison of the efficacy of higher taxa and species numbers in the assessment of biodiversity in the neotropics. **Philosophical Transactions of the Royal Society of London. Series B: Biological Sciences**, The Royal Society London, v. 345, n. 1311, p. 89–99, 1994.

PRMA. **Protocolo de Monitoramento para Programas e Projetos de Restauração Florestal. Monitoring Protocol for Forest Restoration Programs & Projects**. [S.l.], 2013. Available at <<[http://media.wix.com/ugd/5da841\\_c228aedb71ae4221bc95b909e0635257.pdf](http://media.wix.com/ugd/5da841_c228aedb71ae4221bc95b909e0635257.pdf)>>, Accessed on 2019-07-10.

PROTHRO, J. W.; GRIGG, C. M. Fundamental principles of democracy: Bases of agreement and disagreement. **The Journal of Politics**, Southern Political Science Association, v. 22, n. 2, p. 276–294, 1960.

PULITI, S.; ØRKA, H.; GOBAKKEN, T.; NÆSSET, E. Inventory of small forest areas using an unmanned aerial system. **Remote Sensing**, Multidisciplinary Digital Publishing Institute, v. 7, n. 8, p. 9632–9654, 2015.

PUTZ, F. E.; REDFORD, K. H. The importance of defining ‘forest’: Tropical forest degradation, deforestation, long-term phase shifts, and further transitions. **Biotropica**, Wiley Online Library, v. 42, n. 1, p. 10–20, 2010.

- REAL, R.; VARGAS, J. M. The probabilistic basis of jaccard's index of similarity. **Systematic biology**, Society of Systematic Biologists, v. 45, n. 3, p. 380–385, 1996.
- REIF, M. K.; THEEL, H. J. Remote sensing for restoration ecology: Application for restoring degraded, damaged, transformed, or destroyed ecosystems. **Integrated environmental assessment and management**, Wiley Online Library, v. 13, n. 4, p. 614–630, 2017.
- REIS, B. P.; MARTINS, S. V.; FILHO, E. I. F.; SARCINELLI, T. S.; GLERIANI, J. M.; LEITE, H. G.; HALASSY, M. Forest restoration monitoring through digital processing of high resolution images. **Ecological engineering**, Elsevier, v. 127, p. 178–186, 2019.
- REIS, B. P.; MARTINS, S. V.; FILHO, E. I. F.; SARCINELLI, T. S.; GLERIANI, J. M.; MARCATTI, G. E.; LEITE, H. G.; HALASSY, M. Management recommendation generation for areas under forest restoration process through images obtained by uav and lidar. **Remote Sensing**, Multidisciplinary Digital Publishing Institute, v. 11, n. 13, p. 1508, 2019.
- RIBEIRO, J. F.; WALTER, B. M. T. As principais fitofisionomias do bioma cerrado. **Cerrado: ecologia e flora**, Embrapa Informação Tecnológica Brasília, v. 1, p. 151–212, 2008.
- RODRIGUES, R. R.; BRANCALION, P. H. S.; ISERNHAGEN, I. **referencial dos conceitos e ações de restauração florestal**. [S.l.], 2009. Available at <<<https://www.sosma.org.br/wp-content/uploads/2015/03/referencial-teorico.pdf>>>, Accessed on 2019-09-06.
- RODRIGUES, R. R.; GANDOLFI, S.; BRANCALION, P. H. S. **Restauração florestal**. [S.l.]: Oficina de Textos, 2015. 432 p.
- RODRIGUES, R. R.; ISERNHAGEM, I.; BRANCALION, P. H. S. **Pacto pela restauração da mata atlântica: referencial dos conceitos e ações de restauração florestal**. 1. ed. [S.l.]: – São Paulo: LERF/ESALQ : Instituto BioAtlântica, 2009. 256 p.
- ROSA, M. R.; BRANCALION, P. H.; CROUZEILLES, R.; TAMBOSI, L. R.; PIFFER, P. R.; LENTI, F. E.; HIROTA, M.; SANTIAMI, E.; METZGER, J. P. Hidden destruction of older forests threatens brazil's atlantic forest and challenges restoration programs. **Science advances**, American Association for the Advancement of Science, v. 7, n. 4, p. eabc4547, 2021.
- ROUHAN, G.; GAUDEUL, M. Plant taxonomy: a historical perspective, current challenges, and perspectives. In: **Molecular Plant Taxonomy**. [S.l.]: Springer, 2014. p. 1–37.
- RUGGIERO, P. G.; METZGER, J. P.; TAMBOSI, L. R.; NICHOLS, E. Payment for ecosystem services programs in the brazilian atlantic forest: Effective but not enough. **Land use policy**, Elsevier, v. 82, p. 283–291, 2019.
- RUIZ, L.; RECIO, J.; FERNÁNDEZ-SARRÍA, A.; HERMOSILLA, T. A feature extraction software tool for agricultural object-based image analysis. **Computers and Electronics in Agriculture**, Elsevier, v. 76, n. 2, p. 284–296, 2011.

SANKEY, T.; DONAGER, J.; MCVAY, J.; SANKEY, J. B. Uav lidar and hyperspectral fusion for forest monitoring in the southwestern usa. **Remote Sensing of Environment**, Elsevier, v. 195, p. 30–43, 2017.

SANTOS, A. D.; GALEÃO, P. The rural environmental registry (car) and the land grabbing strategies in the brazilian amazon. In: **VI Conference of BRICS Initiative of Critical Agrarian Studies**. [S.l.]: BRICS Initiative for Critical Agrarian Studies (BICAS), 2018. p. 27.

SANTOS, A. R. D.; PARADELLA, W. R.; VENEZIANI, P.; MORAIS, M. C. D. A estereoscopia com imagens radarsat-1: uma avaliação geológica na província mineral de carajás. **Revista brasileira de Geociências**, v. 29, n. 4, p. 627–632, 2017.

SANTOS, S. A.; CARDOSO, E. L.; BRASIL, M.; FLEITAS, A.; SORIANO, B. M.; MELVILLE, L.; GARCIA, J. C. Restauração de pastagens do pantanal por meio do banco de sementes e introdução de forrageiras nativas. **Cadernos de Agroecologia**, v. 13, n. 2, p. 6–6, 2018.

SCHIRRMANN, M.; GIEBEL, A.; GLEINIGER, F.; PFLANZ, M.; LENTSCHKE, J.; DAMMER, K.-H. Monitoring agronomic parameters of winter wheat crops with low-cost uav imagery. **Remote Sensing**, Multidisciplinary Digital Publishing Institute, v. 8, n. 9, p. 706, 2016.

SCHONBERGER, J. L.; FRAHM, J.-M. Structure-from-motion revisited. In: **COMPUTER VISION FOUNDATION (CVF). Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition**. Las Vegas, NV, USA, 2016. p. 4104–4113.

SCHOWENGERDT, R. A. **Remote sensing: models and methods for image processing**. 3. ed. Orlando, FL: United States of America: Academic Press, 2007. 515 p.

SCHROTH, G.; LEHMANN, J.; RODRIGUES, M.; BARROS, E.; MACÊDO, J. Plant-soil interactions in multistrata agroforestry in the humid tropicsa. **Agroforestry Systems**, Springer, v. 53, n. 2, p. 85–102, 2001.

SCHULTZ, C. A.; JEDD, T.; BEAM, R. D. The collaborative forest landscape restoration program: a history and overview of the first projects. **Journal of Forestry**, Oxford University Press, v. 110, n. 7, p. 381–391, 2012.

SEWELL, A.; BOUMA, J.; ESCH, S. van der. **Investigating the challenges and opportunities for scaling up ecosystem restoration**. [S.l.]: PBL Netherlands Environmental Assessment Agency: The Hague, The Netherlands, 2016. 78 p.

SHABAYEK, A. E. R.; DEMONCEAUX, C.; MOREL, O.; FOFI, D. Vision based uav attitude estimation: Progress and insights. **Journal of Intelligent & Robotic Systems**, Springer, v. 65, n. 1-4, p. 295–308, 2012.

SHONO, K.; CADAWENG, E. A.; DURST, P. B. Application of assisted natural regeneration to restore degraded tropical forestlands. **Restoration Ecology**, Wiley Online Library, v. 15, n. 4, p. 620–626, 2007.

- SHUMAN, C. S.; AMBROSE, R. F. A comparison of remote sensing and ground-based methods for monitoring wetland restoration success. **Restoration Ecology**, Wiley Online Library, v. 11, n. 3, p. 325–333, 2003.
- SIBONA, E.; VITALI, A.; MELONI, F.; CAFFO, L.; DOTTA, A.; LINGUA, E.; MOTTA, R.; GARBARINO, M. Direct measurement of tree height provides different results on the assessment of lidar accuracy. **Forests**, v. 8, n. 1, 2017. ISSN 1999-4907. Disponível em: <<https://www.mdpi.com/1999-4907/8/1/7>>.
- SILVA, C. A.; CROOKSTON, N. L.; HUDAK, A. T.; VIERLING, L. A.; KLAUBERG, C.; SILVA, M. C. A. **Package ‘rLiDAR’**. 2017. Available at <<<https://cran.r-project.org/web/packages/rLiDAR/rLiDAR.pdf>>>, Accessed on 2019-09-01.
- SILVA, C. A.; HUDAK, A. T.; VIERLING, L. A.; LOUDERMILK, E. L.; O’BRIEN, J. J.; HIERS, J. K.; JACK, S. B.; GONZALEZ-BENECKE, C.; LEE, H.; FALKOWSKI, M. J.; KHOSRAVIPOUR, A. Imputation of individual longleaf pine (*pinus palustris* mill.) tree attributes from field and lidar data. **Canadian journal of remote sensing**, Taylor & Francis, v. 42, n. 5, p. 554–573, 2016.
- SILVA-JUNIOR, C. H. L.; PESSÔA, A. C. M.; CARVALHO, N. S.; REIS, J. B. C.; ANDERSON, L. O.; ARAGÃO, L. E. O. C. The brazilian amazon deforestation rate in 2020 is the greatest of the decade. **Nature Ecology & Evolution**, Nature Publishing Group, v. 5, n. 2, p. 144–145, 2021.
- SILVA, V. C. S. da; VIEIRA, I. C. G.; GALBRAITH, D.; POTAPOV, P.; RIVERO, S. L. de M.; LIMA, A. M. M. de; PIMENTEL, M. A. da S.; ADAMI, M. Marked non-compliance with deforestation embargoes in the brazilian amazon. **Environmental Research Letters**, IOP Publishing, v. 17, n. 5, p. 054033, apr 2022. Disponível em: <<https://doi.org/10.1088/1748-9326/ac6398>>.
- SIMBERLOFF, D. S.; ABELE, L. G. Island biogeography theory and conservation practice. **Science**, American Association for the Advancement of Science, v. 191, n. 4224, p. 285–286, 1976.
- SOARES-FILHO, B.; RAJÃO, R.; MACEDO, M.; CARNEIRO, A.; COSTA, W.; COE, M.; RODRIGUES, H.; ALENCAR, A. Cracking brazil’s forest code. **Science**, American Association for the Advancement of Science, v. 344, n. 6182, p. 363–364, 2014.
- SOUSA, A. de P.; VIEIRA, D. L. M. **Protocolo de Monitoramento da Recomposição da Vegetação Nativa no Estado de Mato Grosso**. [S.l.], 2018. Available at <<[https://www.webambiente.cnptia.embrapa.br/webambiente/wiki/lib/exe/fetch.php?media=webambiente:sousa\\_protocolo\\_mt\\_rev.pdf](https://www.webambiente.cnptia.embrapa.br/webambiente/wiki/lib/exe/fetch.php?media=webambiente:sousa_protocolo_mt_rev.pdf)>>, Acesso em 2021-10-07.
- SOUZA, A.; MONTEIRO, A. M. V.; RENNÓ, C. D.; ALMEIDA, C. A.; VALERIANO, D. de M.; MORELLI, F.; VINHAS, L.; MAURANO, L. E. P.; ADAMI, M.; ESCADA, M. I. S.; MOTTA, M. da; AMARAL, S. **Metodologia Utilizada nos Projetos PRODES e DETER**. [S.l.], 2019. Available at <<[http://www.obt.inpe.br/OBT/assuntos/programas/amazonia/prodes/pdfs/Metodologia\\_Prodes\\_Deter\\_revisada.pdf](http://www.obt.inpe.br/OBT/assuntos/programas/amazonia/prodes/pdfs/Metodologia_Prodes_Deter_revisada.pdf)>>, Accessed on 2019-09-14.

SOUZA, C. M.; SHIMBO, J. Z.; ROSA, M. R.; PARENTE, L. L.; ALENCAR, A. A.; RUDORFF, B. F. T.; HASENACK, H.; MATSUMOTO, M.; FERREIRA, L. G.; SOUZA-FILHO, P. W. M.; OLIVEIRA, S. W. de; 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, 2020. ISSN 2072-4292. Disponível em: <<https://www.mdpi.com/2072-4292/12/17/2735>>.

STAFFORD, J. V. Implementing precision agriculture in the 21st century. **Journal of agricultural engineering research**, Elsevier, v. 76, n. 3, p. 267–275, 2000.

SUNDERLIN, W. D.; ANGELSEN, A.; BELCHER, B.; BURGERS, P.; NASI, R.; SANTOSO, L.; WUNDER, S. Livelihoods, forests, and conservation in developing countries: an overview. **World development**, Elsevier, v. 33, n. 9, p. 1383–1402, 2005.

SWAYZE, N. C.; TINKHAM, W. T.; VOGELER, J. C.; HUDAK, A. T. Influence of flight parameters on uas-based monitoring of tree height, diameter, and density. **Remote Sensing of Environment**, Elsevier, v. 263, p. 112540, 2021.

TAROLLI, P. High-resolution topography for understanding earth surface processes: Opportunities and challenges. **Geomorphology**, Elsevier, v. 216, p. 295–312, 2014.

TAY, J. Y.; ERFMEIER, A.; KALWIJ, J. M. Reaching new heights: can drones replace current methods to study plant population dynamics? **Plant ecology**, Springer, v. 219, n. 10, p. 1139–1150, 2018.

TORRES-SÁNCHEZ, J.; LÓPEZ-GRANADOS, F.; BORRA-SERRANO, I.; PEÑA, J. M. Assessing uav-collected image overlap influence on computation time and digital surface model accuracy in olive orchards. **Precision agriculture**, Springer, v. 19, n. 1, p. 115–133, 2018.

TSOUROS, D. C.; BIBI, S.; SARIGIANNIDIS, P. G. A review on uav-based applications for precision agriculture. **Information**, Multidisciplinary Digital Publishing Institute, v. 10, n. 11, p. 349, 2019.

UYSAL, M.; TOPRAK, A.; POLAT, N. Dem generation with uav photogrammetry and accuracy analysis in sahitler hill. **Measurement**, Elsevier, v. 73, p. 539–543, 2015.

VALBUENA, R.; O’CONNOR, B.; ZELLWEGER, F.; SIMONSON, W.; VIHERVAARA, P.; MALTAMO, M.; SILVA, C. A.; ALMEIDA, D. R.; DANKS, F.; MORSDORF, F. et al. Standardizing ecosystem morphological traits from 3d information sources. **Trends in Ecology & Evolution**, Elsevier, 2020.

VELDMAN, J. W.; ALEMAN, J. C.; ALVARADO, S. T.; ANDERSON, T. M.; ARCHIBALD, S.; BOND, W. J.; BOUTTON, T. W.; BUCHMANN, N.; BUISSON, E.; CANADELL, J. G. et al. Comment on “the global tree restoration potential”. **Science**, American Association for the Advancement of Science, v. 366, n. 6463, p. eaay7976, 2019.



VELDMAN, J. W.; OVERBECK, G. E.; NEGREIROS, D.; MAHY, G.; STRADIC, S. L.; FERNANDES, G. W.; DURIGAN, G.; BUISSON, E.; PUTZ, F. E.; BOND, W. J. Where tree planting and forest expansion are bad for biodiversity and ecosystem services. **BioScience**, Oxford University Press, v. 65, n. 10, p. 1011–1018, 2015.

VENATOR, M.; AKLANOGLU, S.; BRUNS, E.; MAIER, A. Enhancing collaborative road scene reconstruction with unsupervised domain alignment. **Machine Vision and Applications**, Springer, v. 32, n. 1, p. 1–16, 2021.

VERDONE, M.; SEIDL, A. Time, space, place, and the bonn challenge global forest restoration target. **Restoration ecology**, Wiley Online Library, v. 25, n. 6, p. 903–911, 2017.

VIANI, R.; RODRIGUES, R.; PADOVEZI, A.; FARAH, F. T.; GARCIA, L.; SANGLADE, L.; BRANCALION, P.; CHAVES, R.; BARRETO, T.; STRASSBURG, B.; SCARAMUZZA, C. D. M. **Pacto pela restauração da Mata Atlântica - Protocolo de monitoramento para programas e projetos de restauração florestal**. [S.l.: s.n.], 2013. 61 p. Available at <<[https://www.researchgate.net/publication/304073085\\_Pacto\\_pela\\_restauracao\\_da\\_Mata\\_Atlantica\\_-\\_Protocolo\\_de\\_monitoramento\\_para\\_programas\\_e\\_projetos\\_de\\_restauracao\\_florestal](https://www.researchgate.net/publication/304073085_Pacto_pela_restauracao_da_Mata_Atlantica_-_Protocolo_de_monitoramento_para_programas_e_projetos_de_restauracao_florestal)>>, Accessed on 2021-06-17.

VIANI, R. A.; HOLL, K. D.; PADOVEZI, A.; STRASSBURG, B. B.; FARAH, F. T.; GARCIA, L. C.; CHAVES, R. B.; RODRIGUES, R. R.; BRANCALION, P. H. Protocol for monitoring tropical forest restoration: perspectives from the atlantic forest restoration pact in brazil. **Tropical Conservation Science**, SAGE Publications Sage CA: Los Angeles, CA, v. 10, p. 1940082917697265, 2017.

VIEIRA, D. L.; SCARIOT, A. Principles of natural regeneration of tropical dry forests for restoration. **Restoration Ecology**, Wiley Online Library, v. 14, n. 1, p. 11–20, 2006.

VIEIRA, D. L. M.; RODRIGUES, S. B.; JAKOVAC, C. C.; ROCHA, G. P. E. da; REIS, F.; BORGES, A. Active restoration initiates high quality forest succession in a deforested landscape in amazonia. **Forests**, v. 12, n. 8, 2021. ISSN 1999-4907. Disponível em: <<https://www.mdpi.com/1999-4907/12/8/1022>>.

VIEIRA-FILHO, J. E. R.; GASQUES, J. G. **Uma Jornada Pelos Contrastes do Brasil: Cem anos do Censo Agropecuário**. [S.l.], 2020. 410 p. Disponível em <<[https://www.ipea.gov.br/portal/images/stories/PDFs/livros/livros/201201\\_livro\\_uma\\_jornada\\_pelos\\_contrastes\\_do\\_brasil.pdf](https://www.ipea.gov.br/portal/images/stories/PDFs/livros/livros/201201_livro_uma_jornada_pelos_contrastes_do_brasil.pdf)>>, Acesso em 2021-12-22.

WAGNER, F. H.; FERREIRA, M. P.; SANCHEZ, A.; HIRYE, M. C.; ZORTEA, M.; GLOOR, E.; PHILLIPS, O. L.; FILHO, C. R. de S.; SHIMABUKURO, Y. E.; ARAGÃO, L. E. Individual tree crown delineation in a highly diverse tropical forest using very high resolution satellite images. **ISPRS journal of photogrammetry and remote sensing**, Elsevier, v. 145, p. 362–377, 2018.

WAGNER, F. H.; SANCHEZ, A.; TARABALKA, Y.; LOTTE, R. G.; FERREIRA, M. P.; AIDAR, M. P.; GLOOR, E.; PHILLIPS, O. L.; ARAGAO, L. E. Using the u-net convolutional network to map forest types and disturbance in the atlantic rainforest with very high resolution images. **Remote Sensing in Ecology and Conservation**, Wiley Online Library, v. 5, n. 4, p. 360–375, 2019.

WALLACE, L.; LUCIEER, A.; MALENOVSKÝ, Z.; TURNER, D.; VOPĚNKA, P. Assessment of forest structure using two UAV techniques: A comparison of airborne laser scanning and structure from motion (SfM) point clouds. **Forests**, Multidisciplinary Digital Publishing Institute, v. 7, n. 3, p. 62, 2016.

WICKHAM, J. D.; JONES, K. B.; RIITERS, K. H.; WADE, T. G.; O'NEILL, R. V. Transitions in forest fragmentation: implications for restoration opportunities at regional scales. **Landscape Ecology**, Springer, v. 14, n. 2, p. 137–145, 1999.

WITCZUK, J.; PAGACZ, S.; ZMARZ, A.; CYPEL, M. Exploring the feasibility of unmanned aerial vehicles and thermal imaging for ungulate surveys in forests-preliminary results. **International journal of remote sensing**, Taylor & Francis, v. 39, n. 15-16, p. 5504–5521, 2018.

WRI. **Atlas of Forest and Landscape Restoration Opportunities**. [S.l.], 2014. Available at <<<https://www.wri.org/resources/maps/Atlas-forest-and-landscape-restoration-opportunities>>>, Accessed on 2019-08-08.

WU, X.; SHEN, X.; CAO, L.; WANG, G.; CAO, F. Assessment of individual tree detection and canopy cover estimation using unmanned aerial vehicle based light detection and ranging (uav-lidar) data in planted forests. **Remote Sensing**, Multidisciplinary Digital Publishing Institute, v. 11, n. 8, p. 908, 2019.

WULDER, M.; NIEMANN, K. O.; GOODENOUGH, D. G. Local maximum filtering for the extraction of tree locations and basal area from high spatial resolution imagery. **Remote Sensing of environment**, Elsevier, v. 73, n. 1, p. 103–114, 2000.

YIN, R.; YIN, G. China's primary programs of terrestrial ecosystem restoration: initiation, implementation, and challenges. **Environmental management**, Springer, v. 45, n. 3, p. 429–441, 2010.

YOUNG, A. Effects of trees on soils. In: PRINSLEY, R.; SWIF, M. (Ed.). **Amelioration of soils by trees: A review of current concepts and practices**. London: Commonwealth Science Council, 1986. p. 179–182.

YURTSEVEN, H.; AKGUL, M.; COBAN, S.; GULCI, S. Determination and accuracy analysis of individual tree crown parameters using uav based imagery and obia techniques. **Measurement**, Elsevier, 2019.

ZAHAWI, R. A.; DANDOIS, J. P.; HOLL, K. D.; NADWODNY, D.; REID, J. L.; ELLIS, E. C. Using lightweight unmanned aerial vehicles to monitor tropical forest recovery. **Biological Conservation**, Elsevier, v. 186, p. 287–295, 2015.

ZHAI, Z.; MARTÍNEZ, J. F.; BELTRAN, V.; MARTÍNEZ, N. L. Decision support systems for agriculture 4.0: Survey and challenges. **Computers and Electronics in Agriculture**, Elsevier, v. 170, p. 105256, 2020.

ZHANG, J.; LIN, X. Filtering airborne lidar data by embedding smoothness-constrained segmentation in progressive tin densification. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 81, p. 44–59, 2013. ISSN 0924-2716. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0924271613001019>>.

ZHANG, J.; LIU, J.; PAN, B.; SHI, Z. Domain adaptation based on correlation subspace dynamic distribution alignment for remote sensing image scene classification. **IEEE Transactions on Geoscience and Remote Sensing**, IEEE, v. 58, n. 11, p. 7920–7930, 2020.

ZHANG, N.; WANG, M.; WANG, N. Precision agriculture—a worldwide overview. **Computers and electronics in agriculture**, Elsevier, v. 36, n. 2-3, p. 113–132, 2002.

ZHAO, T.; YANG, Y.; NIU, H.; WANG, D.; CHEN, Y. Comparing u-net convolutional network with mask r-cnn in the performances of pomegranate tree canopy segmentation. In: INTERNATIONAL SOCIETY FOR OPTICS AND PHOTONICS. **Multispectral, Hyperspectral, and Ultraspectral Remote Sensing Technology, Techniques and Applications VII**. Bellingham, WA, 2018. v. 10780, p. 107801J.

ZUAZO, V. H. D.; PLEGUEZUELO, C. R. R. Soil-erosion and runoff prevention by plant covers: a review. In: **Sustainable agriculture**. [S.l.]: Springer, 2009. p. 785–811.

**ANEXO A – ARTIGO SOBRE DETECÇÃO  
AUTOMÁTICA DE ÁRVORES  
VIA RPA-SFM EM ÁREAS DE  
RESTAURAÇÃO FLORESTAL**

# Remotely piloted aircraft imagery for automatic tree counting in forest restoration areas: a case study in the Amazon<sup>1</sup>

Rafael Walter Albuquerque, Marcelo Oliveira Costa, Manuel Eduardo Ferreira, Gabriel Cardoso Carrero, and Carlos Henrique Grohmann

**Abstract:** Throughout the world, restoration of degraded areas (RDA) is not only a global but also a local challenge. In this context, the Brazilian government committed itself to restore 12 million hectares of forests by 2030. RDA monitoring customarily depends on extensive fieldwork to collect data on all individuals planted. As remotely piloted aircrafts (RPAs) can reduce costs and time of fieldwork activities, studying this technology is therefore timely given. A crucial metric for RDA is the number of trees established in the area. Methods using RPAs on automatic tree counting showed good accuracy using algorithms based on the canopy height model (CHM), which is the difference between a digital surface model (DSM) and a digital terrain model (DTM). However, obtaining a DTM demands an extra computational processing step and may require field control points or manually delimiting objects on the surface. The study presented here proposes and evaluates a semi-automated methodology for counting trees directly on DSM in RDAs in the Amazon using RPA coupled with a red–green–blue standard photographic sensor. The DSM method obtained good overall accuracy and *F*-score indexes, superior to the CHM method for all study areas even when overall accuracy was low for both methods.

*Key words:* drones, restoration of degraded areas, DSM, automatic tree count, Amazon.

**Résumé :** Dans le monde entier, la restauration de zones dégradées (RZD) n'est pas seulement un défi mondial mais aussi local. Dans ce contexte, le gouvernement brésilien s'est engagé à restaurer 12 millions d'hectares de forêts d'ici 2030. La surveillance de la RZD dépend habituellement d'un vaste travail sur le terrain pour recueillir des données sur tous les individus plantés. Comme les avions télépilotés (ATP) peuvent réduire les coûts et le temps du travail sur le terrain, l'étude de cette technologie est donc opportune. Le nombre d'arbres établis dans la région constitue une mesure essentielle de la RZD. Les méthodes utilisant la RZD pour le comptage automatique des arbres ont montré une bonne précision en

Received 15 December 2019. Accepted 28 April 2020.

**R.W. Albuquerque and C.H. Grohmann.** Institute of Energy and Environment, University of São Paulo, São Paulo CEP 05508-010, Brazil.

**M.O. Costa.** World Wildlife Fund — WWF-Brasil, Programa Amazônia, CLS 114, Bloco D, Asa Sul, CEP 70377-540 Brasília, DF, Brazil.

**M.E. Ferreira.** Laboratório de Processamento de Imagens e Geoprocessamento — LAPIG/Pro-Vant, Instituto de Estudos Socioambientais — IESA, Universidade Federal de Goiás — UFG, Campus II, Cx. Postal 131, CEP 74001-970 Goiânia, GO, Brazil.

**G.C. Carrero.** Department of Geography, University of Florida, 3141 Turlington Hall, Gainesville, FL 32611-7315, USA; Institute for Conservation and Sustainable Development of the Amazon — IDESAM, Rua Barão de Solimões, 12 Cj. Pq. das Laranjeiras — Flores, CEP 69058-250 Manaus, AM, Brazil.

**Corresponding author:** Rafael Walter Albuquerque (e-mail: [r.w.albuquerque@gmail.com](mailto:r.w.albuquerque@gmail.com)).

<sup>1</sup>This Article is part of a virtual issue on innovative applications of unmanned aerial vehicles in forest science and management jointly published by the *Journal of Unmanned Vehicle Systems* and the *Canadian Journal of Forest Research*.

Copyright remains with the author(s) or their institution(s). Permission for reuse (free in most cases) can be obtained from [copyright.com](http://copyright.com).

A correction was made to the e-First version of this paper on [21 August 2020] prior to the final issue publication. The current online version contains the correction.

utilisant des algorithmes basés sur le modèle de hauteur de couverture (MHC), qui est la différence entre un modèle de surface numérique (MSN) et un modèle de terrain numérique (MTN). Cependant, l'obtention d'un MTN requiert une étape de traitement informatique supplémentaire et peut nécessiter des points de contrôle de champ ou la délimitation manuelle d'objets sur la surface. Dans l'étude présentée ici, on propose et évalue une méthodologie semi-automatisée de comptage des arbres directement sur le MSN dans la RZD en Amazonie utilisant un ATP couplé à un capteur photographique standard rouge-vert-bleu. La méthode MSN a obtenu une bonne précision globale et des indices de score F supérieurs à la méthode MHC pour toutes les régions d'étude, même lorsque la précision globale était faible pour les deux méthodes. [Traduit par la Rédaction]

*Mots-clés* : drones, restauration des zones dégradées, modèle de surface numérique (MSN), comptage automatique des arbres, Amazonie.

## 1. Introduction

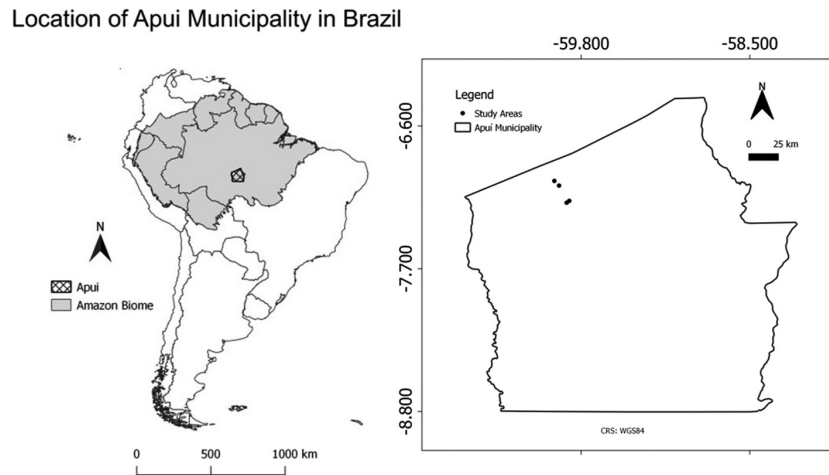
Forest landscapes restoration consists of a process that recovers the ecological integrity of ecosystems, increasing the maintenance of biodiversity and promoting human well-being. This practice became a global goal in 2011, starting with the “Bonn Challenge” (<http://www.bonnchallenge.org/content/challenge>) in a commitment to globally restore 150 million hectares by 2020 and 350 million hectares by 2030.

To support the mandatory task of monitoring restoration of degraded areas (RDA) in forest environments (Stanturf et al. 2014; McDonald et al. 2016), the use of images obtained by remotely piloted aircrafts (RPA), popularly known as drones, is considered as a promising methodology. RPAs can efficiently monitor areas undergoing environmental recovery (Zahawi et al. 2015) since they can carry image sensors with a high spatial resolution, generating aerophotogrammetric mosaics and digital surface models (DSMs) (Berni et al. 2009; D'Oleire-Oltmanns et al. 2012; Aasen et al. 2015). One of the RDA monitoring metrics is the density of trees established in the recovery site, also understood as the success rate of seedlings planted, which is obtained by tree counting (Brancaion et al. 2012).

Since manually counting trees in the field (Brancaion et al. 2015; COPEL 2015; McDonald et al. 2016) takes time, some remote sensing studies have been using RPAs to do it faster. These studies counted trees automatically considering point clouds obtained in forested areas (Dandois and Ellis 2013; Alonzo et al. 2014; Wallace et al. 2014; Mohan et al. 2017). The method used by these authors demands the acquisition of the digital terrain model (DTM) to generate the canopy height model (CHM), as it is the difference between DSM and DTM. Obtaining the DTM demands extra computational processing and often requires manual work of delimiting objects on the surface, such as vehicles, houses, and trees. Although research efforts are seeking the automation of this process (García-Pedrero et al. 2017), for instance the cloud compare initiative (Girardeau-Montaut 2016), it is still a procedure that demands time and an extra computational processing step.

On the other hand, to have a faster process, our study aims to evaluate the automatic counting of trees in RDAs directly, using the digital surface model (DSM) instead of the CHM, as long as each tree is identified by a geographic coordinate rather than by mapping the crown area.

It is worth pointing out that this work also proposes and assesses the accuracy of a methodology for automatic tree counting in Amazon RDA areas using data derived from low-cost RPA coupled with a red–green–blue (RGB) sensor. As far as the authors of this manuscript know, there are no previous studies of automatic tree count using local maximum algorithm on DSM instead of CHM database. It is then expected for this method to provide faster tree counting results, directly contributing to the improvement of RDA policies, as well as promoting a better quality of data collection procedures. Using low-cost RPA

**Fig. 1.** Location of Apuí municipality in Brazil and the study areas.

(Tarolli 2014; Albuquerque et al. 2017) is especially desired in developing countries, where financial resources are scarce (Mlambo et al. 2017).

## 2. Materials and methods

### 2.1. Study area

In this work, we assessed four RDA areas located in the Southern Brazilian Amazon forest, more precisely in the municipality of Apuí, Amazonas state (AM), as shown in Figs. 1 and 2. The region has been recently facing high deforestation rates (INPE 2017). Hence, it has a series of RDA projects implemented through cooperation between governments, non-government organizations, and institutions that work in the region, in particular the Institute for Conservation and Sustainable Development of the Amazon.

Fieldwork was conducted in July 2016 with RPA overflying four areas that had a previous anthropic use, such as extensive pastures (Fig. 2). Among these areas, two presented a vegetation cover at intermediate stages of ecological succession. They were composed by plants of natural regeneration, denominated “capoeiras”. The formation of capoeiras occurs during the years of abandonment of a deforested area and may be at different stages and ages, ranging from shrub to forest formation with a closed canopy.

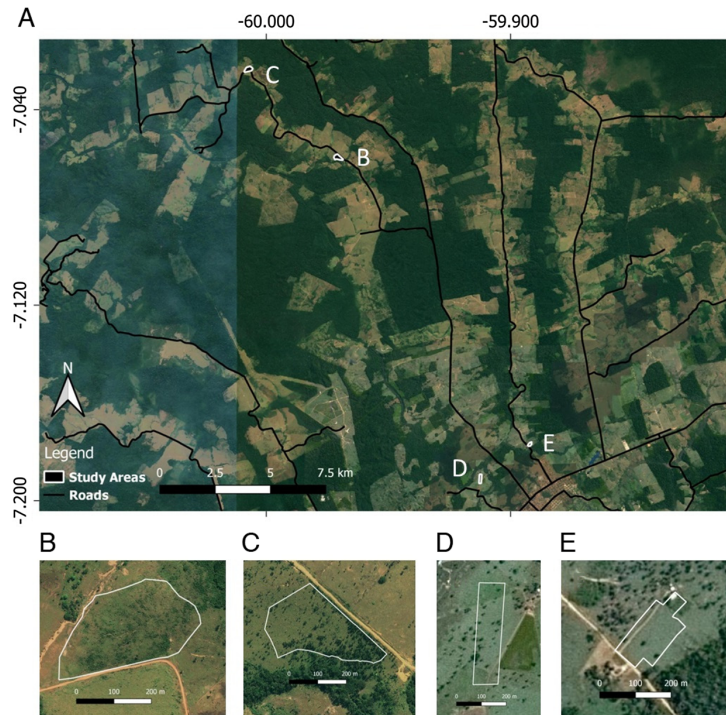
In these capoeiras, the process of recovery, or passive restoration (PR) (Aronson et al. 2011), occurs without the direct intervention of activities aiming to accelerate the process of regeneration. As the selected areas had two and five years of abandonment, both were still at an early stage of regeneration and were previously occupied by pastures.

For the other two areas, the type of recovery was active restoration (AR) with the planting of selected species in an organized way. The purpose of these AR areas is to obtain some income and restoring specific environmental functions of the soil and overall diversity. The overflown AR areas form an agroforestry system (AS) and a silvopastoral system (SS). Figure 3 illustrates the RDA classification scheme of all study areas, composed of four RDAs.


### 2.2. Materials

In the areas with the PR system, a Phantom 3 Professional (rotary wing) was used coupled with a Sony EXMOR 1/2.3" 12MP RGB sensor. More information on this RPA model can be obtained at <https://www.dji.com/phantom-3-pro/info#specs>.

**Fig. 2.** (A) Study areas viewed in the municipality of Apui. (B) Passive restoration with five years of abandonment study area. (C) Passive restoration with two years of abandonment study area. (D) Silvopastoral system study area. (E) Agroforestry system study area. Imagery from August 2010, ©2019 DigitalGlobe, CNES/Airbus, DigitalGlobe, Map Data ©2019 Google. Coordinate reference system (CRS): WGS 84 decimal degree.



**Fig. 3.** Classification of the four study areas: PR—PR2y, PR—PR5y, AR—SS, and AR—AS. RDA, restoration of degraded areas; PR, passive restoration; PR2y, passive restoration with two years of abandonment; PR5y, passive restoration with five years of abandonment; AR, active restoration; SS, silvopastoral system; and AS, agroforestry system.

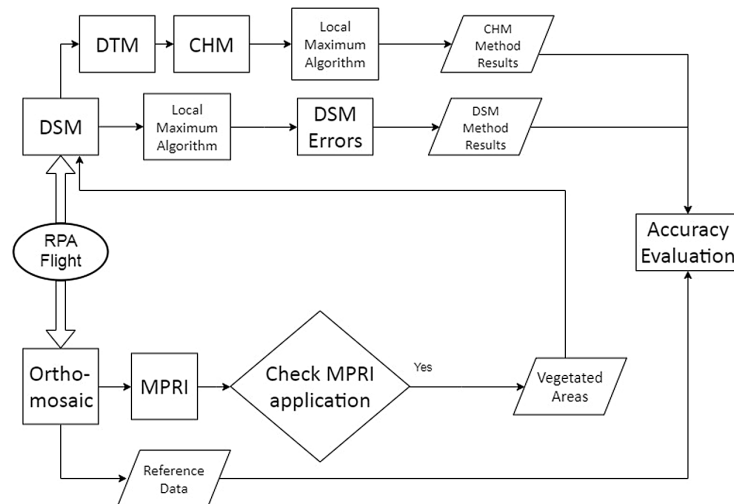


The areas with AR systems were overflowed by a Swinglet Cam (fixed wing) manufactured by SenseFly carrying a 12MP Canon IXUS 220 HS 1/2.3" RGB sensor. For more information about this instrument, see [http://95.110.228.56/documentuav/drone%20manual/\[ENG\]\\_2014\\_Extended\\_User\\_Manual\\_swinglet\\_CAM\\_v12\\_1.pdf](http://95.110.228.56/documentuav/drone%20manual/[ENG]_2014_Extended_User_Manual_swinglet_CAM_v12_1.pdf). A fixed-wing RPA was chosen to be used on AR areas because this kind of equipment is more suitable for covering large areas (Tahar and Ahmad 2013; Varga et al. 2015; Albuquerque et al. 2017), and AR may consist of large-scale projects (Holl et al. 2011).

The flight planning was drafted using the Pix4D Capture software (free version for smartphones/tablets) for the rotary wing and the eMotion software for the fixed wing. After RPA



**Fig. 4.** Study methodology workflow to assess and compare the digital surface model (DSM) method and canopy height model (CHM) method accuracy on automatic tree count. DSM errors are explained in section 2.3.4.



flights, DSMs, DTMs, and orthorectified mosaics were obtained using the Pix4D Mapper Pro software (SenseFly desktop/laptop commercial version). The classification processes were done using R (R Core Team 2013), while the layouts were generated using QGIS software.

To confirm if the DSM method is fast, a comparison of the time demanded for data processing by DSM method and by modern deep learning technology, which has recently presented high accuracy on image classification (Cheng et al. 2018; Kamilaris and Prenafeta-Boldú 2018; Zhao et al. 2018; Ma et al. 2019; Wagner et al. 2019; Bhattacharyya and Bhattacharyya 2020; Braga et al. 2020), was made. A notebook core Intel i7 with 2.4GHz and 8 GB RAM was used to measure processing time of the DSM method. As this notebook's hardware was not enough to deal with such a high computational demand required for deep learning, the Google Colab environment (Bisong 2019) was used to measure the processing time of this methodology.

### 2.3. Methods

Figure 4 summarizes the present work methodology. It shows the DSM method and the CHM method workflow and, if appropriate to avoid commission errors, the use of Modified Photochemical Reflectance Index (MPRI) vegetation index to consider only vegetated areas. This methodology workflow and each of its steps are explained in the following sections.

#### 2.3.1. Flight patterns

All flights were planned to obtain a ground sample distance equal to <10 cm and were also performed in compliance with Brazil's RPAs laws (ANAC 2017). Rotary-wing and fixed-wing RPA differed on image overlapping values and flight height as Table 1 shows. Flights were performed with the rotary wing RPA on 26 July, 28 July, and 29 July 2016.

#### 2.3.2. Automatic tree count

For the automatic tree counting, the local maximum algorithm (Wulder et al. 2000; Silva et al. 2016, 2017) of the rLiDAR R package (Silva et al. 2017) was used. It is necessary to define the search window size (FWS) of pixels to locate the highest value (maximum pixel value), what was done as a trial and error process where results were visually analyzed until a

**Table 1.** Flight patterns according to remotely piloted aircrafts and restoration of degraded areas classes.

Study area	Rotary wing (passive restoration areas)				Fixed wing (active restoration areas)			
	Front overlap (%)	Side overlap (%)	Flight height (m)	Ground sample distance (cm)	Front overlap (%)	Side overlap (%)	Flight height (m)	Ground sample distance (cm)
PR2y	70	70	120	5	—	—	—	—
PR5y	70	70	120	5	—	—	—	—
SS	—	—	—	—	70	40	120	4
AS	—	—	—	—	70	40	200	6

**Note:** PR2y, passive restoration with two years of abandonment; PR5y, passive restoration with five years of abandonment; SS, silvopastoral system; AS, agroforestry system.

proper tree distribution was obtained. When finished, local maximum algorithm generates a point table with geographic coordinates where each point represents the highest location of a tree crown, which means the counting of an individual tree.

To automatically count trees using the proposed methodology, the local maximum algorithm was applied directly on the DSM, not on the CHM. The application of the local maximum algorithm directly on the DSM is referred to as DSM method in this work.

To test the feasibility of the DSM method, its results were compared with the ones obtained by applying the local maximum algorithm on CHM data, which is a more conventional procedure according to scientific literature (Dandois and Ellis 2013; Alonzo et al. 2014; Wallace et al. 2014; Mohan et al. 2017) and referred to as CHM method in this work. For this, the classification and separation between surface and terrain objects was performed to generate the DTM, thus obtaining the CHM. The local maximum algorithm was then applied on the CHM to identify the highest point of the tree crowns. After obtaining the results and measuring the accuracy of the CHM method, a comparison with the DSM method was made.

### 2.3.3. MPRI index and conditions for its use

Depending on each study area landscape context, the automatic tree count by local maximum algorithm may or may not be subject to many commission errors (Campbell 2008) since its results could identify false trees because of, for example, mounds of grasses. If this situation occurs, the vegetation index MPRI (Barbosa et al. 2019), shown in eq. (1), which involves only visible bands, was calculated to avoid the occurrence of commission errors. When MPRI was used, its threshold values were verified on a trial and error process until a proper area containing only trees was obtained.


$$(1) \quad \text{MPRI} = \frac{(G - R)}{(G + R)}$$

### 2.3.4. Solving DSM errors

Local maximum results are susceptible to commission errors due to some DSM failures, which might happen when a tree crown is not sufficiently covered or does not present enough points on the point cloud. In these situations, the local maximum algorithm generates commission errors in the DSM method, where two or more neighboring pixels in a tree crown have equal heights and are mistakenly identified as individual trees.

To eliminate DSM error, points that presented <10 cm distance between each other were excluded, and only the centroid coordinate of the eliminated individuals was kept to avoid generation of an omission error (Campbell 2008). The 10-cm value was defined because forest inventories consider only trees with more than 5 cm in trunk diameter (Oliveira and

**Fig. 5.** Digital surface model (DSM) error generates false-positive (commission) errors on a single tree crown, which are corrected by keeping the centroid coordinate. DSM error is illustrated over the orthomosaic, as DSM contains same altitude values on the whole tree crown.



Felfili 2005), so two trees must be at least 10 cm apart. Figure 5 illustrates DSM error correction.

DSM errors occurred only with the DSM method and not the CHM method because CHM data considered these areas as terrain due to lack of sloping areas.

### 2.3.5. Accuracy evaluation

Considering that automatic classification procedures perform an approximation of the original image (Schowengerdt 2007), its results may generate omission and commission errors (Campbell 2008). As this study addresses areas under RDA projects, commission errors should be mostly avoided because it will suggest that there are more trees on the site than actually exist. This situation would erroneously suggest a more favorable environmental situation than reality (Crouzeilles et al. 2019), so caution must be taken.

After obtaining the total of trees automatically identified, it was necessary to obtain reference data to evaluate the accuracy of the results. High-resolution imagery data enable this kind of data collection by photointerpretation (McKeown 1984; Taylor and Lovell 2012; Lillesand et al. 2015). As done by Mohan et al. (2017), the reference data in this work were obtained by photointerpretation of the RPA orthomosaic, where each tree was visually identified, located, and recorded with a geographic coordinate. In Mohan et al. (2017), reference data were generated over plots of 20 m × 20 m on the orthomosaics, but in our study, the reference data were a census involving the whole study area.

After obtaining reference data, omission errors (false-negative (FN)), commission errors (false-positive (FP)), number of correctly classified trees (true-positive (TP)), and the overall accuracy (eq. (2)) (Congalton 1991; Bolfe et al. 2004) were obtained.

$$(2) \text{ Overall accuracy} = \frac{\text{TP}}{\text{Reference value}}$$

where reference value is the count obtained by photo interpretation.

Parameters recall ( $r$ ), precision ( $p$ ), and  $F$ -score were also used for accuracy evaluation. They were obtained by eqs. (3)–(5) (Goutte and Gaussier 2005):

$$(3) \quad r = \frac{\text{TP}}{(\text{TP} + \text{FN})}$$

$$(4) \quad p = \frac{\text{TP}}{(\text{TP} + \text{FP})}$$

$$(5) \quad F_{\text{score}} = 2 \times \frac{(r \times p)}{(r + p)}$$

The overall accuracy and the  $F$ -score are indexes that vary from 0 to 1. The closer to 1, the higher the accuracy, since the value 1 represents a classification without any error. Further

details on index recall, precision, and *F*-score, which involve classification errors on their formulas, can be obtained in [Goutte and Gaussier \(2005\)](#).

#### 2.3.6. Measuring data processing time

A data processing time comparison between the DSM method and deep-learning technology was performed to confirm if the DSM method may be justified by being considerably faster despite some loss of accuracy when compared with deep learning. Deep learning is a modern technology that significantly improved the fields of image processing and computer vision ([Zhao et al. 2017](#); [Zhu et al. 2017](#); [Brodrick et al. 2019](#)) and has recently presented fine and accurate results ([Cheng et al. 2018](#); [Kamilaris and Prenafeta-Boldú 2018](#); [Zhao et al. 2018](#); [Ma et al. 2019](#); [Wagner et al. 2019](#); [Bhattacharyya and Bhattacharyya 2020](#); [Braga et al. 2020](#)); however, a costly sample acquisition process is generally required to obtain such a good accuracy ([Kamilaris and Prenafeta-Boldú 2018](#); [Ma et al. 2019](#)). Thus, a table was created (see [Table 3](#) in the Results and discussion section) to compare the data processing time of these two methods.

The deep-learning method involved 250 training samples at the PR2y study area, 0 at the PR5y study area (a similar PR environment and the same RPA sensor enabled using the same deep-learning network obtained at the PR2y study area), 60 at the SS study area (this study area has fewer trees), and 300 on the AS study area. The network U-net ([Ronneberger et al. 2015](#)) was used, the number of epochs was 110, batch size was equal to 2, and uniform grids of 32 rows and 32 columns pixels were extracted during classification process on all study areas. No test samples were applied with the deep-learning method, because this technology is not the main scope of this work and evaluating its accuracy shall be done on future works.

### 3. Results and discussion

[Figure 6](#) illustrates DSM method results on the four study areas and stretches in higher scale for a better visualization. On [Fig. 6](#), each point on the orthomosaic represents the highest point of a tree crown, i.e., each point means the mapping and counting of an individual tree.

#### 3.1. PR area results: PR2y

The PR2y area had the parameter FWS (search window size of the local maximum algorithm) applied with its value equal to 19. MPRI index on this area separated trees from other surface objects and, to avoid commission errors, only areas with  $MPRI > -0.06$  were considered for automatic tree count.

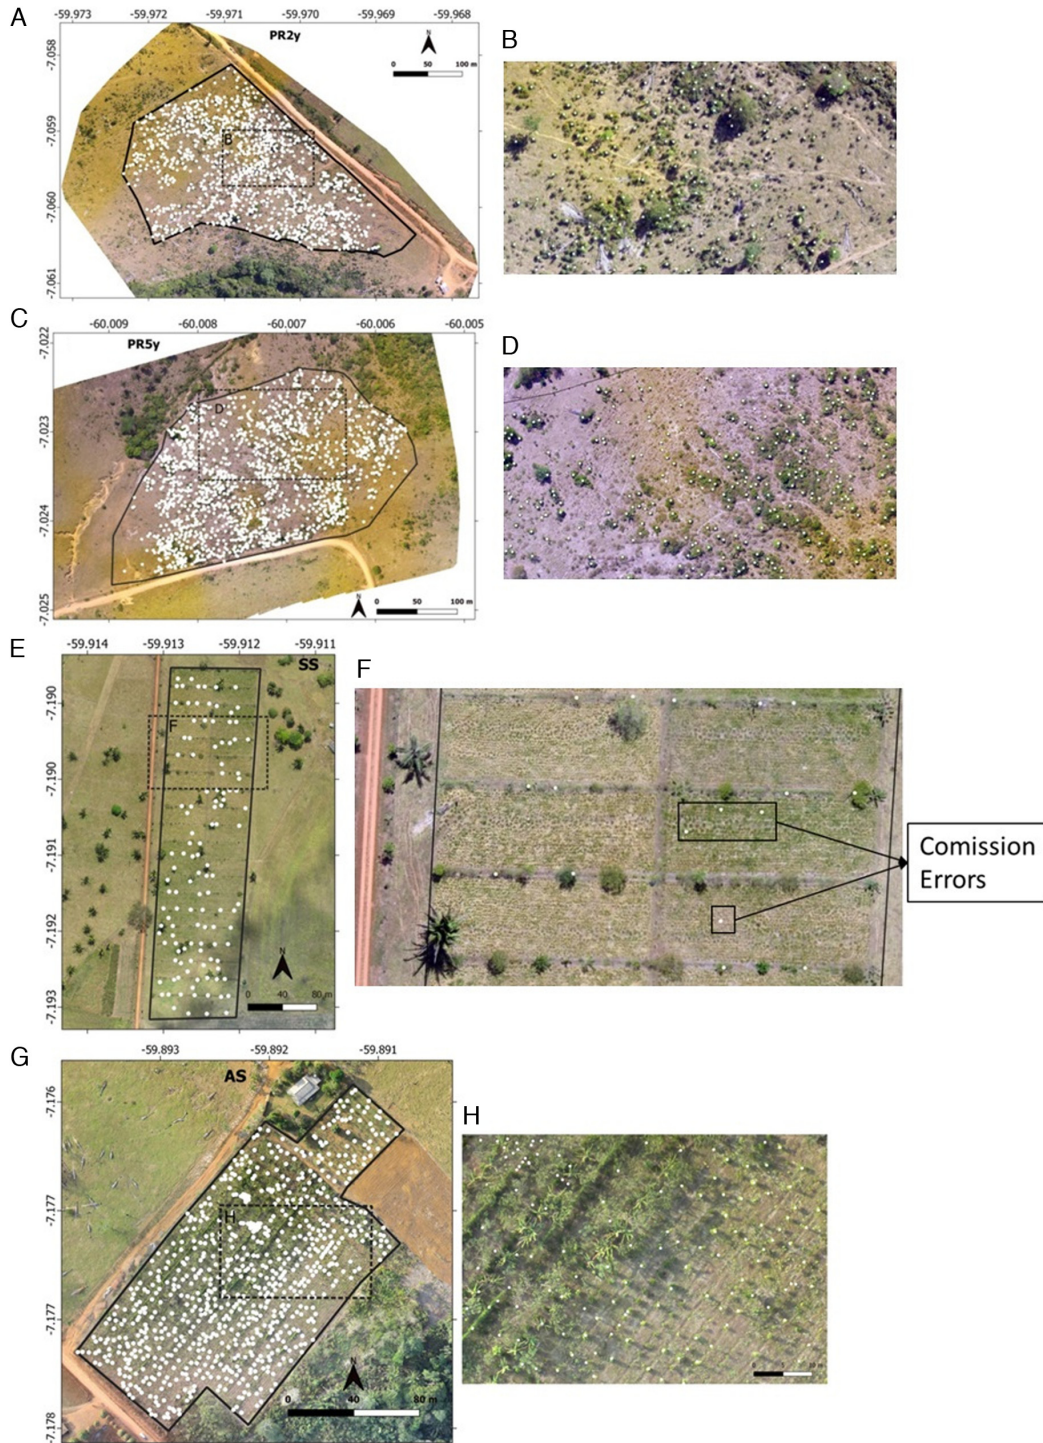
[Figure 6A](#) illustrates DSM method results on the whole PR2y area. [Figure 6B](#) shows certain consistency in the obtained results, as omission errors usually occurred for smaller tree individuals and only a few commission errors can be seen. For the DSM method to also represent and include the smallest individuals, future studies shall evaluate if greater front and side RPA image overlap enables their inclusion on automatic tree counting due to a more refined point cloud.

#### 3.2. PR area results: PR5y


[Figure 6C](#) shows the location of the trees obtained by the DSM method in the PR5y area. Here, the parameter FWS was also equal to 19 and, as in the PR2y area, the MPRI index separated trees from other surface objects. In the PR5y area, only areas with  $MPRI > -0.03$  were considered, focusing on the best result.

Although consistent, the PR5y results showed that, unlike the PR2y, omission errors were not necessarily predominant for smaller trees. In general, trees were bigger at PR5y than at PR2y because of a larger period under natural regeneration.

**Fig. 6.** Location of the trees according to the digital surface model method for the whole area in the (A) PR2y, (C) PR5y, (E) SS, and (G) AS, and respective visualizations in a more detailed stretch on (B), (D), (F), and (H). Coordinate reference system: WGS 84 decimal degree. PR2y, passive restoration with two years of abandonment; PR5y, passive restoration with five years of abandonment; SS, silvopastoral system; AS, agroforestry system.



**Fig. 7.** (A) Orthomosaic and (B) corresponding digital surface model (DSM). In the SS area, not even large trees were adequately mapped by the DSM, as highlighted in Fig. 7B, where the DSM indicates lower altitude in black and higher altitude in white, evidencing that the highlighted large tree had a similar altitude value to grasses due to insufficient side overlap.



### 3.3. AR area results: SS

The SS area has planting lines every 10 m, and some seedlings are interspersed between these lines. The results of the automatic counting in this area are shown in Figs. 6E and 6F. The MPRI index results were not considered in this area because grasses presented similar spectral responses to trees (in general, high MPRI index values), which did not reduce the commission errors that occurred on grasses with prominent heights (Fig. 6F). In this case, to reduce commission errors, the FWS parameter was used with a high value: 181. However, in return for the reduction of commission errors, omission errors were very high.

When examining the poor quality of automatic tree count in the SS area, photointerpretation showed poor quality DSM on the planting lines and even on the large trees (Fig. 7).

### 3.4. AR area results: AS

The AS area has a high tree density. It has planting lines every 2 m, and some seedlings are interspersed between these lines. MPRI index was not performed because this study area was basically composed of trees. In AS, the parameter FWS was used with a value equal to 5 to detect trees and seedlings. The results of automatic counting in this area are shown in Figs. 6G and 6H.

By examining the DSM of the AS study area in Fig. 8, it can be seen that this DSM does not adequately represent the individual tree crowns, especially the larger ones in the areas with bigger trees and less planting failures.

### 3.5. Results accuracy

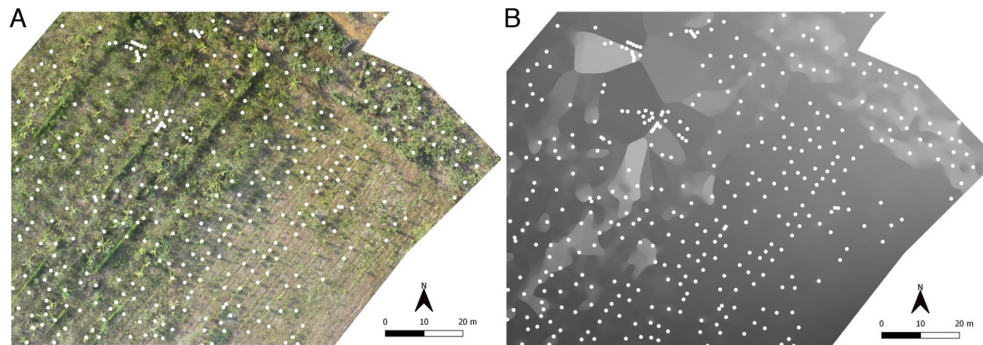
Table 2 shows the automatic tree count results obtained by the DSM method and CHM method as well as their accuracy on the four study areas.

Figure 9 shows the total of existing trees (reference data) on each study area as well as the number of automatically identified trees according to results of the DSM method and CHM methods.

The reduced representation of tree canopies in the DSM obtained by the fixed-wing RPA on both SS and AS areas, as illustrated in Figs. 7 and 8, affected automatic tree counting accuracy shown in Table 2.

Table 2 also shows similar accuracy values between the DSM method and the CHM method. In the PR areas, the DSM method obtained more accurate values than the CHM method, in both overall accuracy and *F*-score.

**Fig. 8.** Stretch of the agroforestry system (AS) orthomosaic with trees identified by the (A) digital surface model (DSM) method and (B) the DSM of the AS study area, which visually does not adequately represent the crowns of arboreal individuals.



**Table 2.** Number of trees counted automatically and the accuracy of the results obtained by the digital surface model (DSM) method and the canopy height model (CHM) method for the study areas.

Study area	No. of existing trees	No. of automatically identified trees	TP	FP	FN	R	<i>p</i>	<i>F</i>	Overall accuracy
PR2y DSM method	1794	1204	1192	12	602	0.66	0.99	0.80	0.66
PR2y CHM method	1794	1075	1047	28	747	0.58	0.97	0.73	0.58
PR5y DSM method	1947	1499	1497	2	450	0.77	1.00	0.87	0.77
PR5y CHM method	1947	1288	1268	20	679	0.65	0.98	0.78	0.65
SS DSM method	412	128	86	42	326	0.21	0.67	0.32	0.21
SS CHM method	412	204	100	104	312	0.24	0.49	0.32	0.24
AS DSM method	4027	810	794	16	3233	0.20	0.98	0.33	0.20
AS CHM method	4027	1015	841	174	3186	0.21	0.83	0.33	0.21

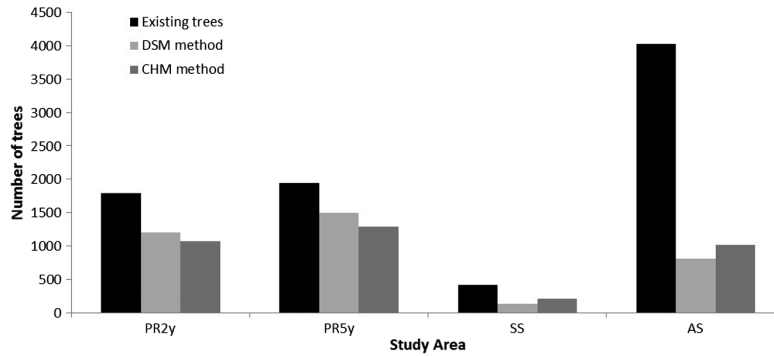
**Note:** TP, true positive; FP, false positive; FN, false negative; *r*, recall; *p*, precision; *F*, *F*-score (section 2.3.5); PR2y, passive restoration with two years of abandonment; PR5y, passive restoration with five years of abandonment; AR, active restoration; SS, silvopastoral system; AS, agroforestry system.

In AR areas, [Table 2](#) and [Fig. 9](#) suggest that SS and AS were more accurate with the CHM method because they presented higher overall accuracy and are closer to the actual number of existing trees. However, despite higher accuracy indexes, SS and AS areas presented a higher number of commission errors (FP), which shall be avoided in this study. [Figure 10](#) illustrates that commission errors were higher with the CHM method, especially in the SS and AS areas, evidencing more accurate results with the DSM method.

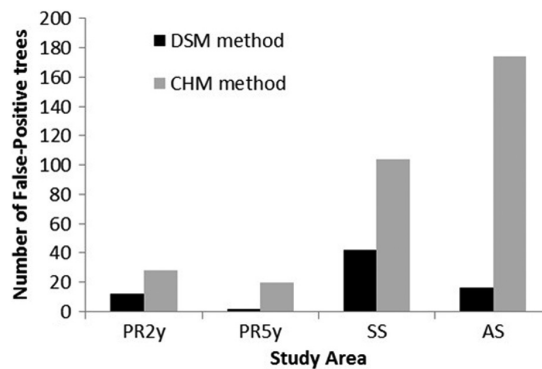
According to the precision-recall curve in [Fig. 11](#), commission and omission errors for the CHM method were more evidenced. [Fig. 11](#) shows better performance with the DSM method for all study areas. Although accuracy indexes consider the same weight to both omission and commission errors on their formulas, in this research, it is necessary to avoid commission errors as much as possible, as explained in section 2.3.5. If a higher weight was assigned to commission errors, a better overall performance of the DSM method would be numerically expressed in the calculation of the *F*-score and overall accuracy. Hence, the tree counting performance of the DSM method would still be unsatisfactory in the SS area.

The AR areas presented an unsatisfactory performance in both the DSM and CHM methods. As already shown in [Figs. 7](#) and [8](#), AR areas did not present a DSM that could accurately represent the field reality, which undoubtedly affected the performance of the classification process. Even though the DSM method had a better performance, one must seek an

**Fig. 9.** Number of existing trees and results of the automatic tree count obtained by the digital surface model (DSM) method and canopy height model (CHM) method in each study area.



**Fig. 10.** Commission errors, or false-positives (FP), on the four study areas. The canopy height model (CHM) method showed a high quantity of FP, and this situation must be avoided because it unduly suggests a better environmental performance than the real situation. DSM, digital surface model; PR2y, passive restoration with two years of abandonment; PR5y, passive restoration with five years of abandonment; SS, silvopastoral system; AS, agroforestry system.

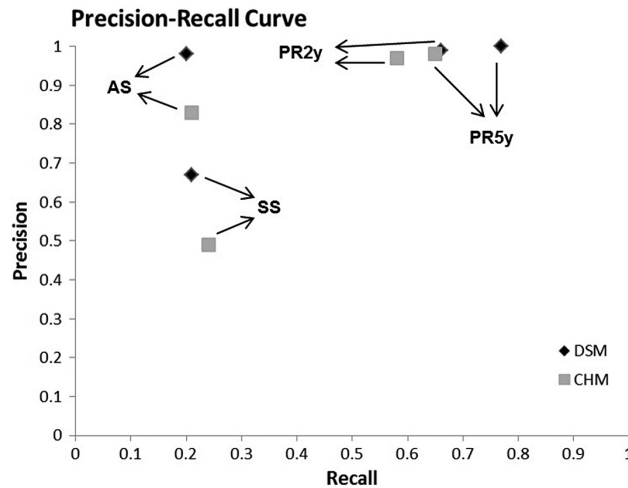


improvement in the quality of the DSM to improve its results, so 40% of side overlap was maybe considered insufficient. To confirm that not only insufficient image overlap but also environment of AR areas influenced the lack of details of DSM data, new flights, with higher image overlap, should be performed. However, this situation was noticed after the field campaign, so more flights with higher image overlap on AR areas were not possible, what would confirm if the AR environment also contributes to the acquisition of poor DSM data.

Although the fixed-wing RPA flew with low side overlap, some studies (Dandois et al. 2015; Torres-Sánchez et al. 2018) pointed out that even the rotary wing presented an image overlap that was considered low. For instance, on forested areas, support on the Pix4d website (<https://support.pix4d.com/hc/en-us/articles/203756125-How-to-verify-that-there-is-Enough-Overlap-between-the-Images>) suggests using higher photo overlap values than the ones used in our study. In this case, future works, besides prioritizing higher image overlap values, should also perform perpendicular (i.e., crossover) flights (Wallace et al. 2016).



**Fig. 11.** Precision-recall curve shows that digital surface model method is closer to value 1 on both  $x$ - and  $y$ -axis, stating that it had a better performance than the canopy height model method on the four study areas.



**Table 3.** Computational processing time comparison between digital surface model (DSM) method and deep learning method.

Study area	Area (ha)	DSM method		Deep learning training samples	Deep learning processing time
		FWS (local maximum search window size)	DSM method processing time		
PR2y	6.56	19	0 h 16 min 56.02 s	250	29 h 01 min 22.59 s
PR5y	6.46	19	0 h 25 min 45.86 s	0	06 h 20 min 23.55 s
SS	4.18	181	2 h 04 min 19.56 s	60	10 h 07 min 42.14 s
AS	2.07	5	0 h 03 min 01.53 s	300	09 h 30 min 42 s

Although future studies should evaluate a DSM refinement, the obtained results show that the DSM method in this study performed better than the CHM method on all study areas. It can then be stated that the DSM method can be used as an alternative for counting trees in RDA areas when the purpose is to measure the success rate of the establishment of arboreal individuals with reasonable accuracy. This fact, however, doesn't inhibit the CHM data usage because it contains important tree height data, so the DSM method can be used on an independent tree counting process. If the tree height measurement is desired, DSM method results may be used over the CHM data so that the geographic coordinates may extract the corresponding tree height values. In that case, the objective of this work was to evaluate only the automatic tree count considering DSM and CHM databases, so evaluating the tree height of each study area was not performed neither on the field (to generate a tree height reference data) nor on the RPA database.

RGB orthomosaic database was not used on this work to automatically count trees like Goodbody et al. (2017) and Feduck et al. (2018) did, because a fast methodology was evaluated (considering local maximum algorithm) to generate coordinates only. The RGB orthomosaic database must be used when automatic tree crown delineation (TCD), which generates polygons to detect trees instead of coordinates, is desired. Also, Michez et al. (2016) commented that automatic TCD is a specific subject to be studied. In that case, to

accurately perform TCD, modern methodologies such as deep learning (LeCun et al. 2015) would be used, since they are promising and already being used (Zhao et al. 2018; Wagner et al. 2019). On PR areas, the DSM method presented similar accuracy results to Zhao et al. (2018) and a bit lower accuracy results than Wagner et al. (2019). Although a bit inaccurate when compared with Wagner et al. (2019), the DSM method may still be an alternative since it doesn't require sampling for training algorithm neither intense computational processing.

To confirm that the DSM method is fast and doesn't require intense computational processing, Table 3 shows that the DSM method was much faster than the deep learning method. Also, the amount of time demanded for sample collection, which was around 10 h for all the study areas, was not considered on the values presented at Table 3 for the deep learning method, reinforcing the DSM method as a faster alternative.

Table 3 shows that the DSM method processing time increases as the FWS parameter increases. Even when the FWS parameter is very high (SS study area) and when no training samples are needed for the deep learning method (PR5y study area), the DSM method data processing was much faster.

### 3.6. Considerations about FWS parameter

The FWS value (local maximum algorithm's search window size of points of maximum elevation) was equal to 5 in the AS area (high tree density), 19 in the PR areas (intermediate tree density, once natural regeneration irregularly vary tree spacing) and 181 in the SS area (low tree density). Thus, when working with high spatial resolution RPA imagery, the higher the density (distance between trees), the lower the value of FWS. Mohan et al. (2017) also observed this relationship between tree density and the FWS parameter value.

Since FWS is related to the spatial resolution of the image and to specific characteristics of each study area, it is not possible to associate a specific minimum distance value to properly separate trees. The only distance value that can be associated when automatically counting trees is the field reality, where the trees have at least 5 cm of trunk diameter (Oliveira and Felfili 2005), so the trees must be at least 10 cm distant from each other as section 2.3.4 described. In addition to the 10 cm distance value, FWS must be evaluated according to spatial resolution and specific characteristics of each study area.

## 4. Conclusions

The results indicated that the DSM method performed better than the CHM method, so it has a great potential to be used for the tree count to calculate tree density. The DSM results reasonably represented the number of arboreal individuals in the PR study areas, which presented 70% of front and side image overlap, while in AR areas accuracy results were poor due to 70% and 40% of front and side overlap between RPA images. Thus, it is important to scientifically report these findings: our RPA image overlap was enough to register landscape surface, but the image must have greater overlap to count trees automatically by the local maximum algorithm. Also, as this situation was noticed after the 2016 field campaign, it was not possible to perform other RPA flights in the study areas with higher image overlap, which would confirm if the AR areas environment also influenced the acquisition of poor DSM data.

The DSM method succeeded on an environmental conservative posture involving RDA projects by avoiding commission errors. If the estimated quantity of trees was higher than the actual value that exists on the field, RDA reports would unduly indicate that the environment is more preserved than it is. Conservative posture is important on RDA landscape registering by RPA, a technology that is capable of recording the stage of a whole recovery area through georeferenced orthomosaics, which are ideal for historical comparison. In

any case, the survey carried out using a RPA may complement or, maybe in the future after improving the DSM method, replace traditional on-the-ground field inventory efforts. In addition to improving DSM method, future works should evaluate TCD performance by using deep learning techniques.

### Acknowledgements

This work was supported by the Brazilian Amazon Program of the World Wide Fund (WWF) in the context of Ecodrones project. The authors thank WWF-Brasil, the support of Embrapa Instrumentação, and the Federal University of Goiás for the provision of equipment and software. We also thank Santiago & Cintra and Pix4D for their technical cooperation and University of São Paulo for data processing and analysis infrastructure. We thank the Institute for Conservation and Sustainable Development of the Amazon (IDESAM) collaboration through its Education, Research, and Extension Program on Sustainable Rural Development (PEPEPRS) and for the support that the staff in Apuí and Manaus gave in the planning and execution of the field activities. We are thankful for the owners of the forest restoration areas (IDESAM's partners) for authorizing our access.

### References

- Aasen, H., Burkart, A., Bolten, A., and Bareth, G. 2015. Generating 3D hyperspectral information with lightweight UAV snapshot cameras for vegetation monitoring: From camera calibration to quality assurance. *ISPRS J. Photogramm. Remote Sens.* **108**(10): 245–259. doi: [10.1016/j.isprsjprs.2015.08.002](https://doi.org/10.1016/j.isprsjprs.2015.08.002).
- Agência Nacional de Aviação Civil (ANAC). 2017. Requisitos gerais para aeronaves não tripuladas de uso civil. Resolução número 419, de 2 de maio de 2017. Regulamento Brasileiro da Aviação Civil Especial, RBAC-E número 94.
- Albuquerque, R.W., Costa, M.O., Ferreira, M.E., Jorge, L.A.C., Sarracini, L.H., Rosa, E.O., and Tavares, L.F.S. 2017. Qualitative effectiveness of unmanned aerial vehicles for monitoring forest restoration in Brazil: A brief review. *Int. J. Curr. Res.* **9**(5): 50802–50806.
- Alonzo, M., Bookhagen, B., and Roberts, D.A. 2014. Urban tree species mapping using hyperspectral and lidar data fusion. *Remote Sens. Environ.* **148**: 70–83. doi: [10.1016/j.rse.2014.03.018](https://doi.org/10.1016/j.rse.2014.03.018).
- Aronson, J., Durigan, G., and Brancalion, P. 2011. Conceitos e definições correlatos à ciência e à prática da restauração ecológica. *IF Série Registros*, n. 44, pp. 1–38. Available from <http://www.lerf.esalq.usp.br/divulgacao/recomendados/artigos/aronson2011.pdf> [accessed 20 October 2016].
- Barbosa, B., Ferraz, G., Gonçalves, L., Marin, D., Maciel, D., Ferraz, P., and Rossi, G. 2019. RGB vegetation indices applied to grass monitoring: A qualitative analysis. *Agron. Res.* **17**(2): 349–357.
- Berni, J.A., Zarco-Tejada, P.J., Suárez, L., and Fereres, E. 2009. Thermal and narrowband multispectral remote sensing for vegetation monitoring from an unmanned aerial vehicle. *IEEE Trans. Geosci. Remote Sens.* **47**(3): 722–738. doi: [10.1109/TGRS.2008.2010457](https://doi.org/10.1109/TGRS.2008.2010457).
- Bhattacharyya, R., and Bhattacharyya, A. 2020. Crown detection and counting using satellite images. *In Emerging technology in modelling and graphics. Edited by J. Mandal and D. Bhattacharya.* Springer, Singapore, Singapore. pp. 765–773.
- Bisong, E. 2019. Google colab. *In Building machine learning and deep learning models on Google Cloud Platform: A comprehensive guide for beginners. Edited by E. Bisong.* Apress, Berkeley, Calif., USA. pp. 59–64.
- Bolfe, É.L., Pereira, R.S., Madruga, R.A., and Fonseca, E.L. 2004. Avaliação da classificação digital de povoamentos florestais em imagens de satélite através de índices de acurácia. *Rev. Árvore*, **28**(1): 85–90. doi: [10.1590/S0100-67622004000100011](https://doi.org/10.1590/S0100-67622004000100011). PMID: 32369791.
- Braga, J.R.G., Peripato, V., Dalagnol, R., Ferreira, M.P., Tarabalka, Y., and Aragão, L.E.O.C., et al. 2020. Tree crown delineation algorithm based on a convolutional neural network. *Remote Sens.* **12**(8): 1288. doi: [10.3390/rs12081288](https://doi.org/10.3390/rs12081288).
- Brancalion, P.H.S., Viani, R.A.G., Rodrigues, R.R., and Gandolfi, S. 2012. Avaliação e monitoramento de áreas em processo de restauração. *In Restauração ecológica de ecossistemas degradados. Edited by S. Martins.* Editora UFV Viçosa, Viçosa, MG, Brazil. pp. 262–293. Available from [http://www.esalqlastrop.com.br/img/aulas/Cumbuca%206\(2\).pdf](http://www.esalqlastrop.com.br/img/aulas/Cumbuca%206(2).pdf) [accessed 31 October 2017].
- Brancalion, P.H.S., Gandolfi, S., and Rodrigues, R.R. 2015. Restauração florestal. *Oficina de Textos*, São Paulo. p. 432.
- Brodrick, P.G., Davies, A.B., and Asner, G.P. 2019. Uncovering ecological patterns with convolutional neural networks. *Trends Ecol. Evol.* **34**(8): 734–745. doi: [10.1016/j.tree.2019.03.006](https://doi.org/10.1016/j.tree.2019.03.006). PMID: 31078331.
- Campbell, J.B. 2008. Introduction to remote sensing. Guilford Press, New York, N.Y., USA.
- Cheng, G., Yang, C., Yao, X., Guo, L., and Han, J. 2018. When deep learning meets metric learning: Remote sensing image scene classification via learning discriminative CNNs. *IEEE Trans. Geosci. Remote Sens.* **56**(5): 2811–2821. doi: [10.1109/TGRS.2017.2783902](https://doi.org/10.1109/TGRS.2017.2783902).

- Companhia Paranaense de Energia (COPEL). 2015. Relatório Técnico SMA/DGSA/VGAM N. 49/2015. Technical Report. Companhia Paranaense de Energia, Curitiba. Available from [http://www.usinamaua.com.br/upload/tiny\\_mce/RT\\_049.2015\\_DGSA.VGAM\\_PRAD\\_Maua\\_5a\\_inspecao.pdf](http://www.usinamaua.com.br/upload/tiny_mce/RT_049.2015_DGSA.VGAM_PRAD_Maua_5a_inspecao.pdf) [accessed 26 November 2017].
- Congalton, R.G. 1991. A review of assessing the accuracy of classifications of remotely sensed data. *Remote Sens. Environ.* **37**(1): 35–46. doi: [10.1016/0034-4257\(91\)90048-B](https://doi.org/10.1016/0034-4257(91)90048-B).
- Crouzeilles, R., Santiami, E., Rosa, M., Pugliese, L., Brancalion, P.H., and Rodrigues, R.R., et al. 2019. There is hope for achieving ambitious Atlantic forest restoration commitments. *Perspect. Ecol. Conserv.* **17**(2): 80–83. doi: [10.1016/j.pecon.2019.04.003](https://doi.org/10.1016/j.pecon.2019.04.003).
- Dandois, J.P., and Ellis, E.C. 2013. High spatial resolution three-dimensional mapping of vegetation spectral dynamics using computer vision. *Remote Sens. Environ.* **136**: 259–276. doi: [10.1016/j.rse.2013.04.005](https://doi.org/10.1016/j.rse.2013.04.005).
- Dandois, J.P., Olano, M., and Ellis, E. 2015. Optimal altitude, overlap, and weather conditions for computer vision UAV estimates of forest structure. *Remote Sens.* **7**(10): 13895–13920. doi: [10.3390/rs71013895](https://doi.org/10.3390/rs71013895).
- D'Oleire-Oltmanns, S., Marzoff, I., Peter, K., and Ries, J. 2012. Unmanned aerial vehicle (UAV) for monitoring soil erosion in Morocco. *Remote Sens.* **4**(11): 3390–3416. doi: [10.3390/rs4113390](https://doi.org/10.3390/rs4113390).
- Feduck, C., McDermid, G.J., and Castilla, G. 2018. Detection of coniferous seedlings in UAV imagery. *Forests*, **9**(7): 432. doi: [10.3390/f9070432](https://doi.org/10.3390/f9070432).
- García-Pedrero, A., Lillo-Saavedra, M., Rodríguez-Esparragon, D., Rodríguez-Gonzalez, A., and Gonzalo-Martin, C. 2017. Increasing the UAV data value by an OBIA methodology. In *Image and Signal Processing for Remote Sensing XXIII*, Bellingham. International Society for Optics and Photonics. Vol. 10427, 104270U.
- Girardeau-Montaut, D. 2016. CloudCompare. EDF R&D Telecom ParisTech, Paris. Available from [http://pcp2019.ifp.uni-stuttgart.de/presentations/04-CloudCompare\\_PCP\\_2019\\_public.pdf](http://pcp2019.ifp.uni-stuttgart.de/presentations/04-CloudCompare_PCP_2019_public.pdf) [accessed 6 September 2019].
- Goodbody, T.R., Coops, N.C., Marshall, P.L., Tompalski, P., and Crawford, P. 2017. Unmanned aerial systems for precision forest inventory purposes: A review and case study. *For. Chron.* **93**(1): 71–81. doi: [10.5558/ffc2017-012](https://doi.org/10.5558/ffc2017-012).
- Goutte, C., and Gaussier, E. 2005. A probabilistic interpretation of precision, recall and f-score, with implication for evaluation. In *European Conference on Information Retrieval*. Springer, Heidelberg. pp. 345–359.
- Holl, K.D., Zahawi, R.A., Cole, R.J., Ostertag, R., and Cordell, S. 2011. Planting seedlings in tree islands versus plantations as a large-scale tropical forest restoration strategy. *Restor. Ecol.* **19**(4): 470–479. doi: [10.1111/j.1526-100X.2010.00674.x](https://doi.org/10.1111/j.1526-100X.2010.00674.x).
- Instituto Nacional de Pesquisas Espaciais (INPE) [National Institute for Space Research]. 2017. PRODES Project: Monitoring the Brazilian Amazon forest by satellite. Brazilian Ministry of Science, Technology and Innovation, São José dos Campos. Available from <http://www.dpi.inpe.br/prodesdigital/prodesmunicipal.php> [accessed 30 May 2019].
- Kamilaris, A., and Prenafeta-Boldú, F.X. 2018. Deep learning in agriculture: A survey. *Comput. Electron. Agric.* **147**: 70–90. doi: [10.1016/j.compag.2018.02.016](https://doi.org/10.1016/j.compag.2018.02.016).
- LeCun, Y., Bengio, Y., and Hinton, G. 2015. Deep learning. *Nature*, **521**(7553): 436–444. doi: [10.1038/nature14539](https://doi.org/10.1038/nature14539). PMID: 26017442.
- Lillesand, T., Kiefer, R.W., and Chipman, J. 2015. *Remote sensing and image interpretation*. John Wiley & Sons, New York.
- Ma, L., Liu, Y., Zhang, X., Ye, Y., Yin, G., and Johnson, B.A. 2019. Deep learning in remote sensing applications: A meta-analysis and review. *ISPRS J. Photogramm. Remote Sens.* **152**: 166–177. doi: [10.1016/j.isprsjprs.2019.04.015](https://doi.org/10.1016/j.isprsjprs.2019.04.015).
- McDonald, T., Gann, G., Jonson, J., and Dixon, K. 2016. International standards for the practice of ecological restoration — Including principles and key concepts. Technical Report. Society for Ecological Restoration, Washington, D.C., USA. Available from [http://www.seraustralia.com/wheel/image/SER\\_International\\_Standards.pdf](http://www.seraustralia.com/wheel/image/SER_International_Standards.pdf) [accessed 9 August 2019].
- McKeown, D.M., Jr. 1984. Knowledge-based aerial photo interpretation. *Photogrammetria*, **39**(3): 91–123. doi: [10.1016/0031-8663\(84\)90004-8](https://doi.org/10.1016/0031-8663(84)90004-8).
- Michez, A., Piégay, H., Lisein, J., Claessens, H., and Lejeune, P. 2016. Classification of riparian forest species and health condition using multi-temporal and hyperspatial imagery from unmanned aerial system. *Environ. Monit. Assess.* **188**(3): 146. doi: [10.1007/s10661-015-4996-2](https://doi.org/10.1007/s10661-015-4996-2). PMID: 26850712.
- Mlambo, R., Woodhouse, I., Gerard, F., and Anderson, K. 2017. Structure from motion (SfM) photogrammetry with drone data: A low cost method for monitoring greenhouse gas emissions from forests in developing countries. *Forests*, **8**(3): 68. doi: [10.3390/f8030068](https://doi.org/10.3390/f8030068).
- Mohan, M., Silva, C., Klauberg, C., Jat, P., Catts, G., and Cardil, A., et al. 2017. Individual tree detection from unmanned aerial vehicle (UAV) derived canopy height model in an open canopy mixed conifer forest. *Forests*, **8**(9): 340. doi: [10.3390/f8090340](https://doi.org/10.3390/f8090340).
- Oliveira, E.C.L., and Felfili, J.M. 2005. Estrutura e dinâmica da regeneração natural de uma mata de galeria no Distrito Federal, Brasil. *Acta Bot. Bras.* **19**(4): 801–811. doi: [10.1590/S0102-33062005000400016](https://doi.org/10.1590/S0102-33062005000400016).
- R Core Team. 2013. R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria. Available from <http://www.R-project.org>.
- Ronneberger, O., Fischer, P., and Brox, T. 2015. U-net: Convolutional networks for biomedical image segmentation. In *International Conference on Medical Image Computing and Computer-assisted Intervention*. Springer, Heidelberg. pp. 234–241.
- Schowengerdt, R.A. 2007. *Remote sensing: models and methods for image processing*. 3rd ed. Academic Press, Orlando, FL, USA.

- Silva, C.A., Hudak, A.T., Vierling, L.A., Loudermilk, E.L., O'Brien, J.J., and Hiers, J.K., et al. 2016. Imputation of individual longleaf pine (*Pinus palustris* Mill.) tree attributes from field and LiDAR data. *Can. J. Remote Sens.* **42**(5): 554–573. doi: [10.1080/07038992.2016.1196582](https://doi.org/10.1080/07038992.2016.1196582).
- Silva, C.A., Crookston, N.L., Hudak, A.T., Vierling, L.A., Klauberg, C., and Silva, M.C.A. 2017. Package 'rLiDAR'. Available from <https://cran.r-project.org/web/packages/rLiDAR/rLiDAR.pdf> [accessed 1 September 2019].
- Stanturf, J.A., Palik, B.J., and Dumroese, R.K. 2014. Contemporary forest restoration: a review emphasizing function. *For. Ecol. Manage.* **331**: 292–323. doi: [10.1016/j.foreco.2014.07.029](https://doi.org/10.1016/j.foreco.2014.07.029).
- Tahar, K.N., and Ahmad, A. 2013. An evaluation on fixed wing and multi-rotor UAV images using photogrammetric image processing. *In Proceedings of World Academy of Science, Engineering and Technology*. No. 73. World Academy of Science, Engineering and Technology (WASET), Paris. p. 391.
- Tarolli, P. 2014. High-resolution topography for understanding earth surface processes: Opportunities and challenges. *Geomorphology*, **216**: 295–312. doi: [10.1016/j.geomorph.2014.03.008](https://doi.org/10.1016/j.geomorph.2014.03.008).
- Taylor, J.R., and Lovell, S.T. 2012. Mapping public and private spaces of urban agriculture in Chicago through the analysis of high-resolution aerial images in Google Earth. *Landsc. Urban Plann.* **108**(1): 57–70. doi: [10.1016/j.landurbplan.2012.08.001](https://doi.org/10.1016/j.landurbplan.2012.08.001).
- Torres-Sánchez, J., López-Granados, F., Borra-Serrano, I., and Peña, J.M. 2018. Assessing UAV-collected image overlap influence on computation time and digital surface model accuracy in olive orchards. *Precis. Agric.* **19**(1): 115–133. doi: [10.1007/s11119-017-9502-0](https://doi.org/10.1007/s11119-017-9502-0).
- Varga, M., Basiri, M., Heitz, G., and Floreano, D. 2015. Distributed formation control of fixed wing micro aerial vehicles for area coverage. *In 2015 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*. IEEE, New York. pp. 669–674.
- Wagner, F.H., Sanchez, A., Tarabalka, Y., Lotte, R.G., Ferreira, M.P., and Aida, M.P., et al. 2019. Using the U-net convolutional network to map forest types and disturbance in the Atlantic rainforest with very high resolution images. *Remote Sens. Ecol. Conserv.* **5**(4): 360–375. doi: [10.1002/rse2.111](https://doi.org/10.1002/rse2.111).
- Wallace, L., Lucieer, A., and Watson, C.S. 2014. Evaluating tree detection and segmentation routines on very high resolution UAV LiDAR data. *IEEE Trans. Geosci. Remote Sens.* **52**(12): 7619–7628. doi: [10.1109/TGRS.2014.2315649](https://doi.org/10.1109/TGRS.2014.2315649).
- Wallace, L., Lucieer, A., Malenovsky, Z., Turner, D., and Vopěnka, P. 2016. Assessment of forest structure using two UAV techniques: A comparison of airborne laser scanning and structure from motion (SfM) point clouds. *Forests*, **7**(3): 62. doi: [10.3390/f7030062](https://doi.org/10.3390/f7030062).
- Wulder, M., Niemann, K.O., and Goodenough, D.G. 2000. Local maximum filtering for the extraction of tree locations and basal area from high spatial resolution imagery. *Remote Sens. Environ.* **73**(1): 103–114. doi: [10.1016/S0034-4257\(00\)00101-2](https://doi.org/10.1016/S0034-4257(00)00101-2).
- Zahawi, R.A., Dandois, J.P., Holl, K.D., Nadwodny, D., Reid, J.L., and Ellis, E.C. 2015. Using lightweight unmanned aerial vehicles to monitor tropical forest recovery. *Biol. Conserv.* **186**: 287–295. doi: [10.1016/j.biocon.2015.03.031](https://doi.org/10.1016/j.biocon.2015.03.031).
- Zhao, B., Feng, J., Wu, X., and Yan, S. 2017. A survey on deep learning-based fine-grained object classification and semantic segmentation. *Int. J. Autom. Comput.* **14**(2): 119–135. doi: [10.1007/s11633-017-1053-3](https://doi.org/10.1007/s11633-017-1053-3).
- Zhao, T., Yang, Y., Niu, H., Wang, D., and Chen, Y. 2018. Comparing U-net convolutional network with mask R-CNN in the performances of pomegranate tree canopy segmentation. *In Multispectral, Hyperspectral, and Ultraspectral Remote Sensing Technology, Techniques and Applications VII*. International Society for Optics and Photonics, Bellingham. Vol. 10780, 107801J.
- Zhu, X.X., Tuia, D., Mou, L., Xia, G.-S., Zhang, L., Xu, F., and Fraundorfer, F. 2017. Deep learning in remote sensing: A comprehensive review and list of resources. *IEEE Geosci. Remote Sens. Mag.* **5**(4): 8–36. doi: [10.1109/MGRS.2017.2762307](https://doi.org/10.1109/MGRS.2017.2762307).

**ANEXO B – ARTIGO SOBRE AVALIAÇÃO  
DOS ASPECTOS  
ESTRUTURAIS DA  
RESTAURAÇÃO FLORESTAL  
VIA RPA-SFM**



## Article

# Forest Restoration Monitoring Protocol with a Low-Cost Remotely Piloted Aircraft: Lessons Learned from a Case Study in the Brazilian Atlantic Forest

Rafael Walter Albuquerque <sup>1,\*</sup>, Manuel Eduardo Ferreira <sup>2</sup>, Søren Ingvor Olsen <sup>3</sup>,  
Julio Ricardo Caetano Tymus <sup>4</sup>, Cintia Palheta Balieiro <sup>4</sup>, Hendrik Mansur <sup>4</sup>,  
Ciro José Ribeiro Moura <sup>5,6</sup>, João Vitor Silva Costa <sup>2</sup>,  
Maurício Ruiz Castello Branco <sup>7</sup> and Carlos Henrique Grohmann <sup>1</sup>

- <sup>1</sup> Institute of Energy and Environment, University of São Paulo, Prof. Luciano Gualberto Avenue, 1289, Butanta 05508-010, SP, Brazil; guano@usp.br
  - <sup>2</sup> Instituto de Estudos Socioambientais—IESA, Laboratório de Processamento de Imagens e Geoprocessamento—LAPIG/Pro-Vant, Universidade Federal de Goiás—UFG, Campus II, Cx. Postal 131, Goiás 74001-970, GO, Brazil; manuel@ufg.br (M.E.F.); joao\_vitor@discente.ufg.br (J.V.S.C.)
  - <sup>3</sup> Department of Computer Science (DIKU), University of Copenhagen, Universitetsparken 1, 2100 Ø Copenhagen, Denmark; ingvor@di.ku.dk
  - <sup>4</sup> The Nature Conservancy Brasil—TNC, Av. Paulista, 2439/91, Bela Vista 01311-300, SP, Brazil; jtymus@tnc.org (J.R.C.T.); cbalieiro@tnc.org (C.P.B.); hmansur@tnc.org (H.M.)
  - <sup>5</sup> Programa de Engenharia Ambiental, Av. Athos da Silveira Ramos, 149, Ilha do Fundão, Centro de Tecnologia—Bloco A, 2º andar, Sala DAPG—Universidade Federal do Rio de Janeiro, Escola Politécnica 21941-909, RJ, Brazil; ciro@poli.ufrj.br
  - <sup>6</sup> Instituto Estadual do Ambiente—INEA, Av. Venezuela, 110, Saúde 20081-312, RJ, Brazil
  - <sup>7</sup> Instituto Terra de Preservação Ambiental—ITPA, Rua Francisco Alves, 53, Miguel Pereira 26900-000, RJ, Brazil; mauricio@itpa.org.br
- \* Correspondence: rafael.albuquerque@usp.br



**Citation:** Albuquerque, R.W.; Ferreira, M.E.; Olsen, S.I.; Tymus, J.R.C.; Balieiro, C.P.; Mansur, H.; Moura, C.J.R.; Costa, J.V.S.; Branco, M.R.C.; Grohmann, C.H. Forest Restoration Monitoring Protocol with a Low-Cost Remotely Piloted Aircraft: Lessons Learned from a Case Study in the Brazilian Atlantic Forest. *Remote Sens.* **2021**, *13*, 2401. <https://doi.org/10.3390/rs13122401>

Academic Editor: Giovanni Santopuoli and Kim Calders

Received: 27 April 2021  
Accepted: 15 June 2021  
Published: 19 June 2021

**Publisher's Note:** MDPI stays neutral with regard to jurisdictional claims in published maps and institutional affiliations.



**Copyright:** © 2021 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

**Abstract:** Traditional forest restoration (FR) monitoring methods employ spreadsheets and photos taken at the ground level. Since remotely piloted aircraft (RPA) generate a panoramic high resolution and georeferenced view of the entire area of interest, this technology has high potential to improve the traditional FR monitoring methods. This study evaluates how low-cost RPA data may contribute to FR monitoring of the Brazilian Atlantic Forest by the automatic remote measurement of Tree Density, Tree Height, Vegetation Cover (area covered by trees), and Grass Infestation. The point cloud data was processed to map the Tree Density, Tree Height, and Vegetation Cover parameters. The orthomosaic was used for a Random Forest classification that considered trees and grasses as a single land cover class. The Grass Infestation parameter was mapped by the difference between this land cover class (which considered trees and grasses) and the Vegetation Cover results (obtained by the point cloud data processing). Tree Density, Vegetation Cover, and Grass Infestation parameters presented F\_scores of 0.92, 0.85, and 0.64, respectively. Tree Height accuracy was indicated by the Error Percentage considering the traditional fieldwork and the RPA results. The Error Percentage was equal to 0.13 and was considered accurate because it estimated a 13% shorter height for trees that averaged 1.93 m tall. Thus, this study showed that the FR structural parameters were accurately measured by the low-cost RPA, a technology that contributes to FR monitoring. Despite accurately measuring the structural parameters, this study reinforced the challenge of measuring the Biodiversity parameter via remote sensing because the classification of tree species was not possible. After all, the Brazilian Atlantic Forest is a biodiversity hotspot, and thus different species have similar spectral responses in the visible spectrum and similar geometric forms. Therefore, until improved automatic classification methods become available for tree species, traditional fieldwork remains necessary for a complete FR monitoring diagnostic.

**Keywords:** Atlantic Forest; drones; SfM-MVS; structural parameters; unmanned aerial vehicle

## 1. Introduction

Remotely piloted aircraft (RPA), popularly known as drones, present notable technical advantages in several fields, such as journalism [1] and agriculture [2]. Nevertheless, in Forest Restoration (FR) projects, the real benefits that RPA can provide still demand more studies.

Traditional FR monitoring methods employ sheets and photos taken at the ground level that do not register the whole area of an FR project, e.g., the methods described in the FR monitoring protocol of the Brazilian Atlantic Forest biome [3]. According to Viani et al. [4], the Atlantic Forest FR monitoring protocol is excellent because it provides data collection standards to avoid biases and subjectivity. As the scope of future studies, the authors stated that an automatic feedback report would improve the FR monitoring protocol. Therefore, it would be interesting to investigate whether RPA is capable of generating an automatic feedback report to efficiently support FR monitoring.

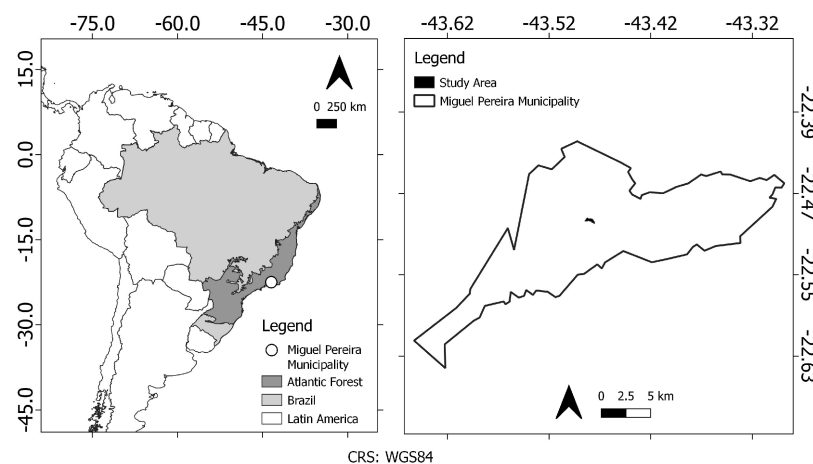
Since RPA generates a panoramic high resolution and georeferenced view of the entire area of interest [5], this technology has high potential to promote efficient FR monitoring [6]. Such potential demands studying how RPA can accurately and automatically provide the important FR monitoring parameters mentioned by McDonald et al. [7], such as tree cover, tree density, and tree species. In biomes like the Brazilian Atlantic Forest, which is a biodiversity hotspot [8], improving the FR monitoring protocol would help managing the targets stipulated under the Paris Agreement, wherein Brazil is committed to restoring 12 million hectares of forests by 2030.

This study aims to evaluate the manner in which RPA can contribute to the FR monitoring protocol of the Brazilian Atlantic Forest. Particularly, we evaluated a low-cost RPA [9] because financial resources are scarce in developing countries [10]. These findings play an important role in improving the FR monitoring protocol by considering an emerging remote sensing technology.

## 2. Materials and Methods

### 2.1. Study Area

The FR study area is located in the Brazilian Atlantic Forest biome, specifically at the Miguel Pereira Municipality in the state of Rio de Janeiro (RJ). Figure 1 illustrates this 23.45 hectare study area, where Instituto Terra de Preservação Ambiental (ITPA) conducted an FR project.



**Figure 1.** Location of the FR study area on Miguel Pereira municipality, situated in the Brazilian Atlantic Forest biome. To see the RPA orthomosaic and the study area on a greater scale, please go to Figure 3.

The traditional fieldwork with 19 field plots to officially monitor the FR occurred in October 2017. It followed the Fast Environmental Diagnosis Methodology [11], which is



Rio de Janeiro State's official FR monitoring process. In January 2018, the RPA fieldwork was conducted in the study area.

## 2.2. Materials

The RPA used in this study is a Phantom 4 Standard (a rotary wing). It is coupled with an RGB 1/2.3" 12MP camera with FOV 94° 20 mm (35 mm format equivalent) lens, Electronic Shutter Speed of 8–1/8000 s, and Image Size of 4000 × 3000. More information regarding this RPA model can be found at <https://www.dji.com/br/phantom-4>, accessed on 26 May 2021.

The flight plan was drafted using the free software Pix4D Capture for smartphones/tablets. The Digital Surface Model (DSM) and orthorectified mosaic were obtained using the Agisoft Photoscan software. The classification processes and graph generation were performed using R [12] version 3.6 and the map layouts were generated using QGIS software version 3.12. The Cloud Compare software was used to generate the Digital Terrain Model (DTM).

## 2.3. Methods

### 2.3.1. Flight Patterns

Two flights were necessary to cover the entire study area. The flights were conducted in compliance with Brazil's RPAs laws [13] at a height of 80 m and generated an 8 cm Ground Sampling Distance (GSD). The front and side overlaps were equal to 80% to generate enough details in the point cloud data [14].

No Ground Control Points (GCPs) were collected by a geodetic Global Navigation Satellite System (GNSS) equipment, and thus the orthomosaic precision was around 3 m [15]. Such cartographic precision is considered enough for this study because change detection over time was not performed in this study [16].

### 2.3.2. Estimation of Forest Restoration Biodiversity Using Low-Cost RPA

Tree species were not distinguishable by photointerpretation on the RPA orthomosaic, as illustrated in Section 3. Thus, the estimation of the FR parameter Biodiversity by low-cost RPA was not considered in this study. Instead, this study focused on the FR structural parameters, which play an important role in FR monitoring [7]. The remotely measured FR structural parameters were Tree Density, Vegetation Cover, Tree Height, and Grass Infestation. Figure 2 shows the workflow for obtaining these FR structural parameters and the accuracy assessment. Sections 2.3.3–2.3.7 describe each step presented in Figure 2.

### 2.3.3. FR Structural Parameter: Tree Density

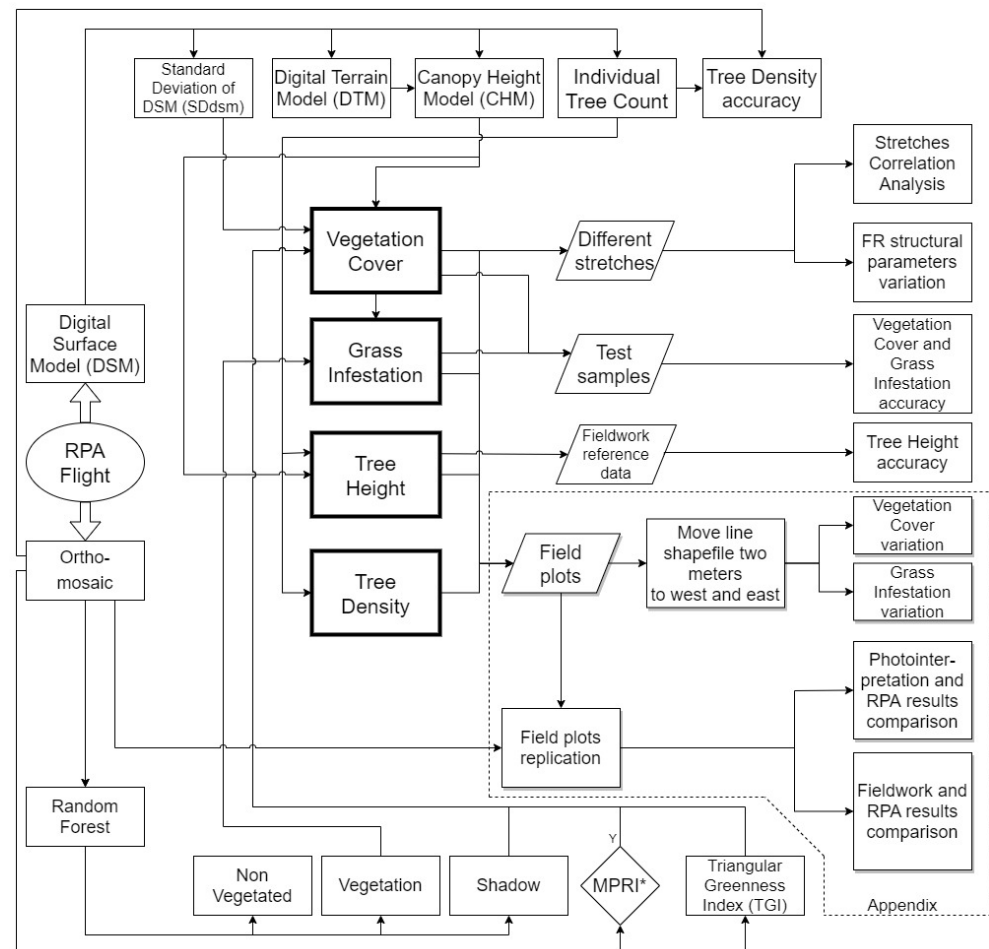
To estimate the Tree Density parameter, individual trees must be counted. Some studies have counted trees automatically using the Canopy Height Model (CHM) database [17], as the CHM is the difference between the DSM and the DTM [18]. In this work, the DTM was created by applying the Cloth Simulation Filter algorithm [19] in Cloud Compare software. Since the study area was sloping and contained some small trees, which were slightly higher than the grasses, these short trees were omitted in the DTM generation, and the CHM was consequently affected. Thus, the individual tree count was obtained directly from the DSM to increase automatic tree counting accuracy, as described in Albuquerque et al. [14].

The Local Maximum algorithm [20,21] of the rLiDAR R package [21] was used on the DSM to obtain the individual tree count. This algorithm searches for the highest value on a fixed window-sized kernel and generates a point table with geographic coordinates of the encountered maximum values. Individual tree count is then obtained by a coordinate set, where each coordinate represents the highest location of a tree crown.

To avoid the individual tree count commission errors (false-positives), two or more coordinates with a distance of less than 10 cm between them were excluded because they represent the same tree. Then, the geographic coordinates of the point halfway between these excluded points were retained to represent the tree. The ten-centimeter threshold

value was defined because forest inventories consider only trees with trunk diameters of >5 cm [22], and thus trees must be at a distance of at least 10 cm from each other. More details about the individual tree count method applied in this work can be found in [14].

After the individual tree count was determined, the number of identified trees was divided by 23.45 hectares (size of the study area) to obtain the tree density.



**Figure 2.** Methodology workflow of this study. MPRI is the Modified Photochemical Reflectance Index [23] and should be used only in the absence of shadow.

#### 2.3.4. FR Structural Parameter: Tree Height

Tree height was determined in two steps: (1) extracting the CHM value corresponding to each geographic coordinate in the individual tree count; (2) calculating the mean of these extracted values. The height values were obtained from the individual tree count results as they correspond to the largest tree crown height value.

#### 2.3.5. FR Structural Parameter: Vegetation Cover

To determine vegetation cover using RPA imagery, trees and grasses must be adequately distinguished. Vegetation cover involves the area covered by trees and not by grass, as Grass Infestation is a FR structural parameter described in Section 2.3.6. This study therefore considers that the variable vegetation is the sum of Vegetation Cover and Grass Infestation.

$$\text{Vegetation} = \text{VegetationCover} + \text{GrassInfestation} \quad (1)$$

Vegetation mapping was performed using a Random Forest supervised classification involving three land cover classes according to Reis et al. [24] and Laliberte et al. [25]: vegetation, shadow, and non-vegetated.

When using RPA to determine the vegetation cover, the CHM should involve only areas with trees, and therefore an accurate CHM would by itself provide the Vegetation Cover parameter. As explained in Section 2.3.3, trees that were slightly higher than grasses on sloping areas were excluded during CHM acquisition, and thus this database could not be used by itself to accurately obtain Vegetation Cover. To isolate Vegetation Cover, vegetation indexes like the Triangular Greenness Index (TGI) (Equation (2)) [26] can be an alternative.

$$TGI = [(Green - 0,39) * (Red - 0,61)] * Blue \quad (2)$$

TGI is not a normalized index, and vegetated areas tend to present negative values. In this work, the TGI could distinguish between trees and grasses, but it did not provide a final Vegetation Cover result on its own because some trees or some parts of tree crowns were missing, and thus the Standard Deviation of DSM (SDdsm) was also used for Vegetation Cover mapping.

The Standard Deviation of DSM (SDdsm) may be used to avoid confusion between trees and grasses because it has presented good results in detecting homogeneous topographic surfaces [27] and the arboreal stratum [28]. However, in medium-aged FR projects, like the one in this study, the height of trees varies considerably, and thus the application of SDdsm for vegetation cover mapping presents some limitations and should be used along with other variables.

Thus, the Vegetation Cover result acquired by RPA in this study was the sum of TGI Vegetated areas (TGIVeg), Standard Deviation of DSM (SDdsm), and CHM. As indicated by Equation (3), the sum of these variables for the Vegetation Cover mapping also involved the exclusion of shaded areas.

$$VegetationCover = [(TGIVeg + SDdsm + CHM) - (3 * Shadow) > 0] \quad (3)$$

Each variable in Equation (3) is a raster containing values equal to zero (means no occurrence) or one (means occurrence). Furthermore, in Equation (3), it is noteworthy that shaded areas, obtained by the land cover class Shadow, are multiplied by the number of layers containing vegetation areas. This ensures that areas mapped as vegetation by more than one vegetation layer will receive zero or negative values when they are overlapping with shaded areas. Moreover, if the values of the variables in Equation (3) are selected to be greater than zero, the equation can be solved using one line of computation code, instead of two.

Regarding the Modified Photochemical Reflectance Index (MPRI) [23], it did not contribute to Vegetation Cover mapping in this work because it generated a large amount of confusion with shaded areas.

### 2.3.6. FR Structural Parameter: Grass Infestation

In reality, Grass Infestation may overlap with Vegetation Cover because grass grows below a tree crown. However, Structure from Motion and Multi-View-Stereo [29,30], or SfM-MVS, is unable to record the surface below the tree crowns, and thus, in this study, it is considered that Grass Infestation does not overlap with Vegetation Cover.

Therefore, Grass Infestation mapping was conducted using Equation (1), which led to Equation (4) because Section 2.3.5 describes Vegetation and Vegetation Cover acquisition.

$$GrassInfestation = Vegetation - VegetationCover \quad (4)$$

### 2.3.7. Accuracy Evaluation

Remote measurements in environmental projects must be conservative, which means that overly optimistic results must be avoided [31]. Regarding the Grass Infestation struc-

tural parameter, as it is an undesirable variable in the Brazilian Atlantic Forest biome, an estimation containing more commission than omission errors is considered conservative. For Vegetation Cover, Tree Height, and Tree Density, which are desirable variables, the conservative path involves more omission than commission errors. In other words, FR classification results obtained using remote sensing must avoid commission errors in desirable FR structural parameters and avoid omission errors in undesirable FR structural parameters.

To estimate Tree Density in closed-canopy conditions, fieldwork may be necessary for acquiring reference data because the boundaries of the overlapping tree crowns may not be clearly identifiable by photointerpretation [32,33]. Since the canopy was not closed in the study area, a photointerpretation qualitative analysis [34] evaluated the accuracy of Tree Density. This qualitative analysis allowed the acquisition of omission and commission errors, or the amount of False-Positive (FP) and False-Negative (FN) occurrences, as well as the Overall Accuracy [35]. Recall, Precision, and F\_score indexes [36] were then calculated according to Equations (5)–(7), respectively.

$$r = \frac{TP}{(TP + FN)} \quad (5)$$

$$p = \frac{TP}{(TP + FP)} \quad (6)$$

$$F_{score} = 2 * \frac{(r * p)}{(r + p)} \quad (7)$$

where:  $TP$  = True Positive,  $FN$  = False Negative,  $FP$  = False Positive,  $r$  = recall,  $p$  = precision.

Vegetation Cover and Grass Infestation accuracies were measured using a Confusion Matrix, along with Overall Accuracy, Producer's Accuracy, User's Accuracy, F\_score, and Kappa Index. In total, 50 test samples were used for each of the three classes: Vegetation Cover, Grass Infestation, and Other Classes.

Tree Height is the only FR structural parameter in this study that cannot be evaluated by photointerpretation. Therefore, the accuracy of this parameter was measured using the Error Percentage [37] between the fieldwork and RPA results (Equation (8)).

$$ErrorPercentage = \frac{(Reference - Results)}{(Reference)} \quad (8)$$

### 2.3.8. Evaluating FR Structural Parameters Values in Stretches with Different FR Success

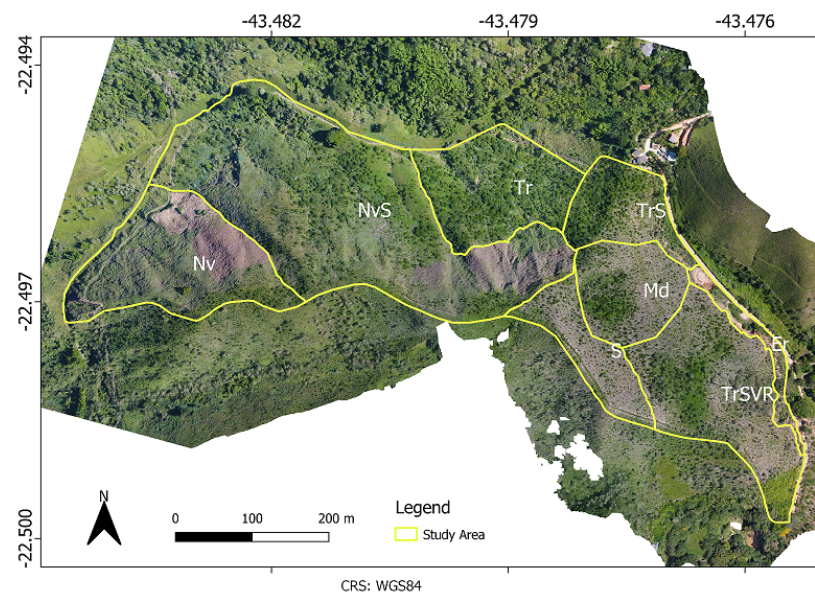
Since RPA can be used to map the entire project area, stretches with different vegetation singularities can be noticed [38]. In that case, stretches with more, less and intermediate FR success within the study area were manually separated by photointerpretation. The intermediate FR success stretches in this work were a mix of more and less FR successful areas. Figure 3 illustrates the polygons that represent these stretches.

A boxplot and correlation matrix quantitatively indicated if the different stretches in Figure 3 have different FR structural parameters. The boxplot illustrated how the FR structural parameters values vary between the final fieldwork results (the final fieldwork results can be found in Appendix A.3), as shown by Equation (9).

$$ErrorPercentage_{stretch} = \frac{(Fieldwork - RPA_{stretch})}{(Fieldwork)} \quad (9)$$

Thus, for each FR structural parameter, a boxplot graph was used to evaluate how the Error Percentage (Equation (9)) varied among the different FR stretches.


Furthermore, for example, to assess whether a high value of Vegetation Cover is associated with low values of Grass Infestation (it is expected that grass reduces as the canopy closes), a correlation matrix of the RPA results in the different stretches was evaluated.



**Figure 3.** Study area divided into 8 different stretches with more, less, and mixed quantities of forested areas (FR success): Non-vegetated predominance (Nv), Non-vegetated mixed with Seedlings (NvS), Trees predominance (Tr), Trees mixed with Seedlings (TrS), Seedlings predominance (S), Trees mixed with Seedlings mixed with Vegetation Remnants (TrSVR), Erosions (Er) and Model (Md). The Md stretch was the one that best represented the whole study area in general.


### 3. Results

Regarding the Biodiversity parameter, it was not possible to identify tree species when replicating field plots in the RPA image. As shown in Figure 4, the study area has different tree species that presented similar spectral responses in the visible spectrum and similar geometric forms in the RPA image, which makes the classification process not possible because the human eye cannot state the difference [39]. Thus, traditional fieldwork will continue being necessary to record tree species in FR projects, and future studies should evaluate the performance of other types of sensors, such as multispectral and hyperspectral, in the estimation of Biodiversity.




**Figure 4.** There are at least six different tree species in the rectangle area, but all of them are very similar, and none could be distinguished by photointerpretation.


Regarding the FR structural parameters, which were the focus of this study, Figures 5–7 show the RPA results in the whole study area. Figure 8 shows a zoomed-in version of the RPA results in the study area.




**Figure 5.** Individual Tree Count results of the RPA study area, which provided the Tree Density result when dividing all the identified trees by the area.



**Figure 6.** The Vegetation Cover and Grass Infestation results of the RPA study area.



**Figure 7.** The Canopy Height Model (CHM) results of the RPA study area, which provided the height of the trees that were automatically identified. The zero CHM values mean grasses or non-vegetated (bare soil) areas.



**Figure 8.** FR structural parameters results of the study area in a high mapping scale. (a) The RPA orthomosaic. (b) The Individual Tree Count, which provided the Tree Density result when dividing all the identified trees by the area. (c) The Vegetation Cover and Grass Infestation results. (d) The Canopy Height Model (CHM), which provided the height of the trees that were automatically identified and where zero CHM values means grasses or bare soil areas.

### 3.1. Vegetation Cover and Grass Infestation Accuracy

The Confusion Matrix shown in Table 1 presents high accuracy indexes for Vegetation Cover and medium accuracy indexes for Grass Infestation. The Overall Accuracy and the Kappa index of the Confusion Matrix are equal to 0.75 and 0.63, respectively. The  $F_{score}$  value was equal to 0.85 and 0.64 for Vegetation Cover and Grass Infestation, respectively.  $F_{score}$  ranges from 0 to 1 and has been widely used [14,17,32,33,40–44], and thus 0.85 and 0.64 can be considered high and medium accuracy values, respectively.

**Table 1.** Confusion Matrix for measuring Vegetation Cover (Trees) and Grass Infestation (Grass) accuracy.

		Target				
		Grass	Trees	Other Classes	Producer's Accuracy	User's Accuracy
Prediction	Grass	26 (52%)	5 (10%)	0 (0%)	52%	84%
	Trees	1 (2%)	41 (82%)	4 (8%)	82%	89%
	Other Classes	23 (46%)	4 (8%)	46 (92%)	92%	63%

### 3.2. Tree Density Accuracy


The Individual Tree Count method to obtain Tree Density presented Recall, Precision, F\_score, and Overall Accuracy values equal to 0.93, 0.90, 0.92, and 0.87, respectively. These are considered high accuracy results. However, Individual Tree Count presented 10% of commission errors (undesirable for Tree Density), which may have influenced the achievement of accurate results because omission errors were compensated.

### 3.3. Tree Height Accuracy

The Tree Height value was equal to 1.68 m and 1.93 m when obtained using RPA and fieldwork (reference data), respectively. With such results, the Error Percentage was equal to 0.13, and thus Tree Height was accurate when measured by RPA because it is a conservative result that estimates a 13% shorter height for trees that are almost 2 m tall.

### 3.4. FR Structural Parameters Values in Stretches with Different FR Success


The stretches with different FR success, described in Section 2.3.8, presented some variation in the RPA results. As Figure 9 shows, only Vegetation Cover presented small variation among the different stretches, suggesting the presence of small tree crowns in general because Tree Density varied more considerably. Furthermore, some variations in Tree Height, Tree Density and Grass Infestation reinforce the occurrence of different FR success that were indicated by photointerpretation.



**Figure 9.** FR structural parameters of the stretches with different FR success varied from the fieldwork reference value, except Vegetation Cover. A variation in Tree Density and non-variation of Vegetation Cover suggest small tree crowns in general.



Figure 10 shows that the FR structural parameters presented some correlation between them. Such correlation suggests some ecological succession process: Grass Infestation has a high negative correlation with the development of trees; the taller the trees, the bigger the tree crowns (high correlation between Tree Height and Vegetation Cover); and many trees presented small tree crowns (medium correlation between Tree Density and Vegetation Cover).



**Figure 10.** FR structural parameters Correlation Matrix between different FR stretches. In this symmetric matrix, the cells of the main diagonal shows a FR structural parameter (TD is Tree Density, VC is Vegetation Cover, TH is Tree Height, and GI is Grass Infestation) and its corresponding values in the different FR stretches. The other cells show the correlation value between different FR structural parameters, where the more asterisk (“\*\*”) symbol occurs, the more correlated two variables are.

#### 4. Discussion: Lessons Learned

In this study, we present the Discussion section as lessons that were learned, and thus each lesson is presented as a subsection. The subsection title represents the lesson itself, while the corresponding text complements and discusses it. By highlighting each lesson as a subsection, we intend to make its discussion easier to be found in the manuscript.

##### 4.1. Low-Cost RPA Is Capable of Accurately Mapping Forest Restoration (FR) Structural Parameters in Open Canopy Conditions

Although previous works accurately evaluated tree cover and tree height using low-cost RPA [44–46], this study evaluated four structural parameters (Vegetation Cover, Tree Height, Tree Density and Grass Infestation) in the context of FR and in a sloping area, which represents a common situation in the Brazilian Atlantic Forest Biome.

RPA works at the local scale only [47], but if a regional scale is desired, the Landsat satellite, although having a lower spatial resolution when compared to other remote sensing databases, showed potential for monitoring the vegetation expansion of FR projects throughout the years [48]. Still regarding FR monitoring at the regional scale, initiatives like the MapBiomas project (<https://mapbiomas.org/>, accessed on 15 June 2021) show the locations of secondary forests for free.

The Landsat free available satellite imagery may provide valuable information, but its spatial resolution generates inconsistencies when more refined data is needed to evaluate the FR [47]. Thus, each technology has advantages and disadvantages, and this work reinforces that low-cost RPA is a good alternative for collecting data to monitor the FR at the local level. Since low-cost RPA is capable of accurately mapping FR structural

parameters in open canopy conditions, future studies shall evaluate FR areas with closed-canopy conditions.

#### *4.2. To Improve the Accuracy of the Tree Height Measurement by Low-Cost RPA in All the FR Stages, a Possible but Expensive Solution would be Using Precise Global Navigation Satellite System (GNSS) Data*

Although the Tree Height was accurate in this work, the CHM omitted trees that were slightly higher than grasses in the sloping area. To handle this situation, a flight prior to the tree growth using precise GNSS coordinates could obtain an accurate (or a literal) DTM. Then, after the FR process begins (after trees begin to grow), an accurate CHM would be possible due to a refined DTM availability for the future RPA data acquisition, which would also demand precise GNSS coordinates.

Besides checking if a precise DTM would include small trees in the CHM of sloping FR areas, the use of precise GNSS data would also confirm if the accuracy of the tree height measured using SfM-MVS increases even when the canopy closes. The use of traditional topography methods (when geodetic GNSS equipment and total station are required) generates a refined DTM in closed-canopy conditions, which allows accurate Tree Height measurements via SfM-MVS [49]. However, classic topography increases the costs of the projects due to the time spent in the field [50] and to the costs of the equipment [51], and thus the benefits of using ground control points for Tree Height measurement via RPA data collected before and after the tree growth must be carefully studied in the future.

To avoid collecting precise GNSS data on every RPA flight for the Tree Height measurement, survey markers can be installed on the FR surroundings, and thus the precise geographic coordinates can be collected only once. After collecting the precise GNSS coordinates, the survey markers can become ground control points (GCP) for the RPA data by putting visual targets above them before each RPA flight. The location of the survey markers has to be the FR surroundings because they must be visible on the RPA data after the canopy closes.

Alternatively, to avoid using survey markers or precise GNSS coordinates on every SfM-MVS cartographic data, collecting different RPA images of the same area along the FR evolution could enable an independent analysis of each orthomosaic until the canopy closes. Future studies may confirm if precise GNSS coordinates are necessary only for a precise DTM generation (when trees have not started to grow) and for the RPA images acquired after the canopy closes.

Tree Height is a relevant structural parameter because it is related to ecology [52], biomass [49,53], and biodiversity [53,54], and measuring it in closed-canopy conditions is not an issue in LiDAR systems [46,53,55]. However, LiDAR systems are considered more expensive, which is not ideal for the financial reality of developing countries [10]. Thus, more studies of Tree Height measurement by SfM-MVS in closed-canopy conditions must be conducted. Tree Height measured by RPA is a field of research that may benefit not only the FR and mature forests, but also different commercial plantations and crops [56].

#### *4.3. Via Photointerpretation, RPA Can Identify Stretches with Different FR Success That Present Different Values of FR Structural Parameters*

One of the advantages of RPA is that the entire FR area can be measured, and thus stretches with different degrees of FR success were visually identified. The values of the FR structural parameters in these stretches presented some variation from the fieldwork reference value, as indicated by the standard deviation of the boxplots shown in Figure 9.

Although the RPA has the advantage of identifying stretches with different FR success, such benefit occurs at the local scale only. If a regional FR monitoring scale is required, Landsat images, due to its spatial resolution, have the potential to identify only considerable increases in vegetation cover [48].

The possibility of identifying stretches with different FR success via photointerpretation of the low-cost RPA orthomosaic reinforces another advantage of monitoring FR using high spatial resolution images: it provides valuable information in open-canopy conditions

even if no more data of the FR site, like field plots, is available. Since photointerpretation of low-cost RPA orthomosaic generates reference data for Tree Cover, Tree Density and Grass Infestation, which are relevant structural parameters, managers can check stretches with less FR success that may need some intervention using RPA data only.

Besides being capable of identifying stretches with different FR success, the FR structural parameters evaluated in this study were based on the Rio de Janeiro local environmental agency [11], and Tree Height was the only FR structural parameter that demanded a traditional fieldwork for reference data acquisition in open canopy conditions. Traditional fieldworks are necessary to evaluate the computational 3D modeling because it is not possible to check tree heights using a photointerpretation of the CHM. Even LiDAR systems that accurately measured Tree Height demanded traditional fieldwork for acquiring reference data [46,53,55]. Thus, Tree Height is the only FR structural parameter evaluated in this study that demands fieldwork to assess its remote sensing accuracy, which reinforces that low-cost RPA data register valuable information for FR projects even if no field plot data is available.

#### *4.4. RGB Limitations for Identifying Different Tree Species Reinforced That Biodiversity and Remote Sensing Constitute a Specific Field of Research and That Traditional Fieldwork Will Continue Being Necessary in the Future*

Although modern Computer Vision techniques, such as Deep Learning, have demonstrated that low-cost RPA can be used to identify palm species in the Amazon [32] or tree species in a German forest [33], it is still not possible to handle the biodiversity of Brazilian FR projects solely via high-resolution RGB imagery. The tree species of the Atlantic Forest Biome in this study looked very similar in the RPA imagery, but since the Biodiversity parameter is relevant for FR projects, future works must check if other species, which were not present in the study area, are distinguishable in high-resolution RGB images. These future studies must generate two databases with precise Global Navigation Satellite Systems (GNSS) geographic coordinates: the low-cost RPA data, which must present ground control points to improve its cartographic precision (1); and the tree species location, which must be a layer where each tree has a precise geographic coordinate associated with its corresponding species. These two databases will make it possible to verify which tree species are distinguishable via photointerpretation.

In this work, even if the two databases mentioned in the previous paragraph (RPA data and tree species location with precise GNSS coordinates) were available, the Biodiversity parameter would still not be possible to be measured via low-cost RPA because photointerpretation could not distinguish different tree species. After all, the targets in the images must be visually distinguishable for a proper reference data [35,39]. A possible solution for this low-cost RPA limitation for recognizing different species may be the flowers of the trees. The flowers can make some tree species distinguishable via photointerpretation, but the remote sensing data must be collected in the flowering period [42], which reinforces the challenge involving Biodiversity and remote sensing.

Another alternative for measuring the Biodiversity parameter via remote sensing would be an estimation of the number of species in a FR site instead of the identification of the species of each tree. When dealing with the number of species, an unsupervised classification could be applied, but reference data would still be necessary [35,57]. In this study, as previously mentioned, there was no reliable Biodiversity reference data for remote sensing estimations due to a significant similarity between the different tree species in the RPA imagery.

Almeida et al. [53] used a refined remote sensing dataset provided by a LiDAR system and also mentioned a biodiversity challenge in the Atlantic Forest Biome because the authors accurately measured canopy structure and above-ground biomass of FR areas, but not species richness. Alonzo et al. [58] used LiDAR and hyperspectral sensors to map 29 tree species considering 30 different remote sensing classes: 29 classes corresponded to 29 different tree species, while 1 class involved different and non-frequent tree species. Thus, regarding the biodiversity challenge, even if multispectral, hyperspectral, or LiDAR sensors

prove to be capable of automatically identifying tropical rainforest species in the near future, the costs of such sensors must decrease considerably if a practical FR monitoring protocol is desired. Traditional fieldwork will therefore continue being necessary and remote sensing may be applied using applications onboard smartphones and tablets, like Agrotag [59], for monitoring the FR biodiversity.

Applications onboard smartphones and tablets like Agrotag can take pictures at the ground level of the tree species and can also share the FR monitoring data collected by field plots on an online Geographic Information System (GIS) platform. Future studies may evaluate if using a low-cost RPA for measuring the structural parameters and an application onboard smartphones and tablets for measuring the Biodiversity parameters are capable of accurately providing a full FR monitoring report.

## 5. Conclusions

For the development of a practical FR monitoring protocol, low-cost RPA was found to be accurate for the measurement of the FR structural parameters. Only Grass Infestation, which is the least important indicator, presented medium accuracy. In addition to improving the accuracy of the Grass Infestation parameter, future studies must evaluate the optimal remote sensing techniques for FR projects of different ages, with a particular focus on how low-cost RPA can accurately measure the FR structural parameters when the canopy is closed. After all, each FR stage will require different remote sensing techniques.

Although low-cost RPA can accurately measure the structural parameters, it cannot accurately measure the FR biodiversity parameter in the Brazilian Atlantic Forest, and thus traditional fieldwork will continue being necessary. It may be possible to utilize an RPA and then use field plots for biodiversity monitoring only, but this would require FR consultants and environmental agencies to evaluate the costs of adding a remote sensing professional to their teams.

**Author Contributions:** Conceptualization, R.W.A., M.E.F., C.P.B., M.R.C.B. and C.H.G.; methodology, R.W.A.; software, R.W.A. and C.H.G.; validation, R.W.A., M.E.F., S.I.O. and C.H.G.; formal analysis, R.W.A., M.E.F. and C.H.G.; investigation, R.W.A., H.M. and J.V.S.C.; resources, R.W.A., M.E.F., H.M., J.V.S.C. and C.H.G.; data curation, R.W.A. and C.J.R.M.; writing—original draft preparation, R.W.A.; writing—review and editing, R.W.A., M.E.F., S.I.O., C.J.R.M. and C.H.G.; visualization, R.W.A., M.E.F., S.I.O., C.J.R.M. and C.H.G.; supervision, R.W.A. and C.H.G.; project administration, R.W.A., M.E.F., J.R.C.T. and C.P.B.; funding acquisition, J.R.C.T., C.P.B. and C.H.G. All authors have read and agreed to the published version of the manuscript.

**Funding:** This study was financed in part by The Nature Conservancy Brazil (TNC) and in part by the Coordenação de Aperfeiçoamento de Pessoal de Nível Superior—Brasil (CAPES)—Finance Code 001. M.E.F. (grant #315699/2020-5) and C.H.G. (grant #423481/2018-5 and #304413/2018-6) are CNPq Research Fellows. The APC was funded in part by The Nature Conservancy Brazil (TNC) and in part by the Coordenação de Aperfeiçoamento de Pessoal de Nível Superior—Brasil (CAPES)—Finance Code 001 of the Programa de Pós-Graduação em Ciência Ambiental (PROCAM) from University of São Paulo (USP).

**Acknowledgments:** The authors thank The Nature Conservancy Brazil (TNC), the field support of Instituto Terra de Preservação Ambiental (ITPA), Laboratório de Engenharia Cartográfica (LECAR) from Universidade Estadual do Rio de Janeiro (UERJ) and the Federal University of Goiás/LAPIG/Pro-Vant for the provision of RPA equipment. We also thank the SPAMLab at IEE-USP for data processing and analysis infrastructure. We are thankful to the landowners of the forest restoration areas (ITPA's partners) for authorizing our access and to Instituto Estadual do Ambiente (INEA) for the FED methodology results grant.

**Conflicts of Interest:** The authors declare no conflict of interest. The funders had no role in the design of the study; in the collection, analyses, or interpretation of data; in the writing of the manuscript, or in the decision to publish the results.

## Appendix A. Field Plot Replication in RPA Imagery

### Appendix A.1. Methods: Field Plot Replication in RPA Imagery


As mentioned in Section 2.3.2, a field plot replication in the RPA image was initially motivated to study the Biodiversity parameter, but since all trees were very similar in the RPA image, an evaluation of the FR structural parameters inside the polygons that represent the field plots was conducted.

The rectangle shapefiles that represented the  $25 \times 4$  m field plots were generated like the fieldwork procedures, where the field plots coordinates correspond to the southernmost latitude and middle longitude of the field plot rectangles. From these coordinates, 25 m lines were generated with  $0^\circ$  Azimuth. The field plot rectangle is then completed by considering 2 m from each perpendicular direction of the 25 m line, forming a  $25 \times 4$  m plot rectangle [11]. Figures A1 and A2 illustrates examples of this field plot rectangle procedure.

When analyzing the RPA results inside the field plot rectangles, two different reference data were considered due to the cartographic uncertainty of the orthomosaic and of the field plot location. These two reference data were the photointerpretation of the field plot rectangles (photointerpretation has no cartographic uncertainty with the RPA results because both came from the same database) and the fieldwork data of each field plot. The differences between the RPA accuracy results considering these two reference data were then recorded and analyzed. The accuracy measurement unit is described in Appendix A.2.

When generating the photointerpretation of the field plots rectangles as Figure A2 shows, the authors stated that the position of the 25-m line considerably influences Vegetation Cover and Grass Infestation parameters. To quantitatively measure such an influence, an experiment was conducted where Vegetation Cover and Grass Infestation were measured in different positions over the RPA image, as explained in the next paragraphs.

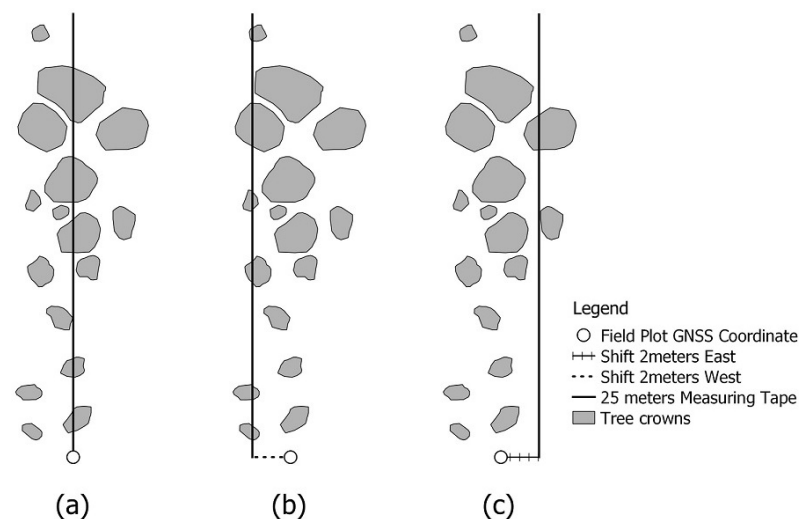
In traditional fieldwork, Vegetation Cover is obtained by stretching a 25 m measuring tape on the floor. The length of the measuring tape covered by trees is noted and then divided by 25 m. If, for example, the number of meters covered by trees is 25 or 12.5, you get 100% and 50% of Vegetation Cover, respectively. Figure A1 illustrates the fieldwork procedures for the Vegetation Cover measuring procedure.



**Figure A1.** Vegetation Cover measuring procedure on a  $25 \times 4$  m plot, where LT is Linear Totality. In the fieldwork procedures, LT is equal to 25 m, and the field plot is defined by considering 2 m from each LT perpendicular direction, forming then a  $25 \times 4$  m plot. L1, L2, and L3 are examples of linear measurements in LT that are covered by trees. Thus, Vegetation Cover is the sum of L1, L2, and L3 divided by LT. Source: adapted from INEA [11].

When applied to RPA imagery, this method can be subject to some issues because Vegetation Cover is an area measurement (two dimensions), and the measuring tape measures lengths (one dimension). As can be seen by Figure A1, if the measuring tape moves 2 m to the left or the right in an RPA image, the Vegetation Cover parameter may considerably vary.

To verify if moving the measuring tape 2 m to the left or the right considerably affects Vegetation Cover on RPA imagery, an experiment was conducted. In such an experiment, the amount of line that covered trees was verified by photointerpretation in three different positions for each field plot. In the first position, the 25-m line is in the field plot coordinate (which is the position for measuring Vegetation Cover according to the fieldwork procedures). In the second and third positions, the line shifted 2 m to the left (west direction) and 2 m to the right (east direction). After verifying the amount of tree cover on these positions, the variation (between the first position and the other two positions) was noted in percentage. Regarding the 2 m value, it represents an usual imprecision value of a common GNSS equipment [60], and it is also the value that the fieldwork procedures move (to the left and the right) to generate a  $25 \times 4$  m plot. Figure A2 illustrates this 2-m shifting process evaluation.



**Figure A2.** An experiment to quantitatively measure the influence of the measuring tape position in Vegetation Cover acquisition if trying to replicate the fieldwork procedures on RPA imagery. Vegetation Cover value from the middle longitude of the field plot, which is where the measuring tape is positioned in the fieldwork procedures, (a) was compared to the Vegetation Cover value when moving the measuring tape 2 m in the west direction (b) and the east direction (c).

If this experiment, illustrated in Figure A2, confirms that Vegetation Cover considerably varies when moving the line shapefile, remote sensing may be reinforced as an alternative to improve this variable measurement. It would also verify that replicating traditional fieldwork procedures over RPA images is not a good idea.

Such an experiment of moving the measuring tape 2 m to the right and the left was also made for Grass Infestation because it has the same Vegetation Cover fieldwork procedures that are illustrated in Figure A1.

It must be mentioned that when comparing RPA and fieldwork results, some issues found that the overflowed study area did not involve the whole area monitored by fieldwork results. Overall, 19 out of 28 field plots, which corresponds to 23.45 out of 28.55 hectares of the FR area, were covered by the RPA imagery, while Vegetation Cover and Grass Infestation fieldwork values were not recorded for each field plot (only the final value was recorded). This means that 17.8% ( $(28.55 - 23.45) / 28.55 = 0.178$ ) of the area monitored by fieldwork procedures, and not by RPA imagery, contained 32% of the field plots. Regarding those not overflowed field plots, Google Earth's free available imagery showed by photoint-

erpretation that these were the FR areas with the highest tree cover (canopy was almost closed), which could also suggest the highest values of other FR structural parameters.

#### *Appendix A.2. FR Structural Parameters Accuracy Evaluation Inside Field Plots*

When replicating the FR structural parameters inside the field plots, it is expected for RPA results to present values closer to the photointerpretation reference data than to the fieldwork reference data because there is no cartographic uncertainty.

RPA classification results inside the field plot rectangles had their accuracy evaluated via Error Percentage [37], where zero Error Percentage means 100% accuracy, positive percentage values are omission errors, and negative percentage values are commission errors. For example, an Error Percentage of 5% means FR structural parameters lacked 5% of the reference data value (omission error), and an Error Percentage of −4% means FR structural parameters exceeded 4% of the reference data value (commission error). Equation (8) shows the calculation of Error Percentage, where “Reference” can be photointerpretation or fieldwork and “Results” are the RPA results automatically obtained.

The variation in Vegetation Cover and Grass Infestation in the experiment illustrated in Figure A2 was also calculated like Equation (8), but considering that “Reference” in Equation (8) is the “25 meters Measuring Tape” in Figure A2, and “Results” in Equation (8) is “Shift 2 meters East” or “Shift 2 meters West” in Figure A2. These variations in Vegetation Cover and Grass Infestation were measured for each field plot.

#### *Appendix A.3. Results: RPA and Fieldwork Data Comparison Inside Field Plot Rectangles*


Although Grass Infestation was the only FR structural parameter with medium accuracy as Section 3.1 shows, Table A1 shows some differences between RPA and fieldwork results. Such differences occurred because the RPA orthomosaic did not cover 33% of the whole field plots, as mentioned in Appendix A.1. Furthermore, stretches with non-vegetated and seedlings predominance (Nv and NvS in Figure 3) occupied 52.3% of the RPA study area, and these areas presented 21.4% of the field plots.

**Table A1.** RPA and fieldwork data comparison.


FR Structural Parameter	RPA	Fieldwork
Vegetation Cover (%)	27.80	55
Tree Density (trees/hectare)	814	1428
Tree Height (meters)	1.68	2
Grass Infestation (%)	27.57	25

When analyzing RPA results inside field plot rectangles, the Error Percentage was generally smaller with photointerpretation reference data than with fieldwork reference data, as Figure A3 shows.

Regarding Grass Infestation, a significant variation of its Error Percentage is presented in Figure A3. As Figure A4 shows, Grass Infestation may considerably vary if moving the measuring tape (or the 25-m line shapefile) two meters to the left or right, as described in Appendix A.1. Such variation reinforces remote sensing as a proper way for measuring Vegetation Cover and Grass Infestation.



**Figure A3.** RPA results' Error Percentage inside field plots when considering two reference data: photointerpretation and fieldwork.



**Figure A4.** When measuring Vegetation Cover and Grass Infestation by a 25-m line shapefile, which is a simulation of the traditional fieldwork procedure, these FR structural parameters significantly varied when moving the measuring line 2 m in east and west directions. The registered Error Percentage presented mean and standard deviation equal to  $11.48 \pm 39.45$  for Vegetation Cover and  $-20.3 \pm 54.61$  for Grass Infestation.

#### Appendix A.4. Discussion: Lessons Learned when Replicating Field Plots in RPA Imagery

**RPA and fieldwork results differ when whole field plots are not overflowed.** RPA and fieldwork results presented quite some differences between them because 17.9% of the area analyzed by fieldwork was not included in the RPA study area. Despite such differences, RPA can contribute to the traditional fieldwork sampling process because it registers whole project areas, so it is possible to identify stretches with different FR success that lack or exceed field plot samples. For instance, stretches with grass predominance occupied 52.3% of the RPA study area, but presented 21.4% of the field plots.



**Due to the cartographic uncertainty between fieldwork data and RPA imagery, the RPA results get closer to the photointerpretation than to the fieldwork data of each field plot.** Error Percentage inside field plots was smaller with photointerpretation reference data than with fieldwork reference data, as Figure A3 shows. If both the RPA orthomosaic and the fieldwork data presented precise GNSS coordinates, the Error Percentage variation shown in Figure A3 would probably be smaller. However, one must consider that precise GNSS coordinates increase the fieldwork costs [50].

**Measuring Vegetation Cover and Grass Infestation over RPA image by field plots procedure (25-m line) generates inconsistencies, reinforcing the RPA potential in measuring these variables by remote sensing techniques.** Since Vegetation Cover and Grass Infestation are a two-dimension variable, measuring them by a line (one dimension) using RPA imagery is a source of many errors. The experiment of moving the line shapefile 2 m to the left and right showed significant variation in Vegetation Cover and Grass Infestation results, as illustrated in Figure A4. This fact confirmed that linear field measurements based on measuring tape should not be used in RPA images.

**If the FR professionals wish to use precise GNSS coordinates to record the field plots location, they may consider turning the fieldwork rectangular plots into the Quadrat Method [61], which uses points.** The Rio de Janeiro State official FR monitoring methodology has the option of using points instead of lines for field plots design. In these situations, each sampling point would be a precise GNSS coordinate (or also a ground control point of the RPA image), and the fieldwork analysts could collect the phytosociological data while the geodetic GNSS tracks its location. However, precise GNSS data usage increases the fieldwork costs [50].

**Remote sensing and forest inventory are different sciences, but their final overall results must be similar. Although an obvious lesson, photointerpretation and traditional fieldwork presented some differences in this work because the whole FR area was not overflowed.** Furthermore, when trying to replicate field plots in the RPA image, the lack of precise GNSS coordinates also generated some differences between photointerpretation and fieldwork results. However, the two methodologies were able to state an ecological succession process in the study area.

## References

- Holton, A.E.; Lawson, S.; Love, C. Unmanned Aerial Vehicles: Opportunities, barriers, and the future of “drone journalism”. *J. Pract.* **2015**, *9*, 634–650. [CrossRef]
- Boursianis, A.D.; Papadopoulou, M.S.; Diamantoulakis, P.; Liopa-Tsakalidi, A.; Barouchas, P.; Salahas, G.; Karagiannidis, G.; Wan, S.; Goudos, S.K. Internet of things (IoT) and agricultural unmanned aerial vehicles (UAVs) in smart farming: A comprehensive review. *Internet Things* **2020**, 100187. [CrossRef]
- Viani, R.; Rodrigues, R.; Padovezi, A.; Turini Farah, F.; Garcia, L.; Sanglade, L.; Brancalion, P.; Chaves, R.; Barreto, T.; Strassburg, B.; et al. Monitoring Protocol for Forest Restoration Programs & Projects. 2013; p. 61. Available online: [https://www.researchgate.net/publication/304073085\\_Pacto\\_pela\\_restauracao\\_da\\_Mata\\_Atlantica\\_-\\_Protocolo\\_de\\_monitoramento\\_para\\_programas\\_e\\_projetos\\_de\\_restauracao\\_florestal](https://www.researchgate.net/publication/304073085_Pacto_pela_restauracao_da_Mata_Atlantica_-_Protocolo_de_monitoramento_para_programas_e_projetos_de_restauracao_florestal) (accessed on 17 June 2021).
- Viani, R.A.; Holl, K.D.; Padovezi, A.; Strassburg, B.B.; Farah, F.T.; Garcia, L.C.; Chaves, R.B.; Rodrigues, R.R.; Brancalion, P.H. Protocol for monitoring tropical forest restoration: Perspectives from the Atlantic Forest Restoration Pact in Brazil. *Trop. Conserv. Sci.* **2017**, *10*, 1940082917697265. [CrossRef]
- Aasen, H.; Burkart, A.; Bolten, A.; Bareth, G. Generating 3D hyperspectral information with lightweight UAV snapshot cameras for vegetation monitoring: From camera calibration to quality assurance. *ISPRS J. Photogramm. Remote Sens.* **2015**, *108*, 245–259. [CrossRef]
- Zahawi, R.A.; Dandois, J.P.; Holl, K.D.; Nadwodny, D.; Reid, J.L.; Ellis, E.C. Using lightweight unmanned aerial vehicles to monitor tropical forest recovery. *Biol. Conserv.* **2015**, *186*, 287–295. [CrossRef]
- McDonald, T.; Gann, G.; Jonson, J.; Dixon, K. *International Standards for The Practice of Ecological Restoration—Including Principles and Key Concepts*; Technical Report; Society for Ecological Restoration: Washington, DC, USA, 2016. Available online: [http://www.seraustralasia.com/wheel/image/SER\\_International\\_Standards.pdf](http://www.seraustralasia.com/wheel/image/SER_International_Standards.pdf) (accessed on 9 August 2019).
- Myers, N.; Mittermeier, R.A.; Mittermeier, C.G.; Da Fonseca, G.A.; Kent, J. Biodiversity hotspots for conservation priorities. *Nature* **2000**, *403*, 853. [CrossRef] [PubMed]
- Tarolli, P. High-resolution topography for understanding Earth surface processes: Opportunities and challenges. *Geomorphology* **2014**, *216*, 295–312. [CrossRef]

10. Mlambo, R.; Woodhouse, I.; 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* **2017**, *8*, 68. [CrossRef]
11. INEA. Manual de Procedimentos para o Monitoramento e Avaliação de áreas em Restauração Florestal no Estado do Rio de Janeiro. Technical Report, Instituto Estadual do Ambiente. 2019. Available online: [http://www.inea.rj.gov.br/wp-content/uploads/2019/05/Manual-Monitoramento-%C3%81reas-Reflorestadas\\_WEB.pdf](http://www.inea.rj.gov.br/wp-content/uploads/2019/05/Manual-Monitoramento-%C3%81reas-Reflorestadas_WEB.pdf) (accessed on 10 September 2019).
12. R Core Team. *R: A Language and Environment for Statistical Computing*; R Foundation for Statistical Computing: Vienna, Austria, 2013. Available online: <http://www.R-project.org> (accessed on 17 June 2021).
13. Agência Nacional de Aviação Civil (ANAC). Requisitos gerais para aeronaves não tripuladas de uso civil. Resolução número 419, de 2 de maio de 2017. Regulamento Brasileiro da Aviação Civil Especial, RBAC-E número 94, 2017. Available online: [https://www.anac.gov.br/assuntos/legislacao/legislacao-1/rbha-e-rbac/rbac/rbac-e-94/@@display-file/arquivo\\_norma/RBACE94EMD00.pdf](https://www.anac.gov.br/assuntos/legislacao/legislacao-1/rbha-e-rbac/rbac/rbac-e-94/@@display-file/arquivo_norma/RBACE94EMD00.pdf) (accessed on 17 June 2021).
14. Albuquerque, R.W.; Costa, M.O.; Ferreira, M.E.; Carrero, G.C.; Grohmann, C.H. Remotely piloted aircraft imagery for automatic tree counting in forest restoration areas: A case study in the Amazon. *J. Unmanned Veh. Syst.* **2020**, *8*, 207–223. [CrossRef]
15. Júnior, L.R.A.; Ferreira, M.E.; Côrtes, J.B.R.; de Castro Jorge, L.A. High accuracy mapping with cartographic assessment for a fixed-wing remotely piloted aircraft system. *J. Appl. Remote Sens.* **2018**, *12*, 014003.
16. Hung, I.-K.; Unger, D.; Kulhavy, D.; Zhang, Y. Positional precision analysis of orthomosaics derived from drone captured aerial imagery. *Drones* **2019**, *3*, 46. [CrossRef]
17. Mohan, M.; Silva, C.; Klauberg, C.; Jat, P.; Catts, G.; Cardil, A.; Hudak, A.; Dia, M. Individual tree detection from unmanned aerial vehicle (UAV) derived canopy height model in an open canopy mixed conifer forest. *Forests* **2017**, *8*, 340. [CrossRef]
18. Liu, H.; Dong, P. A new method for generating canopy height models from discrete-return LiDAR point clouds. *Remote Sens. Lett.* **2014**, *5*, 575–582. [CrossRef]
19. Zhang, W.; Qi, J.; Wan, P.; Wang, H.; Xie, D.; Wang, X.; Yan, G. An easy-to-use airborne LiDAR data filtering method based on cloth simulation. *Remote Sens.* **2016**, *8*, 501. [CrossRef]
20. Silva, C.A.; Hudak, A.T.; Vierling, L.A.; Loudermilk, E.L.; O'Brien, J.J.; Hiers, J.K.; Jack, S.B.; Gonzalez-Benecke, C.; Lee, H.; Falkowski, M.J.; et al. Imputation of individual Longleaf Pine (*Pinus palustris* Mill.) Tree attributes from field and LiDAR data. *Can. J. Remote Sens.* **2016**, *42*, 554–573. [CrossRef]
21. Silva, C.A.; Crookston, N.L.; Hudak, A.T.; Vierling, L.A.; Klauberg, C.; Silva, M.C.A. Package 'rLiDAR'. 2017. Available online: <https://cran.r-project.org/web/packages/rLiDAR/rLiDAR.pdf> (accessed on 1 September 2019).
22. Oliveira, E.C.L.; Felfili, J.M. Estrutura e dinâmica da regeneração natural de uma mata de galeria no Distrito Federal, Brasil. *Acta Bot. Bras* **2005**, *19*, 801–811. [CrossRef]
23. Barbosa, B.; Ferraz, G.; Gonçalves, L.; Marin, D.; Maciel, D.; Ferraz, P.; Rossi, G. RGB vegetation indices applied to grass monitoring: A qualitative analysis. *Agron. Res.* **2019**, *17*, 349–357.
24. Reis, B.P.; Martins, S.V.; Fernandes Filho, E.I.; Sarcinelli, T.S.; Gleriani, J.M.; Leite, H.G.; Halassy, M. Forest restoration monitoring through digital processing of high resolution images. *Ecol. Eng.* **2019**, *127*, 178–186. [CrossRef]
25. Laliberte, A.S.; Browning, D.; Rango, A. A comparison of three feature selection methods for object-based classification of sub-decimeter resolution UltraCam-L imagery. *Int. J. Appl. Earth Obs. Geoinf.* **2012**, *15*, 70–78. [CrossRef]
26. Hunt, E.R.; Doraiswamy, P.C.; McMurtrey, J.E.; Daughtry, C.S.; Perry, E.M.; Akhmedov, B. A visible band index for remote sensing leaf chlorophyll content at the canopy scale. *Int. J. Appl. Earth Obs. Geoinf.* **2013**, *21*, 103–112. [CrossRef]
27. Grohmann, C.H.; Smith, M.J.; Riccomini, C. Multiscale analysis of topographic surface roughness in the Midland Valley, Scotland. *IEEE Trans. Geosci. Remote Sens.* **2010**, *49*, 1200–1213. [CrossRef]
28. Torres-Sánchez, J.; López-Granados, F.; Borra-Serrano, I.; Peña, J.M. Assessing UAV-collected image overlap influence on computation time and digital surface model accuracy in olive orchards. *Precis. Agric.* **2018**, *19*, 115–133. [CrossRef]
29. Colomina, I.; Molina, P. Unmanned aerial systems for photogrammetry and remote sensing: A review. *ISPRS J. Photogramm. Remote Sens.* **2014**, *92*, 79–97. [CrossRef]
30. Schonberger, J.L.; Frahm, J.M. Structure-from-motion revisited. In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Las Vegas, NV, USA, 27–30 June 2016; pp. 4104–4113.
31. Crouzeilles, R.; Santiami, E.; Rosa, M.; Pugliese, L.; Brancalion, P.H.; Rodrigues, R.R.; Metzger, J.P.; Calmon, M.; Scaramuzza, C.A.D.M.; Matsumoto, M.H.; et al. There is hope for achieving ambitious Atlantic Forest restoration commitments. *Perspect. Ecol. Conserv.* **2019**, *17*, 80–83. [CrossRef]
32. Ferreira, M.P.; de Almeida, D.R.A.; de Almeida Papa, D.; Minervino, J.B.S.; Veras, H.F.P.; Formighieri, A.; Santos, C.A.N.; Ferreira, M.A.D.; Figueiredo, E.O.; Ferreira, E.J.L. Individual tree detection and species classification of Amazonian palms using UAV images and deep learning. *For. Ecol. Manag.* **2020**, *475*, 118397. [CrossRef]
33. Schiefer, F.; Kattenborn, T.; Frick, A.; Frey, J.; Schall, P.; Koch, B.; Schmidlein, S. Mapping forest tree species in high resolution UAV-based RGB-imagery by means of convolutional neural networks. *ISPRS J. Photogramm. Remote Sens.* **2020**, *170*, 205–215. [CrossRef]
34. Florenzano, T.G. *Imagens de Satélite Para Estudos Ambientais*; Oficina de Textos: São Paulo, Brazil, 2002; p. 97.
35. Congalton, R.G. A review of assessing the accuracy of classifications of remotely sensed data. *Remote Sens. Environ.* **1991**, *37*, 35–46. [CrossRef]

36. Goutte, C.; Gaussier, E. A probabilistic interpretation of precision, recall and F-score, with implication for evaluation. In *European Conference on Information Retrieval*; Springer: Berlin/Heidelberg, Germany, 2005; pp. 345–359.
37. Keith, K.; Nicholson, D.; Rogers, D. Accuracy and precision of low-dose insulin administration using syringes, pen injectors, and a pump. *Clin. Pediatr.* **2004**, *43*, 69–74. [[CrossRef](#)]
38. Zhang, J.; Hu, J.; Lian, J.; Fan, Z.; Ouyang, X.; Ye, W. Seeing the forest from drones: Testing the potential of lightweight drones as a tool for long-term forest monitoring. *Biol. Conserv.* **2016**, *198*, 60–69. [[CrossRef](#)]
39. Nixon, M.; Aguado, A. *Feature Extraction and Image Processing for Computer Vision*; Academic Press: Cambridge, MA, USA, 2019; p. 626.
40. Braga, J.; Peripato, V.; Dalagnol, R.; Ferreira, M.; Tarabalka, Y.; Aragão, L.; de Campos Velho, H.; Shigemori, E.; Wagner, F. Tree Crown Delineation Algorithm Based on a Convolutional Neural Network. *Remote Sens.* **2020**, *12*, 1288. [[CrossRef](#)]
41. Wagner, F.H.; Sanchez, A.; Tarabalka, Y.; Lotte, R.G.; Ferreira, M.P.; Aidar, M.P.; Gloor, E.; Phillips, O.L.; Aragao, L.E. Using the U-net convolutional network to map forest types and disturbance in the Atlantic rainforest with very high resolution images. *Remote Sens. Ecol. Conserv.* **2019**, *5*, 360–375. [[CrossRef](#)]
42. Wagner, F.H.; Sanchez, A.; Aidar, M.P.; Rochelle, A.L.; Tarabalka, Y.; Fonseca, M.G.; Phillips, O.L.; Gloor, E.; Aragão, L.E. Mapping Atlantic rainforest degradation and regeneration history with indicator species using convolutional network. *PLoS ONE* **2020**, *15*, e0229448. [[CrossRef](#)]
43. Ferreira, M.P.; Lotte, R.G.; D’Elia, F.V.; Stamatopoulos, C.; Kim, D.H.; Benjamin, A.R. Accurate mapping of Brazil nut trees (*Bertholletia excelsa*) in Amazonian forests using WorldView-3 satellite images and convolutional neural networks. *Ecol. Inform.* **2021**, *63*, 101302. [[CrossRef](#)]
44. Belmonte, A.; Sankey, T.; Biederman, J.A.; Bradford, J.; Goetz, S.J.; Kolb, T.; Woolley, T. UAV-derived estimates of forest structure to inform ponderosa pine forest restoration. *Remote Sens. Ecol. Conserv.* **2020**, *6*, 181–197. [[CrossRef](#)]
45. Chen, S.; McDermid, G.; Castilla, G.; Linke, J. Measuring vegetation height in linear disturbances in the boreal forest with UAV photogrammetry. *Remote Sens.* **2017**, *9*, 1257. [[CrossRef](#)]
46. Wu, X.; Shen, X.; Cao, L.; Wang, G.; Cao, F. Assessment of individual tree detection and canopy cover estimation using unmanned aerial vehicle based light detection and ranging (UAV-LiDAR) data in planted forests. *Remote Sens.* **2019**, *11*, 908. [[CrossRef](#)]
47. Camarretta, N.; Harrison, P.A.; Bailey, T.; Potts, B.; Lucieer, A.; Davidson, N.; Hunt, M. Monitoring forest structure to guide adaptive management of forest restoration: A review of remote sensing approaches. *New For.* **2020**, *51*, 573–596. [[CrossRef](#)]
48. Madasa, A.; Orimoloye, I.R.; Ololade, O.O. Application of geospatial indices for mapping land cover/use change detection in a mining area. *J. Afr. Earth Sci.* **2021**, *175*, 104108. [[CrossRef](#)]
49. Krause, S.; Sanders, T.G.; Mund, J.P.; Greve, K. UAV-based photogrammetric tree height measurement for intensive forest monitoring. *Remote Sens.* **2019**, *11*, 758. [[CrossRef](#)]
50. Ferrer-González, E.; Agüera-Vega, F.; Carvajal-Ramírez, F.; Martínez-Carricondo, P. UAV Photogrammetry Accuracy Assessment for Corridor Mapping Based on the Number and Distribution of Ground Control Points. *Remote Sens.* **2020**, *12*, 2447. [[CrossRef](#)]
51. Nie, Z.; Liu, F.; Gao, Y. Real-time precise point positioning with a low-cost dual-frequency GNSS device. *GPS Solut.* **2020**, *24*, 1–11. [[CrossRef](#)]
52. Martins, A.C.; Willig, M.R.; Presley, S.J.; Marinho-Filho, J. Effects of forest height and vertical complexity on abundance and biodiversity of bats in Amazonia. *For. Ecol. Manag.* **2017**, *391*, 427–435. [[CrossRef](#)]
53. Almeida, D.R.A.D.; Stark, S.C.; Chazdon, R.; Nelson, B.W.; César, R.G.; Meli, P.; Gorgens, E.; Duarte, M.M.; Valbuena, R.; Moreno, V.S.; et al. The effectiveness of lidar remote sensing for monitoring forest cover attributes and landscape restoration. *For. Ecol. Manag.* **2019**, *438*, 34–43. [[CrossRef](#)]
54. Ferreira, J.; Lennox, G.D.; Gardner, T.A.; Thomson, J.R.; Berenguer, E.; Lees, A.C.; Mac Nally, R.; Aragão, L.E.; Ferraz, S.F.; Louzada, J.; et al. Carbon-focused conservation may fail to protect the most biodiverse tropical forests. *Nat. Clim. Chang.* **2018**, *8*, 744–749. [[CrossRef](#)]
55. Wallace, L.; Lucieer, A.; Watson, C.S. Evaluating tree detection and segmentation routines on very high resolution UAV LiDAR data. *IEEE Trans. Geosci. Remote Sens.* **2014**, *52*, 7619–7628. [[CrossRef](#)]
56. Eugenio, F.C.; Schons, C.T.; Mallmann, C.L.; Schuh, M.S.; Fernandes, P.; Badin, T.L. Remotely piloted aircraft systems and forests: A global state of the art and future challenges. *Can. J. For. Res.* **2020**, *50*, 705–716. [[CrossRef](#)]
57. Schowengerdt, R.A. *Remote Sensing: Models and Methods for Image Processing*, 3rd ed.; Academic Press: Orlando, FL, USA, 2007; p. 515.
58. Alonzo, M.; Bookhagen, B.; Roberts, D.A. Urban tree species mapping using hyperspectral and lidar data fusion. *Remote Sens. Environ.* **2014**, *148*, 70–83. [[CrossRef](#)]
59. Araujo, L.; Vicente, L.E.; Manzatto, C.V.; Skorupa, L.A.; Victoria, D.D.C.; Soares, A.R. AgroTag: Um sistema de coleta, análise e compartilhamento de dados de campo para qualificação do uso e cobertura das terras no Brasil. In *Proceedings of Simpósio Brasileiro de Sensoriamento Remoto (SBSR)*, 19; Gherardi, D.F.M., Sanches, I.D., e Cruz de Aragão, L.E.O., Eds.; INPE: São José dos Campos, Brazil, 2019; pp. 451–454.
60. Das, P.; Ortega, L.; Vilà-Valls, J.; Vincent, F.; Chaumette, E.; Davain, L. Performance Limits of GNSS Code-Based Precise Positioning: GPS, Galileo & Meta-Signals. *Sensors* **2020**, *20*, 2196.
61. Cottam, G.; Curtis, J.T. The use of distance measures in phytosociological sampling. *Ecology* **1956**, *37*, 451–460. [[CrossRef](#)]

**ANEXO C – ARTIGO SOBRE AVALIAÇÃO  
DOS ASPECTOS DE  
BIODIVERSIDADE DA  
RESTAURAÇÃO FLORESTAL  
VIA RPA-SFM**



## Article

# Mapping Key Indicators of Forest Restoration in the Amazon Using a Low-Cost Drone and Artificial Intelligence

Rafael Walter Albuquerque <sup>1,\*</sup>, Daniel Luis Mascia Vieira <sup>2</sup>, Manuel Eduardo Ferreira <sup>3</sup>, Lucas Pedrosa Soares <sup>4</sup>, Søren Ingvor Olsen <sup>5</sup>, Luciana Spinelli Araujo <sup>6</sup>, Luiz Eduardo Vicente <sup>6</sup>, Julio Ricardo Caetano Tymus <sup>7</sup>, Cintia Palheta Balieiro <sup>7</sup>, Marcelo Hiromiti Matsumoto <sup>8</sup> and Carlos Henriques Grohmann <sup>1</sup>

- <sup>1</sup> Spatial Analysis and Modelling Lab (SPAMLab), Institute of Energy and Environment, University of São Paulo, Prof. Luciano Gualberto Avenue, 1289, São Paulo 05508-010, Brazil; guano@usp.br
  - <sup>2</sup> Embrapa Genetic Resources and Biotechnology, Parque Estação Biológica, PqEB, Av. W5 Norte, Cx. Postal 02372, Brasília 70770-917, Brazil; daniel.vieira@embrapa.br
  - <sup>3</sup> Laboratório de Processamento de Imagens e Geoprocessamento—LAPIG/Pro-Vant, Instituto de Estudos Socioambientais—IESA, Campus II, Universidade Federal de Goiás—UFG, Cx. Postal 131, Goiânia 74001-970, Brazil; manuel@ufg.br
  - <sup>4</sup> Institute of Geosciences, University of São Paulo, Rua do Lago, 562, São Paulo 05508-080, Brazil; lpsouares@usp.br
  - <sup>5</sup> Department of Computer Science (DIKU), University of Copenhagen, Universitetsparken 1, 2100 Ø Copenhagen, Denmark; ingvor@di.ku.dk
  - <sup>6</sup> Embrapa Meio Ambiente, Rodovia SP 340, KM 127 S/N, Jaguariúna 13820-000, Brazil; luciana.spinelli@embrapa.br (L.S.A.); luiz.vicente@embrapa.br (L.E.V.)
  - <sup>7</sup> The Nature Conservancy Brasil—TNC, Av. Paulista, 2439/91, São Paulo 01311-300, Brazil; jtymus@tnc.org (J.R.C.T.); cbalieiro@tnc.org (C.P.B.)
  - <sup>8</sup> Escola Superior de Agricultura Luiz de Queiroz, University of São Paulo (ESALQ/USP), Avenida Pádua Dias, 11, São Dimas, Piracicaba 13418-900, Brazil; mhmatsumo@alumni.usp.br
- \* Correspondence: rafael.albuquerque@usp.br



**Citation:** Albuquerque, R.W.; Vieira, D.L.M.; Ferreira, M.E.; Soares, L.P.; Olsen, S.I.; Araujo, L.S.; Vicente, L.E.; Tymus, J.R.C.; Balieiro, C.P.; Matsumoto, M.H.; Grohmann, C.H. Mapping Key Indicators of Forest Restoration in the Amazon Using a Low-Cost Drone and Artificial Intelligence. *Remote Sens.* **2022**, *14*, 830. <https://doi.org/10.3390/rs14040830>

Academic Editors: Carlos Alberto Silva and Qinghua Guo

Received: 20 December 2021

Accepted: 3 February 2022

Published: 10 February 2022

**Publisher's Note:** MDPI stays neutral with regard to jurisdictional claims in published maps and institutional affiliations.



**Copyright:** © 2022 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

**Abstract:** Monitoring the vegetation structure and species composition of forest restoration (FR) in the Brazilian Amazon is critical to ensuring its long-term benefits. Since remotely piloted aircrafts (RPAs) associated with deep learning (DL) are becoming powerful tools for vegetation monitoring, this study aims to use DL to automatically map individual crowns of *Vismia* (low resilience recovery indicator), *Cecropia* (fast recovery indicator), and trees in general (this study refers to individual crowns of all trees regardless of species as All Trees). Since All Trees can be accurately mapped, this study also aims to propose a tree crown heterogeneity index (TCHI), which estimates species diversity based on: the heterogeneity attributes/parameters of the RPA image inside the All Trees results; and the Shannon index measured by traditional fieldwork. Regarding the DL methods, this work evaluated the accuracy of the detection of individual objects, the quality of the delineation outlines and the area distribution. Except for *Vismia* delineation (IoU = 0.2), DL results presented accurate values in general, as F1 and IoU were always greater than 0.7 and 0.55, respectively, while *Cecropia* presented the most accurate results: F1 = 0.85 and IoU = 0.77. Since All Trees results were accurate, the TCHI was obtained through regression analysis between the canopy height model (CHM) heterogeneity attributes and the field plot data. Although TCHI presented robust parameters, such as  $p$ -value < 0.05, its results are considered preliminary because more data are needed to include different FR situations. Thus, the results of this work show that low-cost RPA has great potential for monitoring FR quality in the Amazon, because *Vismia*, *Cecropia*, and All Trees can be automatically mapped. Moreover, the TCHI preliminary results showed high potential in estimating species diversity. Future studies must assess domain adaptation methods for the DL results and different FR situations to improve the TCHI range of action.

**Keywords:** *Cecropia*; deep learning; drones; photogrammetry; remotely piloted aircraft; RGB; species diversity; tree crown heterogeneity index; tree species; *Vismia*

## 1. Introduction

Forest restoration (FR) projects [1] aim for benefits, such as the provision of ecosystem services [2] and social well-being [3]. However, FR monitoring is a must to ensure a proper provision of such benefits [4–7]. When it comes to the Brazilian Amazon, which is a threatened biome [8], and has increased deforestation in the last years [9], the success of FR projects is considerably relevant to ensure the forest structure and species composition that mitigate climate changes [10].

The rate of forest recovery in the Amazon varies as functions of forest resilience [11,12] and restoration methods [13,14]. In the first two decades of forest recovery, the dominance of *Cecropia* sp. in the canopy indicates high resilience, while *Vismia* sp. canopy dominance indicates low resilience; thus, monitoring these two species is significantly relevant to FR in the Amazon [11,15]. Moreover, a successful FR project is similar to undisturbed forests [7], which have a diverse and heterogeneous canopy [16,17]. Active restoration with high species diversity also presents a more heterogeneous canopy in general when compared to the *Cecropia* and *Vismia* natural regeneration routes due to a greater species diversity [14].

Remotely piloted aircrafts (RPA), popularly known as drones, have high potential in monitoring FR efficiently due to high-resolution remote sensing data [18]. For instance, RPA coupled with red–green–blue (RGB) sensors can be used to measure the structural parameters of the vegetation, such as tree cover and tree height, and such measurements are accurate especially in open canopy conditions [19–22]. RPA coupled with RGB sensors also have high potential to estimate the biomass of FR projects [18].

Despite accurately measuring the structural parameters, measuring the FR biodiversity indicators in high diverse forests is a great challenge [22,23]. Computer vision techniques, such as deep learning [24], have high potential in improving this field of research because they have revolutionized image processing [25–27]. When applied to low-cost RPA images, deep learning accurately identified palm species [28], six usual tree species in the Amazon [29] and the tree species of a German forest [30]. However, the Amazon biome is a high biodiversity biome [31–34]; thus, more species identification via remote sensing will be needed in the future. Therefore, applying deep learning to the map indicator species of FR in the Amazon (such as the *Cecropia* sp. and *Vismia* sp.) and the forest canopy structure complexity may improve FR monitoring, especially the monitoring issues that evaluate FR quality.

When calling upon deep learning, results can be a semantic segmentation, where two objects of the same class are counted as one when touching each other, or an instance segmentation, where the touching objects of the same class are discriminated [35,36]. To estimate canopy structure complexity and to get the number of individuals in the RPA imagery, individual tree crowns must be properly delineated and separated when touching each other [28,37]. Braga et al. [37] showed that the mask region-based convolutional neural network (Mask R-CNN) [38] is an artificial convolutional neural network capable of accurately performing such a task in a tropical diverse forest using a high resolution satellite image.

When considering low-cost RPA images, if an accurate delineation of all kinds of trees in general (regardless of species) is performed, it would be possible to estimate the species diversity of FR projects via heterogeneity measurements of the trees because point cloud data are available [17]. Therefore it is worth discussing the concept of the tree crown heterogeneity index (TCHI): an index that estimates the traditional Shannon index [39] based on the automatic detection and delineation of individual tree crowns and their corresponding structural heterogeneity parameters. The TCHI concept is nonexistent (as far as the authors of this manuscript know). If a proper TCHI is developed, the low-cost RPA potential to estimate species diversity on FR projects would be improved.

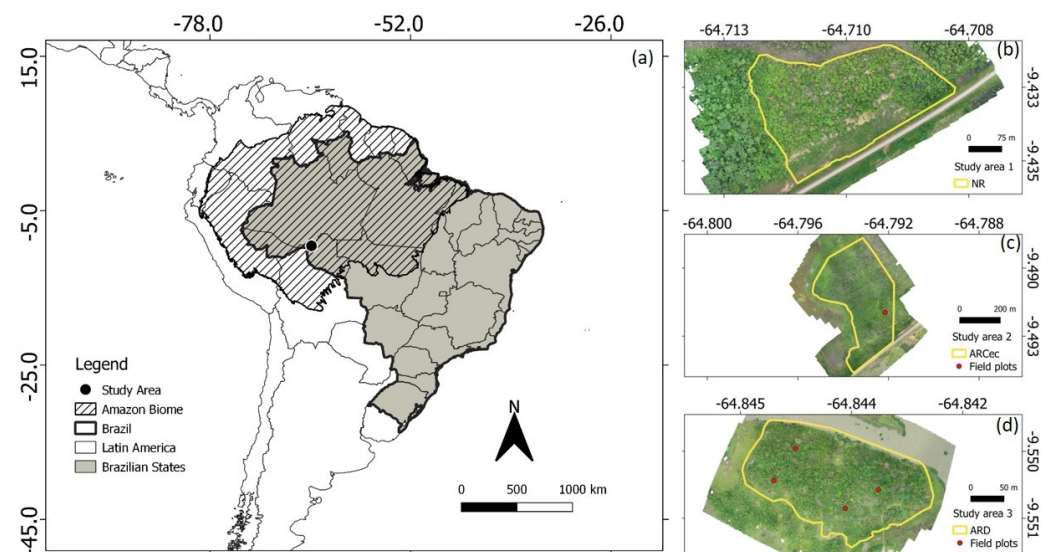
This study aims to assess an artificial neural network capacity, namely the Mask R-CNN, to identify and delineate in low-cost RPA images key canopy elements: *Vismia* sp. crown, as an early FR indicator of low-quality forest regeneration; *Cecropia* sp. crown, as an early FR indicator of high-quality forest regeneration; and the crowns of all kinds

of trees in general, regardless of species. If accurate automatic detection and delineation of the crowns of all kinds of trees are performed, measuring the heterogeneity attributes to estimate species diversity becomes timely. Thus, this study proposes a first approach of TCHI: an equation that estimates species diversity in a site considering the structural heterogeneity attributes of the trees that are automatically detected and delineated.

## 2. Materials and Methods

### 2.1. Study Area

The FR study sites were located in the south Amazon, in the Porto Velho Municipality, along the Madeira river, in Rondônia (RO) state, Brazil (Figure 1).



**Figure 1.** Location of the FR study sites: (a) in South America, Brazil, and Amazon biome. (b) Study site 1 (8.19 hectares) is a naturally regenerating (NR) forest with *Vismia* spp. occurrence, which will be called, in this work, the *Vismia* site (no field plots of forest inventory were available on this site). (c) Study site 2 (14.07 hectares) is an actively restored site with *Cecropia* spp. (ARCec) occurrence, which will be called, in this work, the *Cecropia* site (only one field plot was not damaged after a fire event on this site). (d) Study site 3 (3.32 hectares) is an actively restored diverse (ARD) site, which will be called, in this work, the *Diverse* site.

One site was a naturally regenerating (NR) forest with *Vismia* sp. occurrence. Another site was an actively restored forest with *Cecropia* (ARCec). The third site was an actively restored diverse forest (ARD). For better readability, NR, ARCec, and ARD will be referred to as the *Vismia* site, *Cecropia* site, and *Diverse* site, respectively, in plain text, as these abbreviation meanings will keep being used and described in the figures and tables of this manuscript.

The *Cecropia* site and *Diverse* site had traditional FR monitoring fieldwork of forest inventory performed in July 2019. The RPA flights were conducted in December 2019.

### 2.2. Materials

The RPA used in this study was a Phantom 4 Pro (a rotary wing). It was coupled with an RGB 1" CMOS 20MP sensor. For more information about this RPA model, see [40].

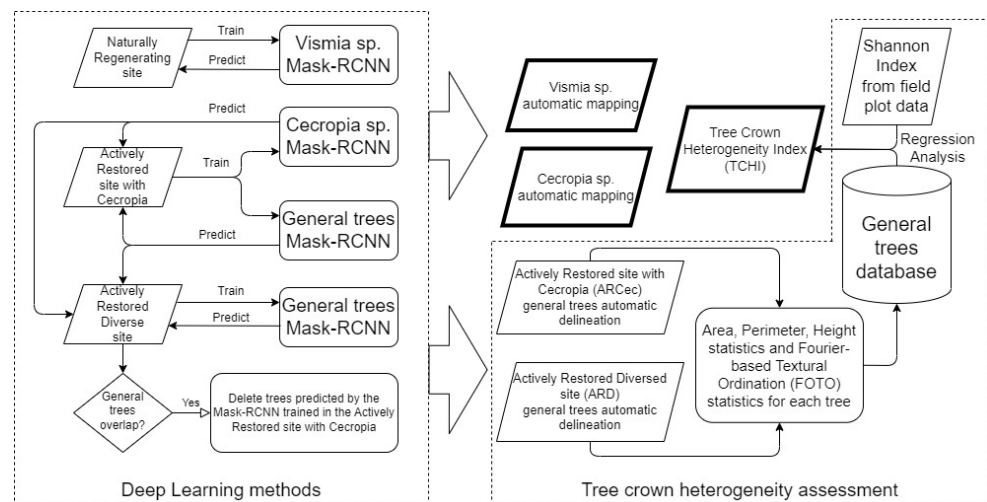
Ground control points (GCPs) were collected by the geodetic global navigation satellite system (GNSS) equipment Spectra Precision SP60. For more information about this GNSS equipment, see [41].

The flight planning was drafted using Map Pilot software [42]. Digital surface models (DSMs), digital terrain models (DTMs), and orthorectified mosaics were obtained using Agisoft Metashape [43] software. The deep learning processes were performed using

Python [44], and linear regression and graphs in R [45]. The map layouts were generated using QGIS software [46].

### 2.3. Methods

Figure 2 illustrates the methods applied in this work, described from Section 2.3.2 to Section 2.3.4. From this part until the end of the manuscript, *Vismia* sp., *Cecropia* sp. and all kinds of trees in general (regardless of species) will be referred to as *Vismia*, *Cecropia*, and All Trees, respectively, for better readability.



**Figure 2.** Deep learning methods for automatically mapping of *Vismia*, *Cecropia* and All Trees and regression analysis methods to assess the tree crown heterogeneity index (TCHI) after mapping All Trees.

#### 2.3.1. Flight Patterns

All flights were in compliance with Brazil's RPA laws [47] at 80 m above the ground, generating around 2 cm of ground sampling distance (GSD); the front and side overlaps were equal to, respectively, 90% and 80%. *Vismia* site, *Cecropia* site, and the Diverse site had 8, 3, and 6 ground control points, respectively.

#### 2.3.2. Deep Learning Methods

Deep learning was used to automatically identify three different canopy elements: crown of *Vismia*, *Cecropia*, and All Trees. The Mask R-CNN was used on these tasks because it performs instance segmentation and, thus, it counts the number of individuals in an area of interest [37], which is relevant for many ecological studies [28,48,49]. Mask R-CNN was also used because it is a reference instance segmentation algorithm in computer vision research [36,50].

Mask R-CNN is a faster R-CNN extension. Faster R-CNN is an artificial convolutional neural network that identifies each target in an image with a bounding box and classifies it. Mask R-CNN, besides the identification and classification of each target, performs a segmentation process that outputs the shape of the object that is inside each bounding box. The result is an instance segmentation, which allows assessing the shape and the number of targets in an image. For more information about Mask R-CNN, see [38].

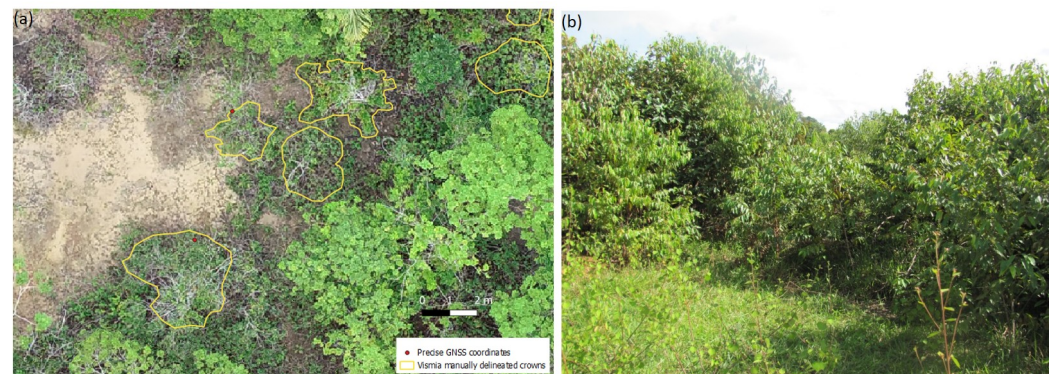
Since the Amazon is a high biodiversity biome [31–34,51,52], it is not possible to know which species are present in a site; thus, the Mask R-CNN for mapping *Vismia* and *Cecropia* were assessed as a one-class remote sensing classification process. Such a process is recommended when one specific target is desired among many other complex and unknown features [53,54]. Therefore, in high biodiversity sites, mapping each species using a one-class classification process is a relevant first step. If high accuracy is achieved,




future works may develop a single Mask R-CNN that maps *Vismia* and *Cecropia*, as well as other relevant species for FR.

For the manual delineation of the samples of *Cecropia* and *Vismia*, both had precise GNSS coordinates that were collected to confirm how they look in the RPA images. Figures 3 and 4 illustrates examples of field plot coordinates with manually delineated samples of these targets, as well as ground photos. As Figures 3 and 4 show, *Cecropia* is much more easily identified visually than *Vismia*, which suggests that the *Cecropia* accuracy may be higher.

Regarding All Trees, precise GNSS coordinates were not necessary for manual delineation of samples, which occurred by photointerpretation. The All Trees target was not assessed in the *Vismia* site because it did not have field plots.



**Figure 3.** Example of *Vismia*: manually delineated samples with precise GNSS coordinates that confirm how these targets look in the RPA image (a); and ground photo (b).



**Figure 4.** Example of *Cecropia*: manually delineated samples with precise GNSS coordinates that confirm how these targets look in the RPA image (a); and ground photo (b).

The sampling process is a notable disadvantage of deep learning because a great amount of samples is needed [55]. To help deal with such an issue, Braga et al. [37] developed an algorithm that generates synthetic images with augmentation processes. Such synthetic images improve the neural network classification results because it simulates an increased number of samples. Such a simulation allocates each sample to different locations and performs some brightness changes, vertical or horizontal flips, and rotations in the artificial image. For more details about the use of synthetic images, see Braga et al. [37]. Table 1 illustrates the number of synthetic images generated in this work, as well as the number of samples per synthetic image. Table 1 also illustrates the number of epochs and samples collected for the Mask R-CNN in this work.

**Table 1.** Deep learning samples manually delineated according to target and study area.

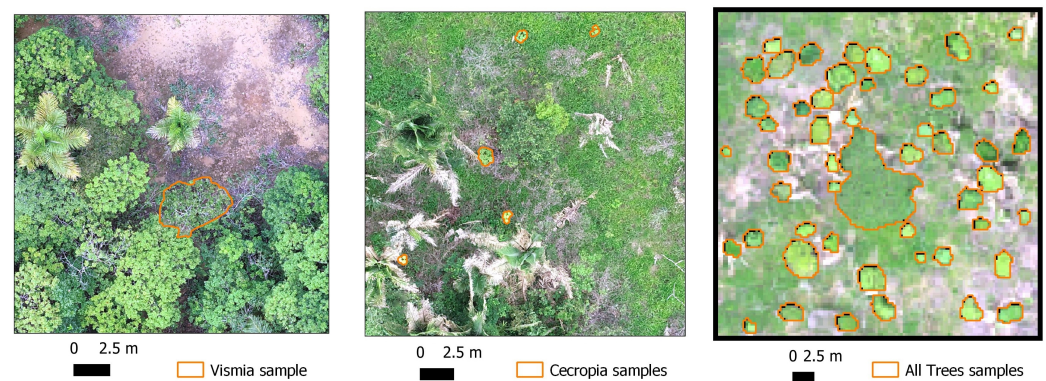
Delineation Target	Study Area	Epochs	Training Samples	Validation Samples	Test Samples	Samples in Synthetic Images	Total of Synthetic Train Images	Total of Synthetic Validation Images
<i>Vismia</i> sp.	Naturally regenerating site (NR)	150	144	48	48	1	6000	2000
<i>Cecropia</i> sp.	Actively restored site with <i>Cecropia</i> (ARCec)	150	240	80	80	5	1800	600
	Actively restored diverse site (ARD)	-	-	-	50	-	-	-
All Trees	Actively restored site with <i>Cecropia</i> (ARCec)	150	369	123	50	50	9000	3000
	Actively restored diverse site (ARD)	110	150	50	50	50	27,000	9000

The Diverse site only had test samples of *Cecropia* to evaluate the data shift phenomena, which is a common issue in the remote sensing classification processes: it happens when an algorithm that was trained in a single image is applied to another one and then presents less accurate results due to differences on imaging conditions and local characteristics [56].

Fine-tuning was performed on all Mask R-CNN training processes shown in Table 1 after 30 epochs, which trained only the heads of the convolution neural network with a learning rate equal to 0.001. Then, the whole network was trained. From epochs 31 to 70, the learning rate remained equal to 0.001, but from epochs 71 to 110, the learning rate was divided by 10; from epochs 111 to 150, the learning rate was divided by 100 (except for All Trees at the Diverse site, which had 110 epochs in the training process). ResNet50 and feature pyramid network (FPN) were used as the backbone. The code for the Mask R-CNN process can be seen in Braga et al. [37].

Table 1 and Figure 5 show that each synthetic image had more samples for All Trees than for *Cecropia* and *Vismia*. It was due to the spatial resolution of the images, or the GSD. A pixel degradation from 2 to around 30 cm considerably increased the All Trees results accuracy because the 2-centimeter GSD results were inaccurate. Such pixel degradation intended to simulate a satellite image where an accurate All Trees assessment was performed [37]. Moreover, poor results in the original 2-centimeter GSD were somehow expected because individual tree crowns are not clearly distinguishable via photointerpretation after the canopy closes [28,30].

Each synthetic image had more *Cecropia* than *Vismia* samples due to the target sizes (Table 1). *Cecropia* has a smaller crown size than *Vismia*, so hardware limitations allowed 5 and 1 samples, respectively, on each *Cecropia* and *Vismia* 2 cm GSD synthetic image. The amount of *Vismia* synthetic images, therefore, was considerably higher than *Cecropia* (see columns “total of synthetic train images” and “total of synthetic validation images” in Table 1). Idem to the amount of synthetic images for All Trees: the *Cecropia* site area (14.07 ha) is larger than the Diverse site area (3.32 ha); thus, the *Cecropia* site presented more sample availability (consequently, the Diverse site presented more synthetic images than the *Cecropia* site for All Trees). Figure 5 shows examples of synthetic images used in this study to train *Vismia*, *Cecropia*, and All Trees.



**Figure 5.** Examples of synthetic images that were used to train Vismia, Cecropia, and All Trees. In these images, the samples are artificially added to a background image.

In Cecropia and Vismia mapping, the synthetic images had  $1024 \times 1024$  pixels, as the tests using  $128 \times 128$  pixels images generated inaccurate results. Increasing the background-size for Vismia and Cecropia mapping was necessary to include the different possible background objects that confused the algorithm, such as grass, bare soil, palm trees, and general trees. The processing time of  $1024 \times 1024$  images was slower than  $128 \times 128$  images, but results were much better.

In the All Trees mapping, which was around 30 cm GSD, the synthetic images had  $128 \times 128$  pixels and the background involving only grass generated the most accurate results. After the training and prediction steps, the All Trees polygons with a maximum canopy height model (CHM, which is the difference between DSM and DTM) value less than 2 m and 0.3 m in height in the Cecropia site and the Diverse site, respectively, were excluded because they were bulky grass.

Mapping All Trees in the Diverse site not only involved the Mask R-CNN trained in this site but also the Mask R-CNN trained in the Cecropia site. Since the tree crowns in the Diverse site were usually large, the Mask R-CNN trained in this site usually detected the larger ones, as the smaller ones were omitted in the prediction process. To improve the accuracy of All Trees (by detecting the smaller tree crowns) in the Diverse site, the Mask R-CNN trained in the Cecropia site was also applied. As a result, two different automatic predictions in the same area generated overlapping tree crowns, which was not an “instance segmentation” characteristic. To handle the overlapping results, the tree crowns predicted by the Mask R-CNN trained in the Cecropia site (which detected smaller tree crowns) were excluded when its polygon overlapped with polygons predicted by the Mask R-CNN trained in the Diverse site (which generally detected large tree crowns). This procedure improved the accuracy of the All Trees final result in the Diverse site.

### 2.3.3. Regression Analysis for Generating the TCHI after Mapping All Trees

Less disturbed and undisturbed forests have species diversity that characterize heterogeneous CHM, while less diverse sites present a homogeneous CHM [16,17]. To evaluate the low-cost RPA capacity for estimating species diversity, a regression analysis between the tree crowns heterogeneity attributes measured by the RPA and the classic Shannon index [57], measured by traditional fieldwork, was performed.

For the regression analysis, the RPA database was generated from the All Trees results (Section 2.3.2), which then had some CHM attributes extracted for each polygon that represented a tree. The attributes of each polygon (of All Trees results) were: area, perimeter, CHM mean, CHM maximum, and principal component analysis (PCA) of the Fourier-based textural ordination (FOTO) statistics (mean and standard deviation). In this work, the defined acronyms of the attributes of the two principal components of FOTO are Fourier textural principal component one (FTPC1) and Fourier textural principal component two (FTPC2).

FOTO evaluated the CHM heterogeneity by a Fourier transform and was implemented using the python package Fototex [58]. FOTO assesses how the pixel values vary along the area and output different values according to the amount of the variation. If the pixels present similar values, FOTO detects a high frequency of these values, which is typical of homogeneous areas, whereas non-frequent values characterize heterogeneous areas. Thus, FOTO numerically expresses patches with more or less heterogeneity. For more information about FOTO, see Bourgoïn et al. [16] and Couteron et al. [59].

The traditional fieldwork database consisted of five field plots with a size  $25 \times 10$  m: one plot was located in the Cecropia site (14.07 ha); and four plots were located in the Diverse site (3.32 ha). Cecropia site, although larger, had only one plot because, unfortunately, a fire event between the forest inventory and the RPA flight damaged the vegetation in many patches (it is possible to see patches without trees, some of them with burnt palms, in Appendix A).

A Shannon index [57] (Equation (1)) was calculated for each field plot. The Shannon index considers the species richness and the number of representatives of each species. A site with ten trees that has nine species A, and one species B, is considered less diverse than another site with ten trees that has five species A and five species B. The greater the diversity, the greater the Shannon index value. For more information about the Shannon index, see Spellerberg and Fedor [39] and Pommerening [60].

$$H' = - \sum_{i=1}^n p_i \cdot \ln p_i \quad (1)$$

where  $H'$  is the Shannon index,  $p_i$  is the probability of a randomly selected tree to belong to the tree species  $i$ , and  $n$  is the number of tree species in the site.

Since the data of five field plots were available, only the automatic trees that intersected these plots were considered on the regression analysis. Thus, each field plot presented a number of trees (automatically identified by the RPA) that corresponded to a Shannon index value (measured by traditional fieldwork). However, the All Trees results are subject to omission errors (when one or more trees are not mapped automatically) and commission errors (when one or more trees do not exist but were automatically mapped); thus, the field plots intersected different amounts of trees. Since the different plots varied on the number of trees associated with a Shannon index value, the average of the crowns' attributes was used. Thus, for each field plot, the average of each tree crown attribute was used in a simple linear regression to estimate the corresponding Shannon index value. Since the average of each attribute was used, the interpretation of the attribute Fourier textural principal component one mean—FTPC1 mean—and the attribute Fourier textural principal component two mean—FTPC2 mean—may be confusing, but it is relevant to emphasize that each tree crown has a FTPC1 mean value and a FTPC2 mean value. Thus, the average of these values were used in the simple linear regressions to estimate the corresponding Shannon index. Appendix B presents the data that were used in this work.

A simple linear regression shows that results are statistically significant and the variables are significantly related to each other when the  $p$ -value is  $< 0.05$  and when a clear linear relation exists between the two variables [61]. For linear regressions with  $p$ -value  $< 0.005$ ,  $R^2_{adj}$  values close to one and residual standard errors close to zero usually indicate a clear linear relation between two variables [62], while  $R^2 > 0.75$  are also usually a good fit in simple linear regressions [63]. If one of the tree crown attributes presents such parameters in the simple linear regression, a preliminary equation that defines the TCHI will show potential for estimating species diversity. However, even if one or more tree crown attributes fill these criteria, it is relevant to emphasize that more field plots are going to be needed in the future to cover a whole range of different FR situations. The TCHI presented in this study is therefore a preliminary result, consisting of a first approach that may lead to relevant studies in the future.

### 2.3.4. Accuracy Evaluation of the Deep Learning Methods

The omission and commission errors, or the amount of false-positive (FP) and false-negative (FN) occurrences, as well as the overall accuracy [64], allows calculating the recall, precision, and F1 indexes [65], according to Equations (2)–(4), respectively.

$$r = \frac{TP}{(TP + FN)} \quad (2)$$

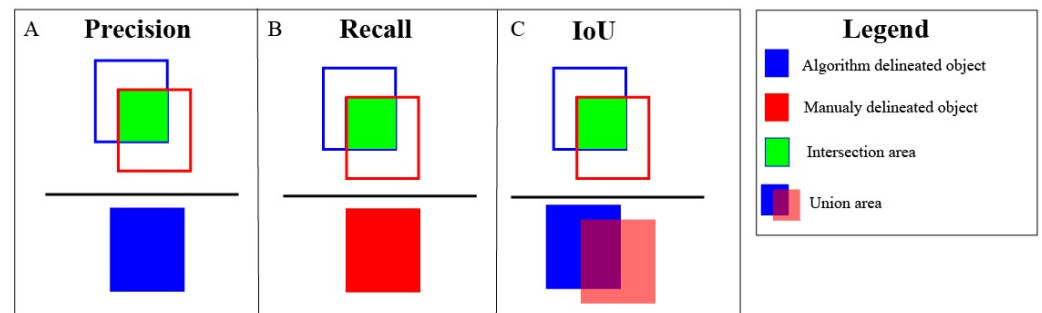
$$p = \frac{TP}{(TP + FP)} \quad (3)$$

$$F1 = 2 * \frac{(r * p)}{(r + p)} \quad (4)$$

where TP = True Positive, FN = False Negative, FP = False Positive,  $r$  = recall,  $p$  = precision.

The Mask R-CNN capacity of detecting individual objects must be evaluated as well as the quality of the delineation outlines [37]. In this work, the target objects were the individual crown of *Vismia*, *Cecropia*, and All Trees.

A tree crown test sample is properly identified (true-positive) when at least 50% of its area is intersected with an automatically delineated tree crown. Regarding the delineation quality of the true-positives, the accuracy indices recall, precision, F1, and intersection over union (IoU) were used. The IoU calculation is in Figure 6. According to Braga et al. [37], an object is correctly delineated when  $IoU \geq 0.5$ , while  $IoU > 0.7$  indicates high fidelity to the reference data.



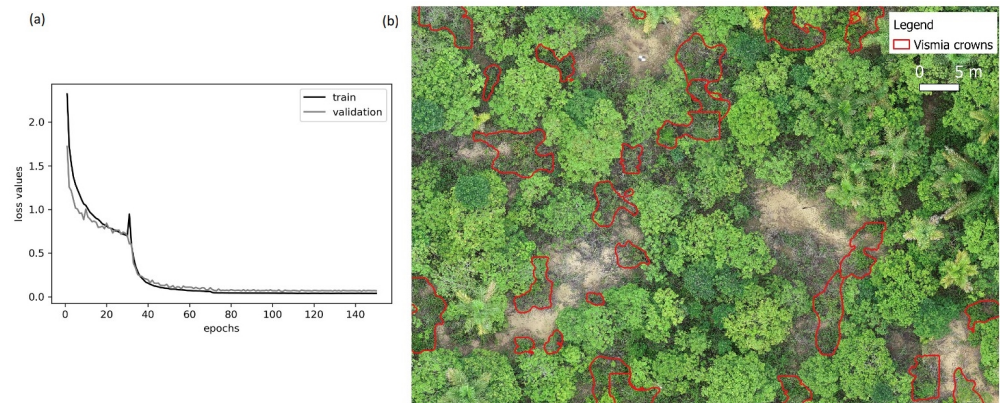
**Figure 6.** Recall, precision, and IoU to evaluate the quality of the automatic delineation.

Besides evaluating individual object detection and its delineation quality, omission and commission errors must be assessed as areas instead of object detection to avoid overestimation accuracy bias [66]. Object detection considers that the overlap between prediction and test must be higher than 50% while area assessment evaluates the whole reference data, which may degrade the accuracy indices even when overlap is greater than 50%. The area accuracy evaluation also occurred with the indices overall accuracy, recall, precision, and F1.

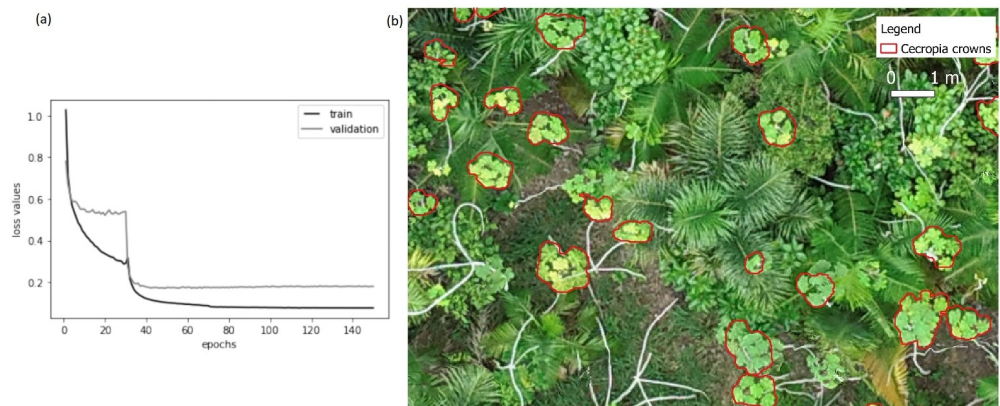
### 3. Results

Results of *Vismia*, *Cecropia*, and All Trees are illustrated from Figures 7–10. The deep learning prediction results for the whole study areas can be seen in Appendix A.

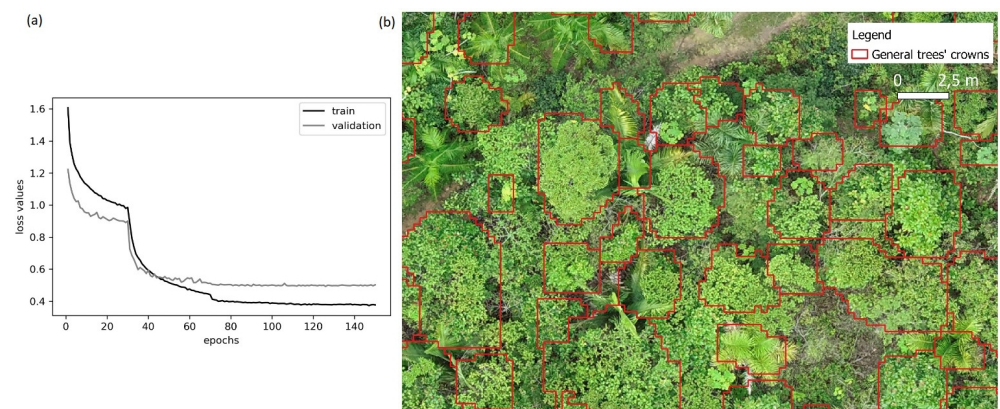
Regarding TCHI after mapping All Trees, Figure 11 shows the simple linear regression results, which should be considered preliminary due to the limited amount of samples. Despite being preliminary, the attribute Fourier textural principal component one mean (FTPC1 mean) presented the most accurate results and showed potential for the low-cost RPA images to estimate species diversity. Figure 11 also shows that the tree crown area and the tree crown perimeter were highly related to the Shannon index.



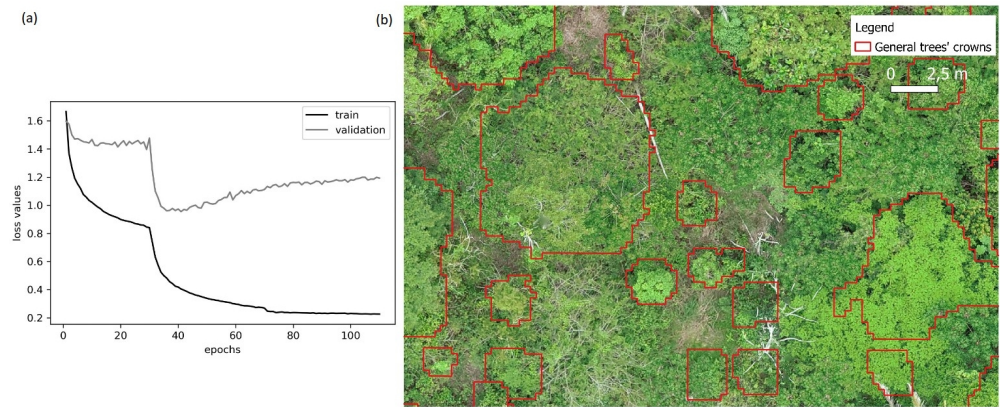
**Figure 7.** (a) Vismia training process; (b) and the prediction results in the naturally regenerating (NR) site. The loss values reduced considerably from epoch 31 due to the transfer learning process, where the whole network started to be trained instead of only the heads.



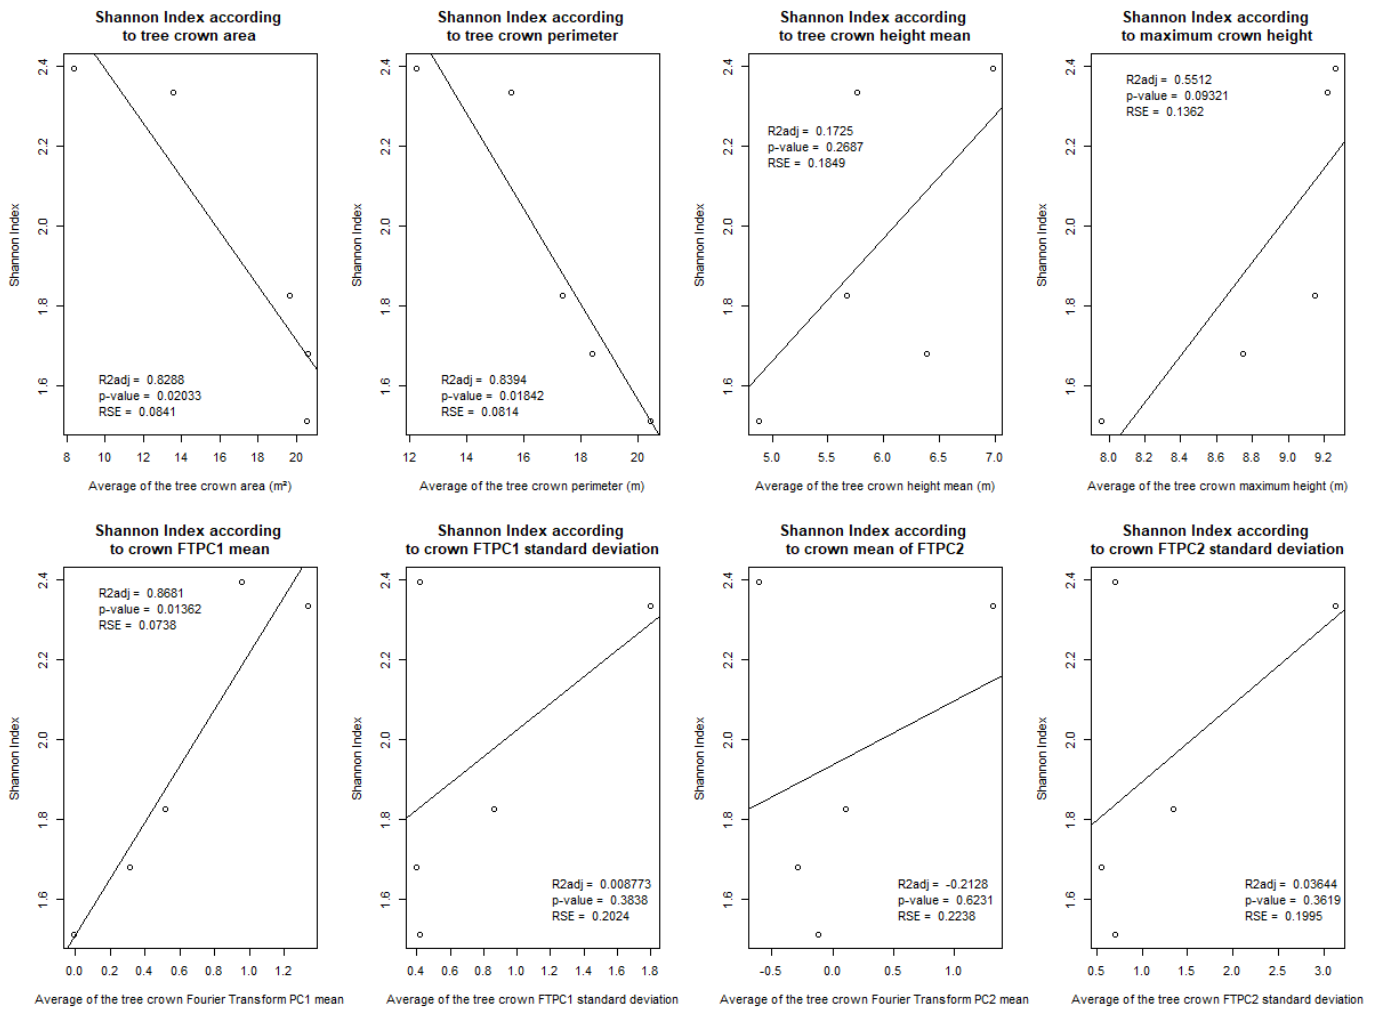
**Figure 8.** (a) Cecropia training process; (b) and the prediction results in the actively restored site with Cecropia (ARCEC). The loss values reduced considerably from epoch 31 due to the transfer learning process, where the whole network started to be trained instead of only the heads.



**Figure 9.** (a) All Trees training process in the actively restored site with Cecropia (ARCEC); (b) and the corresponding prediction results. The loss values reduced considerably from epoch 31 due to the transfer learning process, where the whole network started to be trained instead of only the heads.



**Figure 10.** (a) All Trees training process in the Actively restored diverse (ARD) site, which was not accurate; and (b) the prediction results that also used the convolutional neural network trained in ARcec (Figure 9) to map small trees, as mentioned in Section 2.3.2 (b). The loss values reduced considerably from epoch 31 due to the transfer learning process, where the whole network started to be trained instead of only the heads.



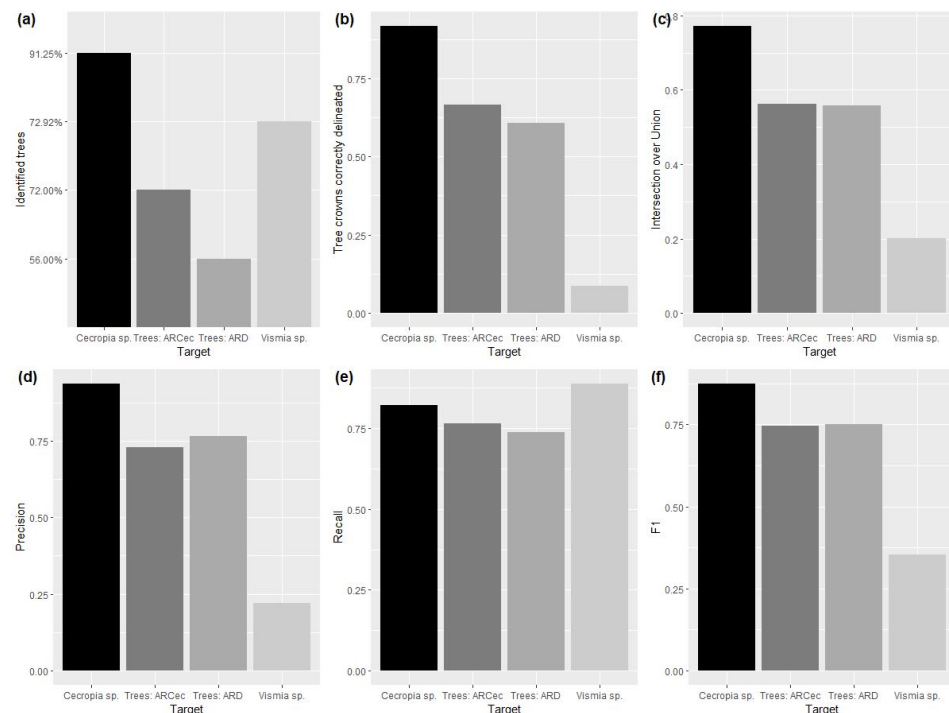
**Figure 11.** Simple linear regression results. Each simple linear regression relates the average value of a crown attribute of the trees that were automatically delineated in a field plot to the corresponding Shannon index.

### Results Accuracy

Table 2 shows that Mask R-CNN results were accurate in general, except Vismia delineation, which was poor. However, Vismia area distribution was accurate, which means that its contour errors were somehow compensated, for instance, by projecting a shape part on the left where it should be on the right. Cecropia was very accurate, not only in the Cecropia site, but also in the Diverse site, which only had test samples; thus, the data shift issue did not significantly decrease the prediction accuracy of this target (for Cecropia mapping, the Diverse site was the target image considering the domain adaption terminology). Figures 12 and 13 show in histograms the information in Table 2.

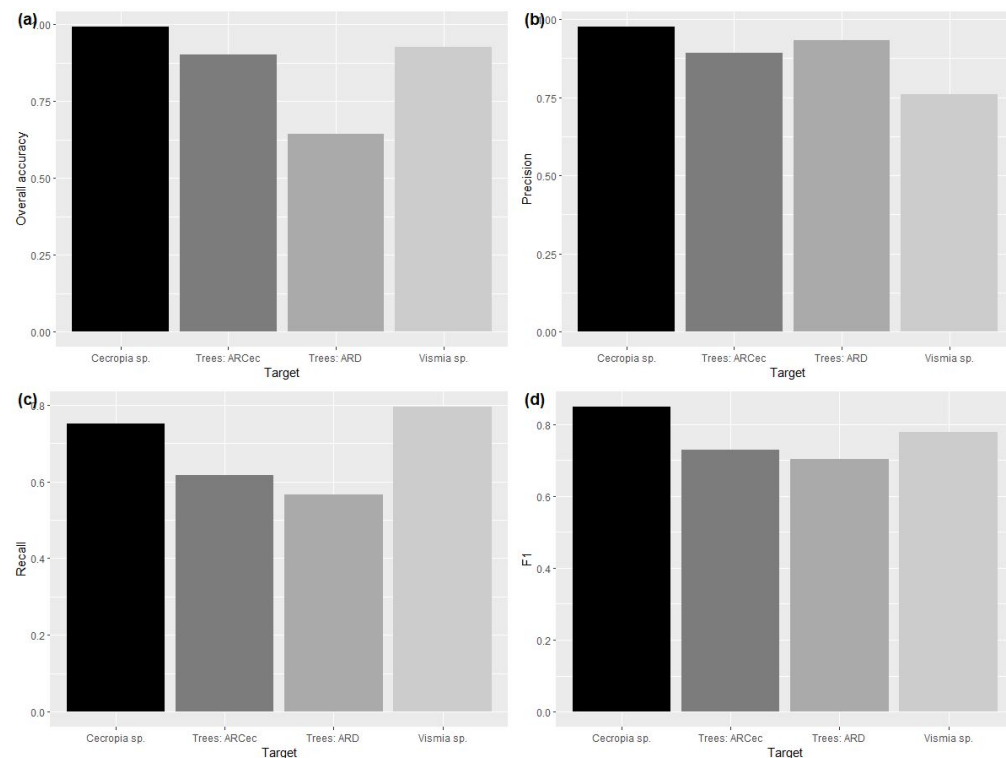
**Table 2.** Mask R-CNN accuracy for delineation and area distribution. Results were accurate in general, except Vismia’s delineation, which was inaccurate. NR is a naturally regenerating forest with Vismia occurrence, ARcec is an actively restored forest with Cecropia, and ARD is an actively restored diverse forest.

		Cecropia: ARcec	Vismia: NR	Trees: ARcec	Trees: ARD	Cecropia: ARD (Test Only)
Delineation Accuracy	Identified trees	91.25%	72.92%	72.00%	56.00%	80.00%
	Tree crowns correctly delineated	0.918	0.086	0.667	0.607	1.000
	IoU	0.772	0.202	0.563	0.558	0.790
	Precision	0.937	0.221	0.730	0.764	0.989
	Recall	0.820	0.888	0.764	0.738	0.798
	F1	0.875	0.354	0.746	0.751	0.883
Area Accuracy	Overall Accuracy	0.993	0.926	0.902	0.642	0.981
	Precision	0.976	0.760	0.893	0.932	0.943
	Recall	0.752	0.796	0.616	0.565	0.669
	F1	0.849	0.777	0.729	0.704	0.783



**Figure 12.** Mask R-CNN accuracy on the delineation of the targets: (a) identified trees; (b) tree crowns correctly delineated; (c) intersection over union; (d) precision; (e) recall; (f) and F1. ARcec is actively restored site with Cecropia and ARD is actively restored diverse site.





**Figure 13.** Mask R-CNN accuracy on the area distribution of the targets: (a) overall accuracy; (b) precision; (c) recall; (d) and F1. ARCEC is actively restored site with *Cecropia* and ARD is actively restored diverse site.

Regarding TCHI after mapping All Trees, the regression analysis showed that, despite the small number of samples, FTPC1mean has high potential in estimating species diversity via low-cost RPA. Thus, the preliminary TCHI is defined in Equation (5).

$$\text{TCHI} = 0.7095141 * \text{FTPC1mean} + 1.5064680 \quad (5)$$

where TCHI is the tree crown heterogeneity index and FTPC1mean is Fourier textural principal component one mean.

#### 4. Discussion

Results showed that, via low-cost RPA images, Mask R-CNN identifies three different canopy elements in the Amazon FR: *Vismia* crown, *Cecropia* crown, and the crowns of all trees in general (regardless of species). Moreover, since the automatic delineation of All Trees was accurate, TCHI was assessed and, despite the small number of samples, its preliminary results showed high potential in estimating the Shannon index, which measures the species diversity.

The Mask R-CNN automatic predictions for the whole extension of the three FR sites is available in Appendix A. *Cecropia* was very accurate because: (1) it has a considerable distinguishing crown that presented specific responses even to SAR data [67]; and (2) many samples were available in the *Cecropia* site. *Vismia* automatic delineation was not accurate, but its canopy area was accurately mapped. *Vismia* mapping was challenging because: (1) *Vismia*'s crown edges were not easily identifiable via photointerpretation due to an irregular overlap between two or more individuals; and (2) the *Vismia* site did not contain many *Vismia* individuals (as did the *Cecropia* site for *Cecropia* individuals); thus, fewer samples were available. Regarding the All Trees mapping in the *Cecropia* site and in the Diverse site, results were accurate.

Mapping the number of representatives of each species is relevant for planning forest management with conservation or economic purposes because it is possible to know the

protection status of each representative, as well as patches that have more or less abundance of the species representatives [48,49]. Besides the relevance of mapping the number of representatives of each species (which is possible via instance segmentation), the spatial distribution and the distance between the representatives of each tree species (which is possible via instance segmentation or semantic segmentation) are also relevant for checking fragmentation, adjacency [49], proper distribution of each species, pollination, and FR indicators assessment [48]. The percentage of canopy that *Vismia* or *Cecropia* covers is also a relevant indicator of the Amazon FR and is possible via instance segmentation or semantic segmentation.

Like Ferreira et al. [28] and Moura et al. [29], this study demonstrates that RPA has high potential to map relevant species in the Amazon biome automatically. Besides mapping species, this study also showed that low-cost RPA is capable of automatic mapping and delineating individual crowns of all kinds of trees in a tropical high diverse forest. Due to such capacity (of mapping all kinds of trees), a high potential to estimate species diversity in general via TCHI was also demonstrated in this study, although more studies in the future are mandatory to involve a broader range of FR situations that may improve the generalization capacity of the proposed index.

In other studies on *Cecropia*, Wagner et al. [68] accurately identified *Cecropia hololeuca* using deep learning (U-Net algorithm, which performs semantic segmentation) applied on a satellite image of the Brazilian Atlantic Forest biome. Moura et al. [29] accurately mapped *Cecropia* using faster\_R-CNN\_inception\_v2\_pets model on an RPA image, which generates a bounding box in its results. In this work, each *Cecropia* crown was delineated in an instance segmentation process.

Since *Cecropia* results were very accurate in this study, the Diverse site, where there were not many *Cecropia* representatives, had only *Cecropia* test samples to assess the data shift issue. The data shift did not affect the quality of the delineation of *Cecropia* crowns, but identified a shorter amount of *Cecropia* individuals and decreased the accuracy of its area distribution. Future studies must assess domain adaptation alternatives to enable the automatic identification of *Cecropia* without the requirements of sample acquisition.

The All Trees training in the Diverse site was capable of detecting larger trees only, as described in Section 2.3.2. After applying the Mask R-CNN trained in the *Cecropia* site, the detection of smaller trees improved the accuracy of the All Trees results in the Diverse site. The All Trees accuracy in both the *Cecropia* site and the Diverse site presented mean IoU equal to 0.56, which is similar to the 0.61 achieved by Braga et al. [37]. Even so, improving tree crown detection and delineation may improve FR monitoring because the proposed TCHI depends on the automatic delineation of tree crowns regardless of species, which reinforces such automatic delineation as a specific research branch.

Despite the limited amount of samples available, the statistical parameters of the preliminary TCHI suggest that the methodology applied in this work, which is unprecedented as far as the authors know, has high potential in estimating species diversity. The preliminary TCHI therefore reinforced the relation between canopy heterogeneity and species diversity, and a hypothesis mentioned by Camarretta et al. [17] that a proper delineation of tree crowns would improve heterogeneity detection, which is related to species diversity. Although presenting accurate statistical parameters, the potential of TCHI in estimating species diversity must be confirmed by future studies because a significant range of different FR situations must be evaluated. Such potential of species diversity estimation would also map, in a single area, where the FR is more-or-less diverse, which would contribute for the concept of precision forest restoration [69].

Nuijten et al. [70] also stated that canopy heterogeneity is related to species composition in FR by using different remote sensing structural metrics and a statistical analysis to classify a hexagonal tessellation in an RPA image of a Canadian boreal forest. While Nuijten et al. [70] defined structural classes inside random hexagons considering statistical CHM attributes in a boreal forest, this work automatically delineated tree crowns and related them to field data of a tropical forest to estimate species diversity.

This study performed instance segmentation processes, where Mask R-CNN was used. Although the Mask R-CNN training process is slow [28,37], this disadvantage will not be an issue if no more samples are needed. In deep learning, sampling and training processes are a notable disadvantage [55], but, ideally, a convolutional neural network should work like in the human face verification in photos [71], where no additional samples are required for accurate prediction results. However, in remote sensing, new samples are frequently required when classifying new images due to different geographic and temporal conditions, which is a phenomenon known as a data shift [56]. To handle the data shift, domain adaptation became a specific field of research [56], for instance, by collecting samples in many places and times of the year [72] or by developing transfer learning python packages to reduce the number of samples required for training [73]. Thus, when considering that an ideal convolutional neural network does not require more samples for training, Mask R-CNN becomes a good deep learning alternative because its prediction process is fast.

Despite being relevant, domain adaptation is a specific field of research. In remote sensing, machine learning processes are a relevant first step to check if the classifier maps the targets accurately. Then, after mapping the targets accurately, a domain adaptation effort may deal with the data shift issue [74]. In this study, this first step was performed as the Mask R-CNN showed high potential to identify individual crowns of important tree genders (*Vismia* and *Cecropia*) and of all trees (regardless of species) on Amazonian FR. The automatic mapping of these targets therefore must present domain adaptation studies in the future.

This work generated four different Mask R-CNN with different weights to perform one-class remote sensing classification. Each Mask R-CNN had one target class and one background class for detecting: *Vismia* (1); *Cecropia* (2); All Trees in the *Cecropia* site (3); and All Trees in the Diverse site (4). Instead of developing different Mask R-CNN for different goals, future studies should also evaluate creating one robust Mask R-CNN with more than one target class and more than one background class. In addition, the background class was essential for accurate results, so future studies should collect more samples in other FR areas with different background contexts, which generally are grass and bare soil. Thus, more target and background classes may develop a single robust neural network that quickly identifies relevant Amazon FR monitoring parameters.

## 5. Conclusions

Mask R-CNN is capable of detecting the crowns of *Vismia* and *Cecropia*, as well as the crowns of all kinds of trees, regardless of species in low-cost RPA images. When assessing species diversity estimation after mapping all kinds of trees, the preliminary TCHI showed high potential in mapping more or less diverse sites. These findings play an important role in FR monitoring, as low-cost RPA proved its potential in estimating quality indicators of Amazon FR projects, which improves FR management and monitoring.

Since low-cost RPA has high potential in detecting relevant Amazon biodiversity FR issues, future studies should evaluate more areas and domain adaptation techniques so that deep learning methods may be accurately applied with high generalization capacity. Moreover, after collecting more data by mapping All Trees in different FR situations, the TCHI equation parameters may improve its range of action. When such high generalization capacity is achieved, and no more samples are required, a user-friendly plugin for open-source geographic information system (GIS) software may be created in the future for the automatic detection of *Vismia*, *Cecropia*, general trees, and TCHI.

**Author Contributions:** Conceptualization, R.W.A. and D.L.M.V.; Methodology, R.W.A. and L.P.S.; Software, R.W.A. and L.P.S.; Validation, R.W.A., M.E.F., S.I.O. and C.H.G.; Formal Analysis, R.W.A., L.P.S. and S.I.O.; Investigation, R.W.A. and D.L.M.V.; Resources, D.L.M.V., L.S.A., L.E.V. and C.H.G.; Data Curation, R.W.A. and L.P.S.; Writing—Original Draft Preparation, R.W.A.; Writing—Review & Editing, D.L.M.V., M.E.F., S.I.O., L.P.S. and C.H.G.; Visualization, R.W.A., D.L.M.V., M.E.F., S.I.O., L.P.S. and C.H.G.; Supervision, R.W.A., D.L.M.V. and C.H.G.; Project Administration, D.L.M.V.,

M.E.F., L.S.A., L.E.V., J.R.C.T., C.P.B., M.H.M. and C.H.G.; Funding Acquisition, D.L.M.V., M.E.F., L.S.A., L.E.V. and C.H.G. All authors have read and agreed to the published version of the manuscript.

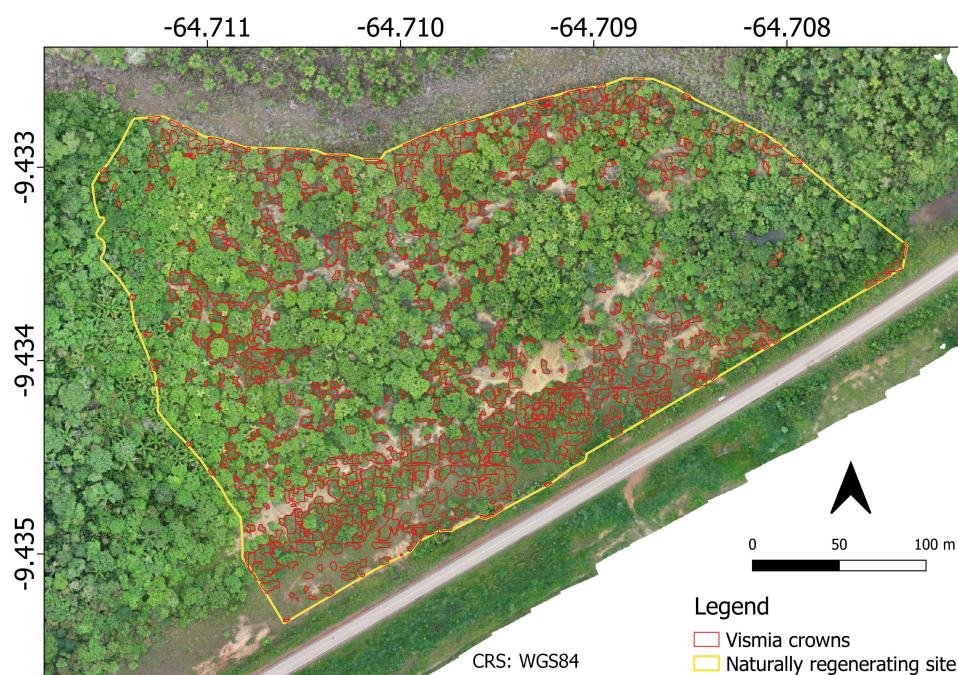
**Funding:** This study was financed in part by the Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Finance Code 001. This study was also financed in part by Embrapa Genetic Resources and Biotechnology and in part by Embrapa Meio Ambiente. M.E.F. (grant #315699/2020-5) and C.H.G. (grants #423481/2018-5 and #304413/2018-6) are CNPq Research Fellows.

**Acknowledgments:** The authors thank Embrapa, Silvia Barbosa Rodrigues for providing the forest inventory data, the field support of CoopJirau and the Federal University of Goiás/LAPIG/Pro-Vant for encouraging RPA projects. We also thank the SPAMLab at IEE-USP for the provision of RPA and GNSS equipment, data processing, and analysis infrastructure, and Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) for financial support on the PhD scholarships. We are thankful for the owners of the forest restoration areas (Jirau industry).

**Conflicts of Interest:** The authors declare no conflict of interest. The funders had no role in the design of the study; in the collection, analyses, or interpretation of data; in the writing of the manuscript, or in the decision to publish the results.

## Appendix A. Deep Learning Results Illustrated in Whole Study Areas

Figures A1–A4 show the four deep learning results in the whole extension of the study areas.



**Figure A1.** Vismia prediction results in the naturally regenerating (NR) site.




Figure A2. Cecropia prediction results in the actively restored site with Cecropia (ARCec).

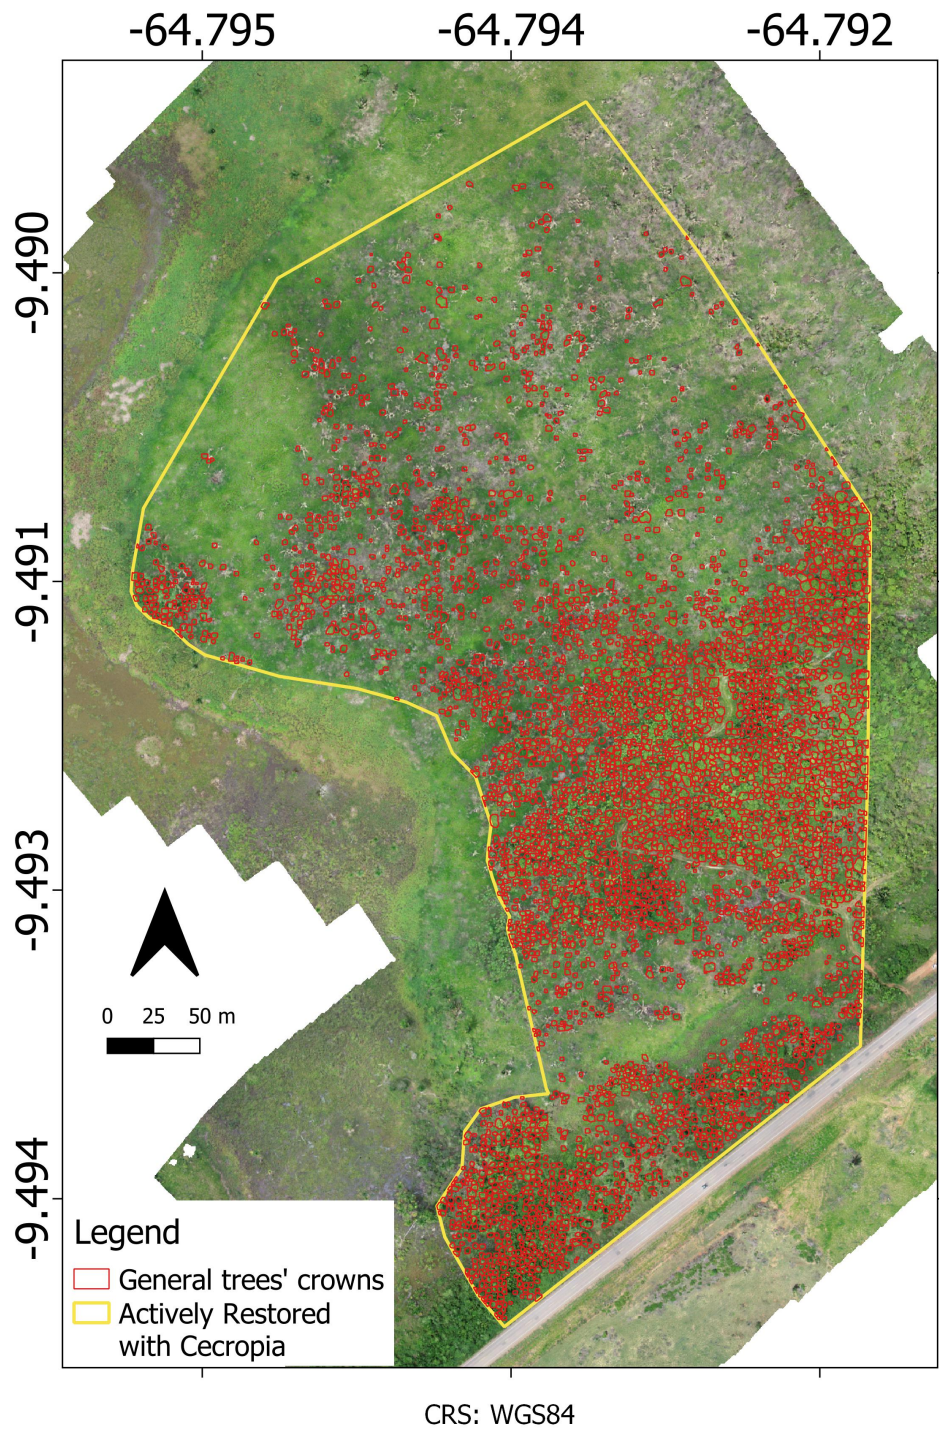
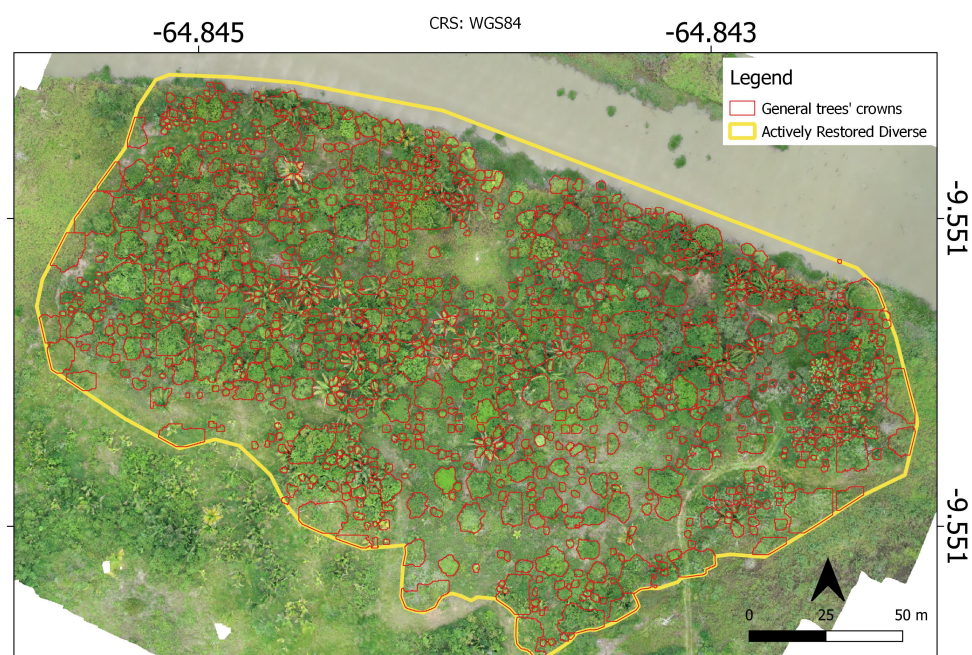


Figure A3. All Trees prediction results in the actively restored site with Cecropia (ARCec).



**Figure A4.** All Trees prediction results in the actively restored diverse site (ARD).

### Appendix B. TCHI Data after Mapping All Trees via Deep Learning

Tables A1–A3 show the data that were used to calculate the preliminary TCHI after mapping All Trees via deep learning.

**Table A1.** Forest inventory data that calculate the Shannon index for each field plot. These data were collected via traditional fieldwork of the forest inventory.

Species	Plot 1	Plot 2	Plot 3	Plot 4	Plot 5
<i>Adenantha pavonina</i>					
<i>Anacardium occidentale</i>		1			2
<i>Apocinaceae</i>					
<i>Astrocaryum aculeatum</i>					2
<i>Attalea speciosa</i>				2	1
<i>Bauhinia sp01</i>			1		
<i>Belluccia grossularioides</i>		1	2		35
<i>Bixa orellana</i>					2
<i>Byrsonima sp02</i>	3			4	
<i>Carapa guianensis</i>					
<i>Cecropia distachya</i>	5	1	1		4
<i>Cecropia membranacea</i>			2		
<i>Cecropia purpurascens</i>	7		2	3	6
<i>Cedrela fissilis</i>					
<i>Ceiba samauma</i>			1		
<i>Clitoria fairchildiana</i>					
<i>Cochlospermum orinocense</i>	8	1	4	1	
<i>Couratari macrosperma</i>					2

Table A1. Cont.

Species	Plot 1	Plot 2	Plot 3	Plot 4	Plot 5
<i>Croton matourensis</i>				34	
<i>Cupania rubiginosa</i>				3	
<i>Dipteryx odorata</i>		3			
<i>Enterolobium sp</i>		1			
<i>Eriotheca sp</i>					
<i>Eschweilera coriacea</i>					
<i>Genipa americana</i>					
<i>Handroanthus serratifolius</i>					
<i>Hevea guianensis</i>		4	1		
<i>Himatanthus sucuuba</i>					1
<i>Hymenaea courbaril</i>			2		
<i>Inga edulis</i>		3			1
<i>Inga heterophylla</i>		1			
<i>Inga sp04</i>					3
<i>Isertia hypoleuca</i>	17				9
<i>Lindackeria paludosa</i>					1
<i>Mabea sp</i>				76	
<i>Mangifera indica</i>					1
<i>Miconia pyrifolia</i>	11	3	5	3	8
<i>Myrcia sp02</i>	12	102	82	52	10
<i>Myrtaceae 2</i>				1	
<i>Myrtaceae 3</i>	2	10	1	5	1
<i>Ocotea sp</i>				1	
<i>Pachira aquatica</i>					
<i>Pachira sp</i>					
<i>Parkia multijuga</i>		1			
<i>Physocalymma scaberrimum</i>	5			1	
<i>Piper aduncum</i>	1	6			
<i>Protium unifoliolatum</i>	29			19	
<i>Psidium guajava</i>		1	1		
<i>Pterodon emarginatus</i>					
<i>Schizolobium amazonicum</i>		2			
<i>Senna alata</i>					
<i>Senna multijuga</i>		1			
<i>Simarouba amara</i>					1
<i>Simarouba versicolor</i>		3			1
<i>Solanum spp</i>					
<i>Stryphnodendron dunckeanum</i>			1		
<i>Swartzia lucida</i>				3	1
<i>Tachigali tinctoria</i>		1			



**Table A1.** *Cont.*

<b>Species</b>	<b>Plot 1</b>	<b>Plot 2</b>	<b>Plot 3</b>	<b>Plot 4</b>	<b>Plot 5</b>
<i>Tapirira guianensis</i>		1			1
<i>Trema micrantha</i>					
<i>Vismia gracilis</i>	15	10			39
<i>Vismia guianensis</i>	25	1	37	2	16
<i>Vismia sandwithii</i>	30	5	9		6
<b>Shannon Index</b>	2.334775	1.678342	1.511594	1.823349	2.394088

**Table A2.** Heterogeneity attributes of each tree crown that was automatically delineated inside the field plots. These data were collected via remote sensing. FTPC1 is Fourier textural principal component one and FTPC2 is Fourier textural principal component two.

Plot	Area	Perimeter	CHMmean	CHMstdev	CHMmin	CHMmax	FTPCA1mean	FTPCA1stde	FTPCA1min	FTPCA1max	FTPCA2mean	FTPCA2stde	FTPCA2min	FTPCA2max
3	65.119	39.311	5.119435	3.280841	-0.00328	12.6938	0.404991	1.455045	-0.69597	9.669959	0.261663	2.074722	-1.71555	14.86461
3	28.129	26.406	3.366363	1.901713	0	7.040863	-0.31739	0.311524	-0.69597	1.197709	-0.01846	0.695184	-0.66874	4.122279
3	3.613	7.629	3.005856	1.947296	0	5.719925	-0.19006	0.397121	-0.66932	0.848243	0.352878	0.759364	-0.41275	2.348622
3	9.032	17.014	7.610554	1.196479	2.299583	9.182724	0.427152	0.261602	0.089069	1.550751	-0.57614	0.78659	-1.09639	3.872258
3	22.28	23.464	2.771878	1.024129	0	7.542839	-0.50516	0.157783	-0.66554	0.454597	-0.11437	0.148365	-0.34738	0.691951
3	6.108	11.136	6.347235	2.709253	0.004837	9.0868	0.886286	1.188347	-0.58509	4.260673	0.594698	2.166958	-1.06947	6.937483
3	22.452	28.753	5.069082	1.075359	0	10.96689	-0.12052	0.379077	-0.56762	2.985223	-0.20846	0.495652	-0.80686	2.843362
3	48.431	36.363	3.725492	1.71961	-0.11349	6.606369	-0.31098	0.339763	-0.6836	1.804834	-0.11054	0.487495	-0.50532	3.720053
2	6.538	11.142	7.378312	0.835771	3.856255	8.309235	0.335718	0.188526	-0.01269	0.813891	-0.5927	0.429563	-0.87881	1.176714
2	74.84	47.461	7.720049	1.813196	0.963417	11.14235	0.525326	0.498828	-0.65947	3.16911	-0.57892	0.685009	-1.44404	3.553976
2	4.731	9.379	7.965543	0.782673	2.244179	9.572548	0.419333	0.099508	0.233903	0.596738	-0.75094	0.394346	-1.00977	0.828341
2	57.807	35.177	6.714935	2.757263	-0.02056	11.04849	0.481698	0.846595	-0.69597	3.786057	-0.22817	1.255041	-1.55378	6.290686
2	32.689	34.029	4.735298	0.778733	2.378983	6.820885	-0.28059	0.136493	-0.49576	0.151903	-0.30785	0.111566	-0.54278	0.103714
2	5.936	12.899	4.955179	0.492389	4.045937	6.063095	-0.27546	0.074306	-0.38744	-0.11507	-0.35117	0.065346	-0.50046	-0.23339
2	2.409	7.045	7.636636	2.943989	3.691277	12.20493	2.063702	1.718944	-0.28772	4.599868	1.327158	1.91322	-0.47216	6.38865
2	64.603	42.868	8.511374	0.764597	4.643204	12.09242	0.574774	0.257937	-0.22508	2.294271	-0.89379	0.261569	-1.32826	1.713706
1	63.915	45.761	4.337894	1.651773	0.793602	12.22772	-0.30323	0.256276	-0.65293	0.56833	-0.27417	0.221224	-0.98045	0.557243
1	5.333	9.969	0.903739	1.251807	0	3.760948	-0.47756	0.308349	-0.69597	0.392144	0.236693	0.485465	-0.15663	1.493688
1	4.215	9.975	12.02187	4.007458	0	15.93677	7.834983	9.142468	1.774665	29.69638	8.372838	15.52596	-2.68251	39.13299
1	35.097	31.068	8.524904	4.193895	-0.10499	15.36579	2.141066	2.536678	-0.68205	15.8741	1.016266	4.251897	-2.58661	22.14248
1	4.731	10.565	11.25474	3.037268	2.662628	13.81744	3.407625	2.624248	1.12727	11.38162	2.008901	6.083042	-2.28632	14.96166
1	3.871	8.802	7.006234	3.731296	3.468102	12.91788	2.527597	2.859887	-0.41815	7.528047	2.490923	4.130253	-1.795	10.32378
4	44.904	34.016	6.244992	1.816363	0.996513	9.068893	0.173356	0.41305	-0.60792	1.815155	-0.29251	0.773015	-1.06127	3.919278
4	2.581	9.386	6.772082	3.101002	3.562378	11.19086	2.247702	3.012706	-0.36029	7.882115	1.863147	3.653275	-1.49495	8.587377
4	65.979	48.66	4.774225	2.003087	0.424896	10.94702	-0.03879	0.750378	-0.68859	6.519537	-0.04699	1.242492	-0.7953	12.68339
4	3.785	8.802	11.18225	2.132175	1.550011	13.90279	2.100087	1.444676	0.983257	8.191	-0.33297	3.448375	-1.98948	14.56447

Table A2. Cont.

Plot	Area	Perimeter	CHMmean	CHMstdev	CHMmin	CHMmax	FTPCA1mean	FTPCA1stde	FTPCA1min	FTPCA1max	FTPCA2mean	FTPCA2stde	FTPCA2min	FTPCA2max
4	4.043	8.796	8.847744	3.095808	0.431656	12.70915	2.42247	2.344196	-0.60006	7.870145	1.434274	4.169788	-1.47805	15.05686
4	3.871	9.379	11.56552	2.705374	1.205254	13.88068	3.408568	2.312897	1.695313	9.796259	0.638469	4.27188	-2.25043	12.12099
4	89.807	45.736	5.710779	3.102415	1.64621	14.78353	0.726542	1.88475	-0.61801	8.226952	0.533843	2.356327	-1.83763	12.82553
4	86.797	52.26	3.097198	1.282993	0	10.37563	-0.43387	0.436039	-0.67807	3.297346	-0.0949	0.42824	-1.05175	4.798019
1	4.989	10.565	2.594007	0.506873	1.295456	3.367157	-0.55758	0.033358	-0.63448	-0.50407	-0.14113	0.077593	-0.20492	0.173152
1	5.763	11.142	3.537497	0.499803	1.566437	4.706284	-0.45407	0.051183	-0.53054	-0.33943	-0.18381	0.122273	-0.29835	0.203358
1	3.441	8.796	4.337077	0.992384	1.794785	5.625793	-0.29708	0.053235	-0.42464	-0.19068	-0.24132	0.214781	-0.41681	0.244165
3	40.344	35.19	6.642838	0.605936	3.950012	9.699669	0.070372	0.147227	-0.19429	0.855601	-0.58871	0.116883	-1.07072	-0.07084
3	6.194	10.565	3.579031	1.17162	0	5.186081	-0.21053	0.448625	-0.54826	1.195263	0.110991	0.765588	-0.33293	2.763646
3	6.538	11.738	2.132504	0.660017	0	3.347786	-0.55308	0.125729	-0.67807	-0.0338	-0.02748	0.243737	-0.18173	1.039601
3	3.613	8.219	6.835736	0.651863	4.250809	7.99382	0.10962	0.117666	-0.17384	0.314418	-0.51713	0.249941	-0.78584	0.28765
3	5.247	9.975	7.189706	0.577249	5.691086	8.36628	0.197599	0.120036	-0.09026	0.371255	-0.66221	0.11313	-0.83086	-0.40648
2	2.065	5.866	6.328863	0.774717	4.998161	7.379341	0.085219	0.084087	-0.06179	0.1692	-0.44667	0.197249	-0.6946	-0.1985
2	2.581	6.456	2.516833	0.273776	1.735298	3.363579	-0.57799	0.019402	-0.60178	-0.53215	-0.13763	0.022468	-0.16155	-0.08298
2	6.022	9.975	7.104853	1.958472	2.622948	10.26601	0.593139	0.496412	-0.40358	1.998008	-0.32734	0.865179	-1.33871	2.749068
2	3.957	9.392	4.496574	1.151446	1.601051	5.517975	-0.19725	0.261226	-0.60149	0.515177	-0.14092	0.447423	-0.44077	1.183987
2	3.441	7.623	6.913352	1.097175	4.765274	9.905563	0.339027	0.466996	-0.07205	1.498015	-0.32178	0.492166	-0.83903	1.172888
1	4.215	8.796	3.107001	0.970136	0.442558	4.464371	-0.48844	0.082112	-0.64182	-0.37683	-0.15895	0.105838	-0.31404	0.047556
4	8.774	12.899	4.364909	1.038066	0.549828	5.440331	-0.32587	0.148639	-0.66997	0.176937	-0.18504	0.430464	-0.41643	2.120316
4	6.624	10.559	2.655107	0.435818	1.801559	3.993599	-0.5565	0.057155	-0.6307	-0.35925	-0.15082	0.029417	-0.21058	-0.06705
4	7.656	12.911	3.628137	1.344258	1.239876	5.857239	-0.36409	0.165487	-0.64384	0.017518	-0.11675	0.231081	-0.43421	0.321494
4	4.817	9.386	4.308281	1.429484	1.84951	6.648903	-0.25823	0.187091	-0.61735	0.212086	-0.07847	0.275433	-0.60457	0.520399
4	8.172	12.309	2.745759	1.21562	0	4.274643	-0.42806	0.174489	-0.66996	0.014023	-0.02432	0.267492	-0.29852	0.903595
4	4.817	9.386	4.824788	1.137	2.2743	6.535606	-0.19017	0.1711	-0.55245	0.132062	-0.28883	0.21769	-0.56395	0.076414
4	1.29	4.693	1.99779	0.114795	1.788002	2.433456	-0.63025	0.004002	-0.6365	-0.62539	-0.1262	0.002236	-0.12905	-0.12288
4	3.871	8.79	2.232366	1.483713	0	11.91653	-0.10782	1.319545	-0.63316	3.957197	0.528906	1.699226	-0.16908	6.286868

Table A2. Cont.

Plot	Area	Perimeter	CHMmean	CHMstdev	CHMmin	CHMmax	FTPCA1mean	FTPCA1stde	FTPCA1min	FTPCA1max	FTPCA2mean	FTPCA2stde	FTPCA2min	FTPCA2max
4	4.129	8.808	7.194678	0.863822	5.4515	9.093864	0.267943	0.21689	-0.05229	0.690447	-0.56302	0.229609	-0.86612	-0.05738
4	1.979	5.872	9.90452	0.969666	7.360344	11.57283	1.286932	0.46469	0.872513	2.458546	-0.83582	0.520577	-1.24902	0.309813
5	4.051	9.596	6.993476	0.554035	2.319511	8.072655	0.721011	0.165133	0.362456	0.998681	-0.83646	0.204428	-1.04165	-0.29032
5	6.302	10.802	7.177172	0.962539	3.934128	8.710861	0.92671	0.206999	0.336062	1.464034	-0.73948	0.448283	-1.16833	0.420686
5	7.022	11.399	7.740243	0.938236	4.896156	9.538589	1.059383	0.32214	0.621426	1.621939	-0.98677	0.351309	-1.55799	-0.09234
5	28.54	26.983	6.871229	1.393398	0.894493	8.841682	0.927168	0.726795	-0.37189	5.661978	-0.52068	1.287771	-1.29739	7.181975
5	7.743	11.996	6.367768	0.818534	3.083389	8.828812	0.574648	0.244304	0.04083	1.405117	-0.65111	0.348197	-0.95097	0.358819
5	4.411	8.999	8.144852	1.777536	2.885094	9.614311	1.716011	0.506895	1.163184	3.193094	-0.25323	1.67511	-1.5567	3.901798
5	5.942	10.199	5.172714	0.436717	3.687805	7.992622	0.181246	0.05757	0.048333	0.271038	-0.57408	0.091129	-0.67794	-0.33007
5	2.881	7.201	6.094399	1.260213	3.810753	7.862221	0.667777	0.321439	-0.13697	1.329934	-0.4243	0.59697	-0.92484	0.985291
5	14.765	17.412	7.514438	1.895635	3.224686	9.724991	1.435498	0.777824	-0.03845	3.700222	-0.23322	1.390438	-1.62491	3.440152
5	7.563	11.99	6.417062	1.207018	4.493248	8.258713	0.656216	0.449859	-0.00052	1.596533	-0.5972	0.422816	-1.18557	0.477079
5	5.492	10.205	5.385297	0.622274	4.03315	9.073189	0.289163	0.273601	-0.01178	1.354232	-0.48864	0.35346	-0.76967	0.997614
5	6.662	11.399	7.782701	1.402899	3.656174	9.601425	1.289672	0.363723	0.078946	1.971506	-0.78493	0.833656	-1.45933	1.355572
5	6.212	10.802	7.36717	0.461894	4.689758	8.755592	0.857622	0.127292	0.704136	1.294942	-0.93603	0.145056	-1.12679	-0.62726
5	4.772	12.002	5.167382	1.19266	3.573372	8.392746	0.293052	0.452028	-0.08823	1.48954	-0.38059	0.31974	-0.987	0.323958
5	5.042	10.205	7.59755	1.479013	3.070595	9.733353	1.38104	0.595625	0.715453	2.795767	-0.25195	1.62803	-1.58962	5.121841
5	2.971	7.208	4.842277	1.418374	2.329239	8.578911	0.307523	0.448966	-0.20342	1.22301	0.295702	0.925839	-0.61559	2.450948
5	5.312	9.602	8.224847	1.599713	4.244247	9.736839	1.533879	0.679356	-0.06244	3.439811	-0.53613	1.324322	-1.57109	3.209459
5	6.032	10.796	4.526514	0.863805	1.949219	6.453194	0.086033	0.163719	-0.16705	0.433793	-0.38167	0.251908	-0.64997	0.241877
5	5.042	10.802	8.476414	1.178713	4.289162	11.74305	1.45153	0.532362	0.891494	2.879493	-1.00337	0.660389	-2.13556	1.238157
5	3.331	9.017	10.18775	1.185139	4.634438	12.37226	2.297686	0.384895	1.858209	3.104045	-1.44549	0.662927	-2.04331	-0.14826
5	36.822	28.787	6.697485	2.38479	1.730072	11.74391	0.999325	1.04185	-0.25401	5.554715	-0.54858	1.10566	-2.04423	5.28658
5	7.743	12.002	5.744165	0.359735	3.956627	6.189232	0.307561	0.063987	0.157081	0.448816	-0.65428	0.112285	-0.77074	-0.25877
5	7.473	12.002	7.598305	1.552404	4.781235	10.34891	1.347795	0.689081	0.19237	2.768367	-0.44058	0.805717	-1.51418	1.784046
5	10.083	13.209	9.906447	1.003685	5.13726	11.6647	2.029642	0.357005	1.326314	3.129253	-1.30954	0.9755	-2.12405	2.578822
5	6.842	10.802	6.438966	0.985115	5.438622	9.635727	0.632272	0.516692	0.266723	2.316442	-0.56945	0.559291	-1.51076	1.258503

**Table A3.** Mean values of the heterogeneity attributes (shown in Table A2) calculated for each field plot and corresponding Shannon index measured by traditional fieldwork. This sheet was used in the regression analysis. FTPCA1 is Fourier textural principal component one and FTPCA2 is Fourier textural principal component two.

Plot	Area	Perimeter	CHMmean	CHMstdev	CHMmin	CHMmax	FTPCA1mean	FTPCA1stdev	FTPCA1min	FTPCA1max	FTPCA2mean	FTPCA2stdev	FTPCA2min	FTPCA2max	Shannon
1	13.557	15.5439	5.762497	2.084269	1.191858	9.219016	1.333331	1.794779	-0.17786	6.402963	1.312624	3.121833	-1.17216	8.928008	2.334775
2	20.58608	18.40862	6.382908	1.2634	2.886571	8.745109	0.314357	0.396097	-0.32853	1.457309	-0.28852	0.549242	-0.8619	1.895913	1.678342
3	20.54615	20.44331	4.876593	1.42472	1.236889	7.95645	-0.00859	0.419196	-0.47375	1.959594	-0.11564	0.700278	-0.75573	3.308784	1.511594
4	19.66089	17.36933	5.669507	1.626192	1.785102	9.145865	0.516664	0.861543	-0.28378	3.348483	0.103445	1.347034	-0.93891	5.269306	1.823349
5	8.36204	12.21668	6.977465	1.157382	3.629697	9.25874	0.958779	0.418766	0.29713	2.217852	-0.61008	0.699209	-1.31593	1.634646	2.394088

## References

1. SER. Princípios da Society for Ecological Restoration (SER) International Sobre a Restauração Ecológica. Technical Report, Embrapa Florestas. 2021. Available online: [https://cdn.ymaws.com/www.ser.org/resource/resmgr/custompages/publications/SER\\_Primer/ser-primer-portuguese.pdf](https://cdn.ymaws.com/www.ser.org/resource/resmgr/custompages/publications/SER_Primer/ser-primer-portuguese.pdf) (accessed on 11 October 2021)
2. Muradian, R.; Corbera, E.; Pascual, U.; Kosoy, N.; May, P.H. Reconciling theory and practice: An alternative conceptual framework for understanding payments for environmental services. *Ecol. Econ.* **2010**, *69*, 1202–1208. [CrossRef]
3. Adams, C.; Rodrigues, S.T.; Calmon, M.; Kumar, C. Impacts of large-scale forest restoration on socioeconomic status and local livelihoods: what we know and do not know. *Biotropica* **2016**, *48*, 731–744. [CrossRef]
4. Brancalion, P.H.S.; Viani, R.A.G.; Rodrigues, R.R.; Gandolfi, S. Avaliação e monitoramento de áreas em processo de restauração. In *Restauração Ecológica de Ecossistemas Degradados*; Martins, S., Ed.; Editora UFV: Viçosa, Brazil, 2012; pp. 262–293. Available online: [http://www.esalqlastrop.com.br/img/aulas/Cumbuca%206\(2\).pdf](http://www.esalqlastrop.com.br/img/aulas/Cumbuca%206(2).pdf) (accessed on 31 October 2021)
5. PRMA. Protocolo de Monitoramento para Programas e Projetos de Restauração Florestal. Monitoring Protocol for Forest Restoration Programs & Projects. Technical Report, PACTO PELA RESTAURAÇÃO DA MATA ATLÂNTICA. 2013. Available online: [http://media.wix.com/ugd/5da841\\_c228aedb71ae4221bc95b909e0635257.pdf](http://media.wix.com/ugd/5da841_c228aedb71ae4221bc95b909e0635257.pdf) (accessed on 10 July 2021)
6. Chaves, R.B.; Durigan, G.; Brancalion, P.H.; Aronson, J. On the need of legal frameworks for assessing restoration projects success: new perspectives from São Paulo state (Brazil). *Restor. Ecol.* **2015**, *23*, 754–759. [CrossRef]
7. McDonald, T.; Gann, G.; Jonson, J.; Dixon, K. *International Standards for the Practice of Ecological Restoration—Including Principles and Ley Concepts*; Technical Report; Society for Ecological Restoration: Washington, DC, USA, 2016. Available online: [http://www.seraustralasia.com/wheel/image/SER\\_International\\_Standards.pdf](http://www.seraustralasia.com/wheel/image/SER_International_Standards.pdf) (accessed on 9 August 2021)
8. Lovejoy, T.E.; Nobre, C. Amazon Tipping Point. *Sci. Adv.* **2018**, *4*, eaat2340. [CrossRef]
9. Silva-Junior, C.H.L.; Pessoa, A.C.M.; Carvalho, N.S.; Reis, J.B.C.; Anderson, L.O.; Aragão, L.E.O.C. The Brazilian Amazon deforestation rate in 2020 is the greatest of the decade. *Nat. Ecol. Evol.* **2021**, *5*, 144–145. [CrossRef]
10. Rödig, E.; Cuntz, M.; Rammig, A.; Fischer, R.; Taubert, F.; Huth, A. The importance of forest structure for carbon fluxes of the Amazon rainforest. *Environ. Res. Lett.* **2018**, *13*, 054013. [CrossRef]
11. Jakovac, C.C.; Bongers, F.; Kuyper, T.W.; Mesquita, R.C.; Peña-Claros, M. Land use as a filter for species composition in Amazonian secondary forests. *J. Veg. Sci.* **2016**, *27*, 1104–1116. [CrossRef]
12. Poorter, L.; Bongers, F.; Aide, T.M.; Zambrano, A.M.A.; Balvanera, P.; Becknell, J.M.; Boukili, V.; Brancalion, P.H.; Broadbent, E.N.; Chazdon, R.L.; others. Biomass resilience of Neotropical secondary forests. *Nature* **2016**, *530*, 211–214. [CrossRef]
13. Freitas, M.G.; Rodrigues, S.B.; Campos-Filho, E.M.; do Carmo, G.H.P.; da Veiga, J.M.; Junqueira, R.G.P.; Vieira, D.L.M. Evaluating the success of direct seeding for tropical forest restoration over ten years. *For. Ecol. Manag.* **2019**, *438*, 224–232. [CrossRef]
14. Vieira, D.L.M.; Rodrigues, S.B.; Jakovac, C.C.; da Rocha, G.P.E.; Reis, F.; Borges, A. Active Restoration Initiates High Quality Forest Succession in a Deforested Landscape in Amazonia. *Forests* **2021**, *12*, 1022. [CrossRef]
15. Mesquita, R.C.; Ickes, K.; Ganade, G.; Williamson, G.B. Alternative successional pathways in the Amazon Basin. *J. Ecol.* **2001**, *89*, 528–537. [CrossRef]
16. Bourgoin, C.; Betbeder, J.; Couteron, P.; Blanc, L.; Dessard, H.; Oszwald, J.; Le Roux, R.; Cornu, G.; Reymondin, L.; Mazzei, L.; others. UAV-based canopy textures assess changes in forest structure from long-term degradation. *Ecol. Indic.* **2020**, *115*, 106386. [CrossRef]
17. Camarretta, N.; Harrison, P.A.; Bailey, T.; Potts, B.; Lucieer, A.; Davidson, N.; Hunt, M. Monitoring forest structure to guide adaptive management of forest restoration: a review of remote sensing approaches. *New For.* **2020**, *51*, 573–596. [CrossRef]
18. Zahawi, R.A.; Dandois, J.P.; Holl, K.D.; Nadwodny, D.; Reid, J.L.; Ellis, E.C. Using lightweight unmanned aerial vehicles to monitor tropical forest recovery. *Biol. Conserv.* **2015**, *186*, 287–295. [CrossRef]
19. Chen, S.; McDermid, G.; Castilla, G.; Linke, J. Measuring vegetation height in linear disturbances in the boreal forest with UAV photogrammetry. *Remote Sens.* **2017**, *9*, 1257. [CrossRef]
20. Wu, X.; Shen, X.; Cao, L.; Wang, G.; Cao, F. Assessment of individual tree detection and canopy cover estimation using unmanned aerial vehicle based light detection and ranging (UAV-LiDAR) data in planted forests. *Remote Sens.* **2019**, *11*, 908. [CrossRef]
21. Belmonte, A.; Sankey, T.; Biederman, J.A.; Bradford, J.; Goetz, S.J.; Kolb, T.; Woolley, T. UAV-derived estimates of forest structure to inform ponderosa pine forest restoration. *Remote Sens. Ecol. Conserv.* **2020**, *6*, 181–197. [CrossRef]
22. Albuquerque, R.W.; Ferreira, M.E.; Olsen, S.I.; Tymus, J.R.C.; Balieiro, C.P.; Mansur, H.; Moura, C.J.R.; Costa, J.V.S.; Branco, M.R.C.; Grohmann, C.H. Forest Restoration Monitoring Protocol with a Low-Cost Remotely Piloted Aircraft: Lessons Learned from a Case Study in the Brazilian Atlantic Forest. *Remote Sens.* **2021**, *13*, 2401. [CrossRef]
23. Almeida, D.R.A.d.; Stark, S.C.; Chazdon, R.; Nelson, B.W.; César, R.G.; Meli, P.; Gorgens, E.; Duarte, M.M.; Valbuena, R.; Moreno, V.S.; others. The effectiveness of lidar remote sensing for monitoring forest cover attributes and landscape restoration. *For. Ecol. Manag.* **2019**, *438*, 34–43. [CrossRef]
24. LeCun, Y.; Bengio, Y.; Hinton, G. Deep learning. *Nature* **2015**, *521*, 436–444. [CrossRef]
25. Zhao, B.; Feng, J.; Wu, X.; Yan, S. A survey on deep learning-based fine-grained object classification and semantic segmentation. *Int. J. Autom. Comput.* **2017**, *14*, 119–135. [CrossRef]
26. Zhu, X.X.; Tuia, D.; Mou, L.; Xia, G.S.; Zhang, L.; Xu, F.; Fraundorfer, F. Deep learning in remote sensing: A comprehensive review and list of resources. *IEEE Geosci. Remote Sens. Mag.* **2017**, *5*, 8–36. [CrossRef]

27. Brodrick, P.G.; Davies, A.B.; Asner, G.P. Uncovering ecological patterns with convolutional neural networks. *Trends Ecol. Evol.* **2019**, *34*, 734–745. [CrossRef]
28. Ferreira, M.P.; de Almeida, D.R.A.; de Almeida Papa, D.; Minervino, J.B.S.; Veras, H.F.P.; Formighieri, A.; Santos, C.A.N.; Ferreira, M.A.D.; Figueiredo, E.O.; Ferreira, E.J.L. Individual tree detection and species classification of Amazonian palms using UAV images and deep learning. *For. Ecol. Manag.* **2020**, *475*, 118397. [CrossRef]
29. Moura, M.M.; de Oliveira, L.E.S.; Sanquetta, C.R.; Bastos, A.; Mohan, M.; Corte, A.P.D. Towards Amazon Forest Restoration: Automatic Detection of Species from UAV Imagery. *Remote Sens.* **2021**, *13*, 2627. [CrossRef]
30. Schiefer, F.; Kattenborn, T.; Frick, A.; Frey, J.; Schall, P.; Koch, B.; Schmidlein, S. Mapping forest tree species in high resolution UAV-based RGB-imagery by means of convolutional neural networks. *ISPRS J. Photogramm. Remote Sens.* **2020**, *170*, 205–215. [CrossRef]
31. Haffer, J.; others. Speciation in Amazonian forest birds. *Science* **1969**, *165*, 131–137. [CrossRef]
32. Prance, G.T. A comparison of the efficacy of higher taxa and species numbers in the assessment of biodiversity in the neotropics. *Philos. Trans. R. Soc. Lond. Ser. B Biol. Sci.* **1994**, *345*, 89–99.
33. Antonelli, A.; Zizka, A.; Carvalho, F.A.; Scharn, R.; Bacon, C.D.; Silvestro, D.; Condamine, F.L. Amazonia is the primary source of Neotropical biodiversity. *Proc. Natl. Acad. Sci. USA* **2018**, *115*, 6034–6039. [CrossRef]
34. Ter Steege, H.; de Oliveira, S.M.; Pitman, N.C.; Sabatier, D.; Antonelli, A.; Andino, J.E.G.; Aymard, G.A.; Salomão, R.P. Towards a dynamic list of Amazonian tree species. *Sci. Rep.* **2019**, *9*, 3501. [CrossRef]
35. Ruiz-Santaquiteria, J.; Bueno, G.; Deniz, O.; Vallez, N.; Cristobal, G. Semantic versus instance segmentation in microscopic algae detection. *Eng. Appl. Artif. Intell.* **2020**, *87*, 103271. [CrossRef]
36. Hafiz, A.M.; Bhat, G.M. A survey on instance segmentation: State of the art. *Int. J. Multimed. Inf. Retr.* **2020**, *9*, 171–189. [CrossRef]
37. Braga, J.R.G.; Peripato, V.; Dalagnol, R.; Ferreira, M.P.; Tarabalka, Y.; Aragão, L.E.O.C.; Campos Velho, H.F.; Shiguemori, E.H.; Wagner, F.H. Tree Crown Delineation Algorithm Based on a Convolutional Neural Network. *Remote Sens.* **2020**, *12*, 1288. [CrossRef]
38. He, K.; Gkioxari, G.; Dollár, P.; Girshick, R. Mask r-cnn. In Proceedings of the IEEE International Conference on Computer Vision, Venice, Italy, 22–29 October 2017; pp. 2961–2969.
39. Spellerberg, I.F.; Fedor, P.J. A tribute to Claude Shannon (1916–2001) and a plea for more rigorous use of species richness, species diversity and the ‘Shannon–Wiener’ Index. *Glob. Ecol. Biogeogr.* **2003**, *12*, 177–179. [CrossRef]
40. DJI. Phantom 4PRO. Available online: <https://www.dji.com/br/phantom-4-pro> (accessed on 12 January 2022).
41. SPECTRA GEOSPATIAL. SP60 Product Details. Available online: <https://spectrageospatial.com/sp60-gnss-receiver/> (accessed on 12 January 2022).
42. DRONESMADEEASY. Map Pilot for DJI. 2020. Available online: <https://support.dronesmadeeasy.com/hc/en-us/categories/200739936-Map-Pilot-for-iOS> (accessed on 25 February 2021).
43. AGISOFT. Discover Intelligent Photogrammetry with Metashape. 2020. Available online: <https://www.agisoft.com/> (accessed on 25 February 2021).
44. Python Core Team. Python: A dynamic, Open Source Programming Language. Python Softw. Found. Available online: <https://www.python.org/> (accessed on 17 June 2021).
45. R Core Team. *R: A language and Environment for Statistical Computing*; R Foundation for Statistical Computing: Vienna, Austria, 2013. Available online: <http://www.R-project.org> (accessed on 17 June 2021).
46. QGIS Development Team. QGIS Geographic Information System. QGIS Association. 2021. Available online: <https://www.qgis.org> (accessed on 17 June 2021).
47. ANAC. Agência Nacional de Aviação Civil. Requisitos Gerais para Aeronaves não Tripuladas de uso Civil. Resolução Número 419, de 2 de Maio de 2017. Regulamento Brasileiro da Aviação Civil Especial, RBAC-E Número 94. 2017. Available online: [https://www.anac.gov.br/assuntos/legislacao/legislacao-1/rbha-e-rbac/rbac/rbac-e-94/@@display-file/arquivo\\_norma/RBACE94EMD00.pdf](https://www.anac.gov.br/assuntos/legislacao/legislacao-1/rbha-e-rbac/rbac/rbac-e-94/@@display-file/arquivo_norma/RBACE94EMD00.pdf) (accessed on 17 June 2021).
48. Guariguata, M.R.; Pinard, M.A. Ecological knowledge of regeneration from seed in neotropical forest trees: Implications for natural forest management. *For. Ecol. Manag.* **1998**, *112*, 87–99. [CrossRef]
49. Varma, V.K.; Ferguson, I.; Wild, I. Decision support system for the sustainable forest management. *For. Ecol. Manag.* **2000**, *128*, 49–55. [CrossRef]
50. Minaee, S.; Boykov, Y.Y.; Porikli, F.; Plaza, A.J.; Kehtarnavaz, N.; Terzopoulos, D. Image Segmentation Using Deep Learning: A Survey. *IEEE Trans. Pattern Anal. Mach. Intell.* **2021**. [CrossRef]
51. Antonelli, A.; Sanmartín, I. Why are there so many plant species in the Neotropics? *Taxon* **2011**, *60*, 403–414. [CrossRef]
52. Ter Steege, H.; Sabatier, D.; Mota de Oliveira, S.; Magnusson, W.E.; Molino, J.F.; Gomes, V.F.; Pos, E.T.; Salomão, R.P. Estimating species richness in hyper-diverse large tree communities. *Ecology* **2017**, *98*, 1444–1454. [CrossRef]
53. Bellinger, C.; Sharma, S.; Japkowicz, N. One-Class versus Binary Classification: Which and When? In Proceedings of the 2012 11th International Conference on Machine Learning and Applications, Boca Raton, FL, USA, 12–15 December 2012; Volume 2, pp. 102–106. [CrossRef]
54. Deng, X.; Li, W.; Liu, X.; Guo, Q.; Newsam, S. One-class remote sensing classification: One-class vs. binary classifiers. *Int. J. Remote. Sens.* **2018**, *39*, 1890–1910. [CrossRef]

55. Dargan, S.; Kumar, M.; Ayyagari, M.R.; Kumar, G. A survey of deep learning and its applications: A new paradigm to machine learning. *Arch. Comput. Methods Eng.* **2020**, *27*, 1071–1092. [[CrossRef](#)]
56. Zhang, J.; Liu, J.; Pan, B.; Shi, Z. Domain Adaptation Based on Correlation Subspace Dynamic Distribution Alignment for Remote Sensing Image Scene Classification. *IEEE Trans. Geosci. Remote Sens.* **2020**, *58*, 7920–7930. [[CrossRef](#)]
57. Shannon, C.E. A mathematical theory of communication. *Bell Syst. Tech. J.* **1948**, *27*, 379–423. [[CrossRef](#)]
58. PyPI. Fototex. Available online: <https://pypi.org/project/fototex/> (accessed on 12 January 2022).
59. Couteron, P.; Barbier, N.; Gautier, D. Textural ordination based on Fourier spectral decomposition: a method to analyze and compare landscape patterns. *Landsc. Ecol.* **2006**, *21*, 555–567. [[CrossRef](#)]
60. Pommerening, A. Approaches to quantifying forest structures. *For. Int. J. For. Res.* **2002**, *75*, 305–324. [[CrossRef](#)]
61. Alexopoulos, E.C. Introduction to multivariate regression analysis. *Hippokratia* **2010**, *14*, 23.
62. Pal, M.; Bharati, P. Introduction to correlation and linear regression analysis. In *Applications of Regression Techniques*; Springer: Singapore, 2019; pp. 1–18.
63. Lewis, S. Regression analysis. *Pract. Neurol.* **2007**, *7*, 259–264. [[CrossRef](#)]
64. Congalton, R.G. A review of assessing the accuracy of classifications of remotely sensed data. *Remote Sens. Environ.* **1991**, *37*, 35–46. [[CrossRef](#)]
65. Goutte, C.; Gaussier, E. A probabilistic interpretation of precision, recall and F-score, with implication for evaluation. In *European Conference on Information Retrieval*; Springer: Berlin/Heidelberg, Germany, 2005; pp. 345–359.
66. Radoux, J.; Bogaert, P. Good practices for object-based accuracy assessment. *Remote Sens.* **2017**, *9*, 646. [[CrossRef](#)]
67. Foody, G.M.; Green, R.M.; Lucas, R.; Curran, P.J.; Honzák, M.; Do Amaral, I. Observations on the relationship between SIR-C radar backscatter and the biomass of regenerating tropical forests. *Int. J. Remote Sens.* **1997**, *18*, 687–694. [[CrossRef](#)]
68. Wagner, F.H.; Sanchez, A.; Tarabalka, Y.; Lotte, R.G.; Ferreira, M.P.; Aidar, M.P.; Gloor, E.; Phillips, O.L.; Aragao, L.E. Using the U-net convolutional network to map forest types and disturbance in the Atlantic rainforest with very high resolution images. *Remote Sens. Ecol. Conserv.* **2019**, *5*, 360–375. [[CrossRef](#)]
69. Castro, J.; Morales-Rueda, F.; Navarro, F.B.; Löf, M.; Vacchiano, G.; Alcaraz-Segura, D. Precision restoration: A necessary approach to foster forest recovery in the 21st century. *Restor. Ecol.* **2021**, *29*, e13421. [[CrossRef](#)]
70. Nuijten, R.J.; Coops, N.C.; Watson, C.; Theberge, D. Monitoring the Structure of Regenerating Vegetation Using Drone-Based Digital Aerial Photogrammetry. *Remote Sens.* **2021**, *13*, 1942. [[CrossRef](#)]
71. Guo, G.; Zhang, N. A survey on deep learning based face recognition. *Comput. Vis. Image Underst.* **2019**, *189*, 102805. [[CrossRef](#)]
72. Brandt, M.; Tucker, C.J.; Kariryaa, A.; Rasmussen, K.; Abel, C.; Small, J.; Chave, J.; Rasmussen, L.V.; Hiernaux, P.; Diouf, A.A.; others. An unexpectedly large count of trees in the West African Sahara and Sahel. *Nature* **2020**, *587*, 78–82. [[CrossRef](#)]
73. Weinstein, B.G.; Marconi, S.; Aubry-Kientz, M.; Vincent, G.; Senyondo, H.; White, E.P. DeepForest: A Python package for RGB deep learning tree crown delineation. *Methods Ecol. Evol.* **2020**, *11*, 1743–1751. [[CrossRef](#)]
74. Zhu, L.; Ma, L. Class centroid alignment based domain adaptation for classification of remote sensing images. *Pattern Recognit. Lett.* **2016**, *83*, 124–132. [[CrossRef](#)]