


UNIVERSIDADE FEDERAL DO PARANÁ

MARKS MELO MOURA

MODELAGEM ESPAÇO-TEMPORAL DA BIOMASSA EM ÁREA DE
RESTAURAÇÃO FLORESTAL A PARTIR DE SENSORES ORBITAIS E AÉREOS

CURITIBA

2021



MARKS MELO MOURA

MODELAGEM ESPAÇO-TEMPORAL DA BIOMASSA EM ÁREA DE
RESTAURAÇÃO FLORESTAL A PARTIR DE SENSORES ORBITAIS E AÉREOS

Tese apresentada ao curso de Pós-Graduação em Ciências florestais, Setor de Ciências Agrárias, Universidade Federal do Paraná, como requisito parcial à obtenção do título de Doutor em Engenharia Florestal.

Orientadora: Profa. Dra. Ana Paula Dalla Corte
Coorientador: Prof. Dr. Carlos Roberto Sanquetta
Dr. Alexis de Sousa Bastos

CURITIBA

2021

Ficha catalográfica elaborada pela
Biblioteca de Ciências Florestais e da Madeira - UFPR

Moura, Marks Melo

Modelagem espaço-temporal da biomassa em área de restauração florestal a partir de sensores orbitais e aéreos / Marks Melo Moura.
– Curitiba, 2022.

1 recurso on-line : PDF.

Orientadora: Profa. Dra. Ana Paula Dalla Corte

Coorientadores: Prof. Dr. Carlos Roberto Sanquetta

Prof. Dr. Alexis de Sousa Bastos

Tese (Doutorado) - Universidade Federal do Paraná, Setor de Ciências Agrárias, Programa de Pós-Graduação em Engenharia Florestal. Defesa: Curitiba, 18/02/2022.

Área de concentração: Manejo Florestal.

1. Mapeamento florestal – Rondônia. 2. Fotogrametria aérea.
3. Biomassa florestal. 4. Equações. 5. Sensoriamento remoto. 6. Teses.
I. Dalla Corte, Ana Paula. II. Sanquetta, Carlos Roberto. III. Bastos, Alexis de Sousa. IV. Universidade Federal do Paraná, Setor de Ciências Agrárias. V. Título

CDD – 634.9

CDU – 634.0.58(811.1)

Bibliotecária: Berenice Rodrigues Ferreira – CRB 9/1160

TERMO DE APROVAÇÃO

Os membros da Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação ENGENHARIA FLORESTAL da Universidade Federal do Paraná foram convocados para realizar a arguição da tese de Doutorado de **MARKS MELO MOURA** intitulada: **MODELAGEM ESPAÇO-TEMPORAL DA BIOMASSA EM ÁREA DE RESTAURAÇÃO FLORESTAL A PARTIR DE SENSORES ORBITAIS E AÉREOS**, sob orientação da Profa. Dra. ANA PAULA DALLA CORTE, que após terem inquirido o aluno e realizada a avaliação do trabalho, são de parecer pela sua APROVAÇÃO no rito de defesa.

A outorga do título de doutor está sujeita à homologação pelo colegiado, ao atendimento de todas as indicações e correções solicitadas pela banca e ao pleno atendimento das demandas regimentais do Programa de Pós-Graduação.

CURITIBA, 18 de Fevereiro de 2022.

Assinatura Eletrônica

23/02/2022 13:35:39.0

ANA PAULA DALLA CORTE

Presidente da Banca Examinadora

Assinatura Eletrônica

24/02/2022 13:27:58.0

RODRIGO DE CAMPOS MACEDO

Avaliador Externo (UNIVERSIDADE FEDERAL DO PARANÁ -UFPR)

Assinatura Eletrônica

23/02/2022 16:45:07.0

FABIANA BARBOSA GOMES

Avaliador Externo (CENTRO DE ESTUDOS DA CULTURA E MEIO
AMBIENTE DA AMAZÔNIA)

Assinatura Eletrônica

24/02/2022 08:32:21.0

VAGNER ALEX PESCK

Avaliador Externo (UNIVERSIDADE ESTADUAL DO CENTRO-OESTE)

Assinatura Eletrônica

23/02/2022 19:41:24.0

KARLA DA SILVA ROCHA

Avaliador Externo (UNIVERSIDADE FEDERAL DO ACRE)

AGRADECIMENTOS

Ao meu comitê orientador, composto pelos professores Ana Paula Dalla Corte, Carlos Roberto Sanquetta e Alexis de Sousa Bastos que acreditaram na minha capacidade para o desenvolvimento deste trabalho, sempre oferecendo apoio em diversos aspectos nestes quatro anos de jornada. Em especial à professora Ana Paula Dalla Corte, que me orientou e compartilhou seus conhecimentos durante todo o decorrer do período.

Ao Programa de Pós-Graduação em Engenharia Florestal da Universidade Federal do Paraná pela oportunidade de ingressar no programa e desenvolver esta pesquisa. Aos todos os professores do PPGEF e PPGCG que compartilharam seus conhecimentos, não só em sala de aula, mas se disponibilizando a auxiliar em meu processo de aprendizado de forma geral.

Ao Centro de Estudos Rioterra pelo apoio logístico para aquisição dos dados em especial a Alexandre Queiroz, Fabiana Barbosa Gomes e Luiz Felipe Ulchôa Almeida pelos apoios em campo e companheirismo.

Aos colegas de Pós-Graduação, em especial a todos do BIOFIX, pela amizade e troca de conhecimentos durante este período.

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

À minha família, em especial aos meus pais e irmã, pela compreensão das muitas ausências durante este período, e pelo apoio e incentivo para a conclusão desta etapa.

E a todos que de alguma forma contribuíram para este trabalho.

RESUMO

Plantios de restauração são caracterizadas por áreas que foram anteriormente desmatadas e passaram por processos antrópicos de plantio visando sua restauração. Em geral essas florestas são caracterizadas principalmente por espécies de rápido crescimento e são uma alternativa para redução das emissões líquidas de carbono, e desta forma atenuar as mudanças climáticas. Entretanto, esses ambientes florestais ainda são pouco estudados, neste âmbito, este trabalho visou ajustar modelos preditivos de biomassa em relação à altura e diâmetro das árvores obtidos por meio do inventário florestal quantitativo e utilizando sensores orbitais Sentinel-2A e Landsat-8 analisando temporalmente e quantitativamente os estoques de biomassa em áreas de plantios de restauração, assim como avaliar a sua distribuição espacial e identificar espécies existentes nas parcelas inventariadas utilizando rede neural convolucional no período de 2016 a 2020. Este estudo foi realizado em uma região da Floresta Amazônica localizada no estado de Rondônia, Brasil, para o inventário florestal foi necessária a medição de todas as árvores com circunferência à altura do peito acima de 15 cm em parcelas com 200 m², após as medições foi selecionada uma árvore da parcela que representasse a árvore média em relação ao diâmetro à 1,30m de altura, sendo a mesma derrubada visando o cálculo de sua biomassa acima do solo (AGB). As equações ajustadas apresentaram R^2_{aj} variando de 0,49 a 0,57, raiz quadrada do erro médio (RMSE) de 247 a 296 kg e Erro padrão da estimativa (S_{yx}) de 49 a 53 kg. Em 2016 as parcelas continham em média 41,47 t.ha⁻¹ de AGB e 2020 contabilizou-se 81,66 t.ha⁻¹. Neste sentido, observamos um incremento total em AGB de 96,92% entre 2016 e 2020. O modelo ajustado que possuía a melhor performance estatística foi escolhido para especializar a AGB nos plantios de restauração utilizando a plataforma online *Google Earth Engine* (GEE). De forma geral, a AGB e os índices de vegetação apresentaram valores de correlação baixos, e os modelos ajustados apresentaram R^2_{aj} variando de 0,489 a 0,772. A espacialização da AGB demonstrou que em 2016 a área de estudo possuía 237.483.130 t de AGB, enquanto em 2020 o estoque foi 375.761.230 t, ou seja, um acréscimo de 138.278.100 t (+63,2% em relação ao ano do início dos plantios). Com finalidade de identificação de seis espécies florestais as redes neurais convolucionais (CNNs) foram treinadas utilizando o pacote *Keras-Tensorflow* com o modelo *faster_rcnn_inception_v2_pets*. Os resultados demonstraram que a redução do *threshold* diminui a exatidão na identificação, assim como a sobreposição dos polígonos de identificação das espécies, no entanto, em comparação com os dados coletados em campo, observa-se que há uma alta correlação entre as árvores identificadas pela CNN e às observadas nas parcelas. As métricas estatísticas utilizadas para validar as classificações evidenciaram que a CNN é capaz de identificar as espécies com acurácia acima de 90%. A partir dos resultados obtidos foi possível estimar e avaliar a dinâmica temporal da biomassa com utilização de sensores orbitais, a distribuição espacial em escala regional e utilização de imagens UAV como subsídio para aquisição de dados de árvores individuais em plantios de restauração.

Palavras-chave: Bioma amazônico. Drone. Equações alométricas. Reflorestamento. Rede Neural Convolucional.

ABSTRACT

Restoration plantings are characterized by areas that were previously deforested and have undergone anthropic planting processes aimed at their restoration. In general, these forests are characterized mainly by fast-growing species and are an alternative for reducing net carbon emissions, and thus mitigate climate change. However, these forest environments are still poorly studied, in this context, this work aimed to adjust predictive models of biomass in relation to height and diameter of trees obtained through quantitative forest inventory and using Sentinel-2A and Landsat-8 orbital sensors analyzing temporally and quantitatively the biomass stocks in areas of restoration plantations, as well as to evaluate their spatial distribution and identify existing species in the inventoried plots using convolutional neural network in the period from 2016 to 2020. This study was conducted in a region of the Amazon rainforest located in the state of Rondônia, Brazil, for the forest inventory was necessary the measurement of all trees with circumference at breast height above 15 cm in plots with 200 m², after the measurements was selected a tree of the plot that represented the average tree in relation to the diameter at 1.30 m height, and it was cut down aiming to calculate its above ground biomass (AGB). The adjusted equations showed R²aj. ranging from 0.49 to 0.57, square root of the mean error (RMSE) from 247 to 296 kg and Standard Error of the estimate (Syx) from 49 to 53 kg. In 2016 the plots contained an average of 41.47 t.ha⁻¹ of AGB and 2020 accounted for 81.66 t.ha⁻¹. In this sense, we observed a total increment in AGB of 96.92% between 2016 and 2020. The fitted model that had the best statistical performance was chosen to specialize AGB in restoration plantings using the Google Earth Engine (GEE) online platform. Overall, AGB and vegetation indices showed low correlation values, and the fitted models showed R²aj. ranging from 0.489 to 0.772. The spatialization of AGB showed that in 2016 the study area had 237.483.130 t of AGB, while in 2020 the stock was 375.761.230 t, that is, an increase of 138,278,100 t (+63.2% compared to the year of the beginning of plantations). In order to identify six forest species, convolutional neural networks (CNNs) were trained using the *Keras-Tensorflow* package with the *faster_rcnn_inception_v2_pets* model. The results showed that threshold reduction decreases identification accuracy, as does the overlapping of species identification polygons. However, in comparison with field data, there is a high correlation between trees identified by the CNN and those observed in the plots. The statistical metrics used to validate the classifications showed that the CNN is able to identify species with accuracy above 90%. From the results obtained it was possible to estimate and evaluate the temporal dynamics of biomass using orbital sensors, the spatial distribution on a regional scale and the use of UAV images as a subsidy for the acquisition of data from individual trees in restoration plantations.

Keywords: Allometric equations. Amazon biome. Drone. Convolutional Neural Network. Reforestation.

LISTA DE FIGURAS

FIGURA 1 – LOCALIZAÇÃO DA ÁREA DE ESTUDO	19
FIGURA 2 – ANÁLISE TEMPORAL DO DESMATAMENTO EM RONDÔNIA EM COMPARAÇÃO À AMAZÔNIA LEGAL.....	25
FIGURA 3 – DISTRIBUIÇÕES DIAMÉTRICAS DAS ÁRVORES EM 2016 E 2020.	46
FIGURA 4 – COMPARAÇÃO DOS CINCO MELHORES MODELOS EM RELAÇÃO AOS DADOS OBSERVADOS E AJUSTADOS	48
FIGURA 5 – DISTRIBUIÇÃO GRÁFICA DOS RESÍDUOS PADRONIZADOS DE BIOMASSA TOTAL PARA OS CINCO MELHORES MODELOS AJUSTADOS, O EIXO Y INDICA OS RESÍDUOS PADRONIZADOS, ENQUANTO O X INDICA O TOTAL DE OBSERVAÇÕES.....	49
FIGURA 6 – DISTRIBUIÇÃO DA BIOMASSA EM RELAÇÃO AO INTERVALO DE CLASSE DOS DIÂMETROS (A) E ALTURAS (B).....	50
FIGURA 7 – ESTOQUE DE BIOMASSA DAS PARCELAS INVENTARIADAS NOS ANOS DE 2016 A 2020.....	51
FIGURA 8 – ESTOQUE DE BIOMASSA ACIMA DO SOLO TOTAL DAS PARCELAS INVENTARIADAS NOS ANOS 2016 A 2020	52
FIGURA 9 – CORRELOGRAMA ENTRE AS VARIÁVEIS INDEPENDENTES E A VARIÁVEL DEPENDENTE (BIOMASSA ACIMA DO SOLO), OS VALORES AUSENTES DEMONSTRAM A FALTA DE SIGNIFICÂNCIA À 95%. A – SENTINEL-2A E B – LANDSAT-8	72
FIGURA 10 – SELEÇÃO DE VARIÁVEIS UTILIZANDO VALOR DE IMPORTÂNCIA POR MEIO DA TÉCNICA DE <i>MACHINE LEARNING</i> , A – SENTINEL- 2A E B – LANDSAT-8	73
FIGURA 11 – DISTRIBUIÇÃO ESPACIAL DA BIOMASSA DOS ANOS 2016 (A) E 2020 (B)	76
FIGURA 12 – DIFERENÇA ENTRE AS DISTRIBUIÇÕES ESPACIAIS OBTIDAS EM 2016 E 2020.....	77
FIGURA 13 – REPRESENTAÇÃO DA SELEÇÃO DE AMOSTRAS EM UM INDIVÍDUO. O POLÍGONO VERMELHO REPRESENTA A COPA DA ÁRVORE (<i>Handroanthus</i> spp.) E OS RETÂNGULOS AMARELOS REPRESENTAM AS SUBAMOSTRAS OBTIDAS PARA ESTA ESPÉCIE	91

FIGURA 14 – REPRESENTAÇÃO DAS TRANSFORMAÇÕES REALIZADAS INTERNAMENTE NA CNN PARA A ESPÉCIE <i>Cecropia juranyiana</i> C.MART (URTICACEAE).....	92
FIGURA 15 – APLICAÇÃO DO MODELO INCLUINDO AS 6 ESPÉCIES NO TREINAMENTO, SENDO: A - <i>THRESHOLD</i> = 0.9, B - <i>THRESHOLD</i> = 0.8, C - <i>THRESHOLD</i> = 0.7, D - <i>THRESHOLD</i> = 0.6	97
FIGURA 16 – VARIAÇÃO DA PERDA EM RELAÇÃO ÀS ÉPOCAS E QUANTIDADE DE ESPÉCIES UTILIZADAS NO TREINAMENTO	98
FIGURA 17 – VARIAÇÃO DA PERDA DO MODELO AJUSTADO COM AS 6 ESPÉCIES	98
FIGURA 18 – LOCALIZAÇÃO DAS ÁRVORES NAS PARCELAS E UTILIZANDO O MODELO DE RECONHECIMENTO DAS ESPÉCIES	100

LISTA DE TABELAS

TABELA 1 – ESPÉCIES COLETADAS E A ESTATÍSTICA DESCRITIVA DOS DIÂMETROS E ALTURAS DAS ÁRVORES ABATIDAS PARA CÁLCULO DA BIOMASSA.....	21
TABELA 2 – QUANTIFICAÇÃO DO DESMATAMENTO NA AMAZÔNIA LEGAL NO PERÍODO DE 2004 A 2020	24
TABELA 3 – MODELOS MATEMÁTICOS UTILIZADAS NOS AJUSTES	43
TABELA 4 – ESPÉCIES COLETADAS E A ESTATÍSTICA DESCRITIVA DOS DIÂMETROS E ALTURAS DAS ÁRVORES ABATIDAS PARA CÁLCULO DA BIOMASSA.....	45
TABELA 5 – CINCO MELHORES EQUAÇÕES OBTIDAS NOS AJUSTES, SEGUNDO OS CRITÉRIOS ESTATÍSTICOS.....	47
TABELA 6 – ÍNDICES DE VEGETAÇÃO (IV) UTILIZADOS E SUAS RESPECTIVAS FÓRMULAS	66
TABELA 7 – COEFICIENTES UTILIZADOS PARA A TRANSFORMAÇÃO <i>TASSELED CAP</i> PARA OS SATÉLITES LANDSAT-8 E SENTINEL-2A.....	67
TABELA 8 – VARIÁVEIS SELECIONADAS NOS TRÊS MÉTODOS (STEPWISE, CORRELAÇÃO E VALOR DE IMPORTÂNCIA), PARA OS DADOS OBTIDOS DOS SATÉLITES SENTINEL-2A E LANDSAT-8.....	74
TABELA 9 – CINCO MELHORES MODELOS UTILIZANDO AS VARIÁVEIS INDEPENDENTES OBTIDAS POR MEIO DO SATÉLITE SENTINEL-2A E LANDSAT-8.....	75
TABELA 10 - CARACTERÍSTICAS DAS IMAGENS OBTIDAS DO UAV <i>DJI PHANTOM 4 PRO</i>	89
TABELA 11 – ESPÉCIES FLORESTAIS UTILIZADAS E QUANTIDADE DE AMOSTRAS PARA O TREINAMENTO DAS REDES CONVOLUCIONAIS.....	93
TABELA 12 – ÍNDICES ESTATÍSTICOS UTILIZADOS PARA VERIFICAÇÃO DA CLASSIFICAÇÃO	95
TABELA 13 – MATRIZ DE CONFUSÃO COM INSERÇÃO DAS 6 ESPÉCIES NA REDE NEURAL CONVOLUCIONAL COM THRESHOLD = 0.7	101

TABELA 14 – ESTATÍSTICAS OBTIDAS NO PROCESSO DE CLASSIFICAÇÃO DO CONJUNTO DE DADOS DO TREINAMENTO	102
--	-----

LISTA DE SIGLAS

AGB	- Biomassa acima do solo
APP	- Áreas de Proteção Permanente
CAP	- Circunferência à altura do peito
CAR	- Cadastro Ambiental Rural
DAP	- Diâmetro à altura do peito
FBE	- Fator de expansão da biomassa
GEE	- <i>Google Earth Engine</i>
Ht	- Altura total
IICT	- Instituição de Inovação, Ciência e Tecnologia
INCRA	- Instituto de Colonização e Reforma Agrária
IV	- Índice de vegetação
MMA	- Ministério do Meio Ambiente
OSCIP	- Organização da Sociedade Civil de Interesse Público
PRA	- Programa de Regularização Ambiental
RIOTERRA	- Centro de Estudos da Cultura e do Meio Ambiente da Amazônia
RL	- Reserva Legal
RMSE	- Raiz quadrada do erro médio
SQE	- Soma de quadrado dos erros
S_{yx}	- Erro padrão da estimativa
UAV	- <i>Unmanned Aerial Vehicle</i>
UC	- Unidades de Conservação
VANT	- Veículos Aéreos não Tripulados
ZSEE	- Zoneamento Socioeconômico e Ecológico de Rondônia

SUMÁRIO

ASPECTOS GERAIS	14
1 INTRODUÇÃO GERAL.....	14
2 ESTRUTURA DA TESE.....	18
3 MATERIAL E MÉTODOS	19
3.1 ÁREA DE ESTUDO.....	19
3.2 AQUISIÇÃO DA BIOMASSA FLORESTAL	20
4 REVISÃO BIBLIOGRÁFICA.....	23
4.1 HISTÓRICO DO DESMATAMENTO EM RONDÔNIA	23
4.2 PLANTIOS DE RESTAURAÇÃO FLORESTAL.....	25
4.3 SENSORIAMENTO REMOTO APLICADO AO MONITORAMENTO DOS PLANTIOS DE RESTAURAÇÃO	27
4.4 ESTOQUE DE CARBONO DAS FLORESTAS RESTAURADAS	28
REFERÊNCIAS.....	30
CAPÍTULO I: DINÂMICA DA BIOMASSA EM PLANTIOS DE RESTAURAÇÃO FLORESTAL NO PERÍODO DE 2016 A 2020.....	38
1 INTRODUÇÃO	40
2 MATERIAL E MÉTODOS	43
2.1 AJUSTE DAS EQUAÇÕES	43
3 RESULTADOS.....	45
3.1 EQUAÇÕES AJUSTADAS	46
3.2 BIOMASSA ESTIMADA	49
3.3 ESTOQUE DE BIOMASSA ACIMA DO SOLO NAS PARCELAS	50
4 DISCUSSÃO	53
5 CONCLUSÕES	55
REFERÊNCIAS.....	56
CAPÍTULO II: DINÂMICA DA DISTRIBUIÇÃO ESPACIAL DE BIOMASSA ACIMA DO SOLO EM PLANTIOS DE RESTAURAÇÃO EM RONDÔNIA NA AMAZÔNIA OCIDENTAL	61
1 INTRODUÇÃO.....	63
2 MATERIAL E MÉTODOS	66
2.1 OBTENÇÃO DOS DADOS ORBITAIS	66

2.2 ÍNDICES DE VEGETAÇÃO (IV).....	66
2.3 TRANSFORMAÇÃO <i>TASSELED CAP</i>	67
2.4 TRANSFORMAÇÃO RGB - HSV	67
2.5 TRANSFORMAÇÃO UTILIZANDO COMPONENTES PRINCIPAIS	68
2.6 SELEÇÃO DAS VARIÁVEIS	68
2.7 AJUSTE DE MODELOS.....	69
2.8 ESPACIALIZAÇÃO DA AGB	70
3 RESULTADOS.....	71
3.1 SELEÇÃO DAS VARIÁVEIS	71
3.2 AJUSTE DAS EQUAÇÕES	74
3.3 DISTRIBUIÇÃO ESPACIAL DA BIOMASSA NAS ÁREAS EM PROCESSO DE RESTAURAÇÃO	75
4 DISCUSSÃO	78
5 CONCLUSÃO	80
REFERÊNCIAS.....	81
CAPÍTULO III: DIRETRIZES PARA RESTAURAÇÃO DA FLORESTA AMAZÔNICA: DETECÇÃO AUTOMÁTICA DE ESPÉCIES A PARTIR DE IMAGENS UAV	
1 INTRODUÇÃO	85
2 MATERIAL E MÉTODOS	87
2.1 AQUISIÇÃO E PRÉ-PROCESSAMENTO DAS IMAGENS	89
2.2 TREINAMENTO DAS REDES NEURAS CONVOLUCIONAIS	90
2.3 VALIDAÇÃO DA CLASSIFICAÇÃO	94
3 RESULTADOS.....	96
4 DISCUSSÃO	103
6 CONCLUSÕES	106
REFERÊNCIAS.....	107
REFERÊNCIAS GERAIS.....	113

ASPECTOS GERAIS

1 INTRODUÇÃO GERAL

A redução do desmatamento ilegal e o incremento da regeneração florestal são premissas constantes no Acordo de Paris, assinado em 2015, do qual almeja que as florestas contribuam para redução líquida das emissões de carbono. A maior floresta tropical do mundo está inserida no bioma Amazônico, que armazena aproximadamente 10% do carbono florestal global. Neste sentido, o Brasil se comprometeu a recuperar e reflorestar 12 milhões de hectares de florestas até 2030 para contribuir com as reduções das emissões, parte desses objetivos podem ser alcançados pela regeneração de florestas secundárias em terras anteriormente desmatadas ou degradadas (BONGERS; CHAZDON; POORTER; PEÑA-CLAROS, 2015; MMA, 2016).

Ao analisarmos o armazenamento de carbono, os estudos se concentraram principalmente em florestas primárias e o conhecimento sobre as florestas secundárias é muitas vezes negligenciado, ainda que haja evidências de seu potencial em armazenar carbono (CHAZDON et al., 2016; POORTER et al., 2016 ; MATOS et al., 2019, 2020; BRUUN et al., 2021; NGO BIENG et al., 2021; OBERLEITNER et al., 2021; SANTOS et al., 2021; ZHU et al., 2021). Wang et al. (2017), Brancalion et al. (2019), Spyroglou et al. (2021), Theofanous et al. (2021) e argumentam que a recuperação da biomassa acima do solo (AGB) em plantios de restauração florestal pode ser mais rápido que em outras fitofisionomias florestais, pois durante a sucessão secundária, a estrutura e a complexidade da comunidade florestal aumentam rapidamente, com consequências profundas para a quantidade de luz, nutrientes e sua heterogeneidade espacial dentro das florestas.

Os autores Almeida et al. (2016) afirmam que os plantios de restauração que também estão inseridos nas florestas secundárias compreendem cerca de 21% das florestas anteriormente desmatadas na Amazônia brasileira, e que essas florestas são um componente importante na gestão dessas terras, com o seu desenvolvimento ocorre, conseqüentemente, o restabelecimento do funcionamento do solo, garantindo a incorporação de matéria orgânica no solo, área de refúgio de fauna e conexão com áreas de florestas primárias, entretanto, o desenvolvimento e conseqüente acúmulo de carbono em florestas secundárias está intimamente relacionado às condições

climáticas, com períodos de seca mais longos e intensos e menor precipitação anual, portanto, o crescimento deste tipo florestal é mais lento quando há menos coberturas de florestas em estágio clímax próximos para atuar como fonte de sementes (POORTER et al., 2016; ASSIS et al., 2020; SILVA JUNIOR et al., 2020; SMITH et al., 2020)

Neste âmbito, a estimativa da biomassa florestal é decisiva para a compreensão do papel das fitofisionomias florestais no ciclo global do carbono. O reservatório de carbono florestal total (incluindo carbono subterrâneo) equivale a aproximadamente 85% dos estoques terrestres e 75% da produção primária bruta terrestre (PAN et al., 2013; DUNCANSON et al., 2020). A AGB é estimada principalmente por medições de campo tradicionais ou métodos de sensoriamento remoto, no entanto, para um pequeno povoamento florestal, o cálculo de AGB é mais preciso quando baseado em medições de campo reais. No entanto, o uso de medições de campo para calcular o AGB florestal não é viável em escala regional, pois despende de grande recurso financeiro além de ser moroso.

O método tradicional para estimar o AGB da floresta em escala de árvores individuais contribuindo para o entendimento das escalas maiores envolve três etapas (VAN BREUGEL et al., 2011): (1) os modelos são ajustados para prever a AGB de árvores individuais em parcelas de inventário florestal; (2) AGB no nível da parcela é estimado somando-se o AGB de todas as árvores; e (3) AGB da floresta em escalas espaciais maiores é estimado pela média do AGB de todas as parcelas. Comumente, a biomassa de árvores individuais pode ser obtida derrubando-se árvores ou prevendo o AGB usando modelos previamente ajustados e testados. O primeiro método é caro, demorado e destrutivo e não pode ser usado em grande escala. No segundo método, os modelos de AGB são estabelecidos com base nas relações alométricas entre os AGB das árvores e outras variáveis, como diâmetro à 1,30 m de altura (DAP) e altura total (ht) (CHAVE et al., 2014; ABD LATIF, 2017; MOHD ZAKI; VINH et al., 2019; KENZO et al., 2020; VIRGULINO-JÚNIOR et al., 2020).

O inventário florestal quantitativo é uma ferramenta essencial para aquisição de dados em ambientes florestais em uma determinada área de interesse, a partir desse é possível avaliar a situação atual e obter suporte para análise e planejamento, constituindo a base para o manejo florestal, e fornece também informações sobre o tamanho e a forma da área, bem como informações qualitativas e/ou quantitativas do estoque existente. As informações podem ser obtidas a partir de medidas diretamente

nas árvores ou utilizando sensores remotos (fotografias aéreas, imagens de satélite, LiDAR, etc.). Neste sentido, a AGB não pode ser mensurada diretamente por sensores, sejam eles aéreos ou orbitais, necessitando assim de informações coletadas em campo utilizando métodos tradicionais de inventário florestal (SANQUETTA et al., 2014; BEYENE et al., 2020; CORTE et al., 2020).

O monitoramento e a aquisição de dados da Biomassa Florestal acima do solo são tradicionalmente dependentes de Inventário Florestal geralmente implantados por meio do estabelecimento e medições sistemáticas de parcelas florestais. A implementação de inventários contínuos em determinada área, no entanto, é desafiadora em muitas regiões florestais, especialmente em países em desenvolvimento que muitas vezes carecem de capacidade técnica, financeira e institucional (ABREU et al., 2020; LEÃO et al., 2021; LIMA et al., 2020; ZWIENER et al., 2021). Como consequência, relatar a mudança da AGB ao longo do tempo nessas regiões é frequentemente restrita por possuir apenas coleta de dados de uma única ocasião. Mesmo onde esses dados de inventários contínuos são disponíveis, eles têm uma cobertura espacial limitada que é insuficiente para criar previsões espaciais contínuas de biomassa florestal, no entanto, esses problemas podem ser resolvidos combinando o inventário florestal com dados de sensoriamento remoto (HU et al., 2020; NGUYEN et al., 2020; SUN et al., 2021).

Na modelagem de biomassa baseada em sensoriamento remoto, a coleta de amostras em campo, a seleção de variáveis adequadas e a seleção de algoritmos de modelagem são etapas cruciais em estimativas futuras (LU et al., 2014). Estudos anteriores examinaram a importância de selecionar variáveis adequadas (por exemplo, bandas espectrais, índices de vegetação, medidas de textura e características de pixel) para melhorar a estimativa de AGB (STEININGER, 2010; GOETZ; DUBAYAH, 2011; MOTLAGH et al., 2018; KARYATI et al., 2019; MUKURALINDA et al., 2021). Pesquisas indicaram que a combinação de respostas espectrais e variáveis dendrométricas podem melhorar a estimativa de AGB em comparação com o uso de um único tipo de imagem, especialmente nas regiões tropicais e subtropicais com estrutura de floresta complexa e composição de espécies de árvores (ZHAO et al., 2016; SULLIVAN et al., 2018; LI et al., 2020).

Aliado às estimativas da AGB está o monitoramento desta variável ao longo do tempo, o uso e disponibilidade de dados de sensoriamento remoto fornece oportunidades para mensurar e avaliar a dinâmica do ecossistema. Essa perspectiva

é ainda mais impulsionada à medida que imagens orbitais são disponibilizadas com frequência e sem custos, assim como o processamento de dados está se tornando mais acessível pela implementação de softwares específicos e plataformas online. Acompanhando a perspectiva estão também as demandas crescentes por produtos de dinâmica de ecossistema de alta resolução para enfrentar os desafios ambientais existentes e questões ecológicas emergentes (ALENCAR et al., 2020; JAAFAR; MOURAD, 2021; JIANG et al., 2021).

Estratégias de monitoramento da dinâmica da biomassa estão aliadas a tecnologias que a promovam por meio de técnicas que sejam condizentes à área estudada, neste sentido técnicas veem sendo empregadas para aquisição de dados por meio de sensores aéreos que promovem o reconhecimento da área em curso espaço de tempo e baixo custo. Dentre elas, os Veículos Aéreos não Tripulados (VANT) ou *Unmanned Aerial Vehicle* (UAV) são comumente utilizados em ambientes florestais, suas imagens têm sido empregadas como subsídio a inventários florestais e monitoramento de ambientes (CORTE et al., 2020; CUNHA NETO et al., 2021; MIGUEL et al., 2021).

Diante do exposto, estudos tem apresentado o uso de sensores remotos e UAVs em aplicações florestais, que envolvem tanto classificações florestais, como obtenção de variáveis dendrométricas, de diversidade, monitoramentos, entre outros. Contudo, as florestas secundárias veem sendo negligenciadas ao tratar de estoque de biomassa, dentro desse contexto, nesse estudo foi avaliada a dinâmica temporal da biomassa com utilização de sensores orbitais, a distribuição espacial em escala regional e utilização de imagens UAV como subsídio para aquisição de dados de árvores individuais em florestas secundárias no bioma Amazônico.

2 ESTRUTURA DA TESE

O trabalho foi organizado em três capítulos, sendo que nesses são abordados:

Aspectos gerais: introdução geral, descrição da área de estudo, do levantamento de dados em campo e revisão bibliográfica;

Capítulo 1: desenvolver modelos preditivos de biomassa em relação à altura e diâmetro das árvores, analisando temporalmente e quantitativamente os estoques de biomassa acima do solo visando a quantificação de biomassa aérea nesses ecossistemas e discutir a implicação da abundância de indivíduos nas estimativas;

Capítulo 2: distribuir espacialmente e quantificar a biomassa acima do solo em plantios de restauração florestal de 2016 a 2020, utilizando dados orbitais oriundos dos satélites Sentinel-2A e Landsat 8 e dados coletados em campo;

Capítulo 3: testar o desempenho de imagens de alta resolução obtidas por UAV para a identificação de espécies florestais em áreas de plantios de restauração florestal na Amazônia por meio da aplicação de algoritmo de aprendizado de máquinas;


Conclusão geral e recomendações para estudos futuros.

3 MATERIAL E MÉTODOS

3.1 ÁREA DE ESTUDO

Este estudo foi realizado em uma região da Floresta Amazônica localizada no estado de Rondônia, Brasil, entre os meridianos 62°44'05" e 63°16'54" e paralelos 9°00'00" e 9°30'00" de latitude sul, com área aproximada de 39.326 km² como demonstrado na Figura 1. As áreas analisadas são referentes aos plantios de restauração florestal, contendo 20 parcelas retangulares (20 x 10 m) que são continuamente monitoradas com intuito de avaliar o incremento das árvores, regeneração natural de novas espécies e monitoramento do estoque de carbono, a implementação dessas parcelas foi realizada entre dezembro de 2010 e Janeiro de 2011, no entanto, o monitoramento dessas iniciou-se em 2016.

Nestas parcelas são realizadas medições anuais que contempla uma caracterização das árvores e sua geolocalização. Estas informações foram utilizadas como subsídio para avaliação dos resultados oriundos dos processos automatizados referentes aos processamentos das imagens UAV.



Fonte: o autor (2021).

3.2 AQUISIÇÃO DA BIOMASSA FLORESTAL

Todas as árvores localizadas nas parcelas com CAP (Circunferência à 1,30 m de altura) acima de 15 cm foram identificadas, medidos seus respectivos CAP e alturas totais (ht). Das espécies mensuradas foram coletados alguns galhos e quando possível as estruturas reprodutivas e posteriormente confeccionadas exsiccatas, das quais foram herborizadas e registradas na Universidade Federal de Rondônia (UNIR), com o apoio do Museu Paraense Emílio Goeldi de botânica.

Após o inventário florestal, foram listadas as espécies mais importantes em termos fitossociológicos para realizar a determinação da biomassa pelo método destrutivo. Em contrapartida, foi utilizada a distribuição diamétrica para a seleção de indivíduos a serem abatidos e medidos. Os indivíduos amostrados e as estatísticas descritivas das variáveis coletas são demonstrados na Tabela 1.

Para determinar a biomassa acima do solo, 20 árvores foram amostradas e cortadas, posteriormente, foram divididas em fuste, galhos, folhagem e miscelânea (frutos, flores, brotos, entre outros). As frações recolhidas das árvores foram pesadas separadamente utilizando uma balança digital com precisão de 100 g, obtendo o peso fresco de cada compartimento. Foram retiradas de cada fração das amostras frescas aproximadamente 500 g de toda a biomassa e acondicionadas em embalagens únicas para serem levadas ao laboratório. Essas amostras foram secas em estufa ao ar de circulação forçada a 65 °C até peso constante. Então, a conversão em biomassa seca de cada compartimento foi realizada, de acordo com a Eq.1.

$$bs_x = bf_x \frac{(100 - u_x)}{100} \quad (1)$$

Onde:

bs_x = biomassa seca do compartimento x da árvore (kg);

bf_x = biomassa fresca do compartimento x da árvore (kg); e

u_x = teor de umidade de amostras do compartimento x da árvore (%).

TABELA 1 – ESPÉCIES COLETADAS E A ESTATÍSTICA DESCRITIVA DOS DIÂMETROS E ALTURAS DAS ÁRVORES ABATIDAS PARA CÁLCULO DA BIOMASSA

Epíteto	Nome vulgar	DAP (cm)	ht (m)
<i>Anacardium</i> sp.	Cajueiro	9,87	8,90
<i>Handroanthus serratifolius</i> L.	Ipê-amarelo	10,83	7,02
<i>Bixa orellana</i> L.	Urucum	7,17	7,00
<i>Cordia alliodora</i> (Ruiz & Pav.) Cham.	Freijó	12,19	10,97
<i>Hevea brasiliensis</i> L.	Castanheira	8,12	9,35
<i>Stryphnodendron</i> sp.	Barbatimão	10,50	8,80
<i>Hymenolobium pulcherrimum</i> Ducke	Angelim	6,05	6,15
<i>Inga cylindrica</i> (Vell.) Mart.	Ingá	10,98	8,60
<i>Schizolobium amazonicum</i> Huber ex Ducke.	Paricá	12,73	10,80
<i>Parkia multijuga</i> Benth.	Faveira	11,94	7,70
<i>Hymenaea courbaril</i> L.	Jatobá	13,05	9,80
<i>Enterolobium schomburgkii</i> (Benth.) Benth.	Orelha-de-macaco	5,73	6,30
<i>Apuleia leiocarpa</i> (Vogel) J. F. Macbr.	Garapeira	9,90	9,50
<i>Dipteryx odorata</i> (Aubl.) Willd.	Cumaru	7,48	6,55
<i>Enterolobium schomburgkii</i> (Benth.) Benth.	Orelha-de-macaco	9,24	9,90
<i>Acacia mangium</i> Wild.	Acácia	13,06	9,20
<i>Vismia guianensis</i> (Aubl.) Choisy	Lacre-branco	5,41	7,00
<i>Ceiba pentandra</i> (L.) Gaertn.	Sumaúma	10,66	6,25
<i>Bellucia grossularioides</i> (L.) Triana	Araçá-De-Anta	8,92	6,40
<i>Cedrela odorata</i> L.	Cedro	7,51	6,65
Estatísticas descritivas		DAP (cm)	ht (m)
Média		9,56	8,14
Erro padrão		0,54	0,36
Mediana		9,88	8,15
Desvio padrão		2,44	1,61
Variância da amostra		6,00	2,59
Mínimo		5,41	6,15
Máximo		13,06	10,97

FONTE: o autor (2021).

Para obter a biomassa total de cada árvore foi realizado o somatório das biomassas de cada compartimento. As massas específicas básicas das amostras de madeira (ρ_i) foram determinadas pela relação entre a matéria seca do fuste de cada árvore e seu volume, do qual foi determinado pelo método de *Hohenadl*, com seções relativas de 10%. Posteriormente foi calculada o fator de expansão da biomassa de acordo com as Eq. 2 e 3.

$$FEB_x = \frac{ba}{bf} \quad (2)$$

$$R_x = \frac{br}{ba} \quad (3)$$

Onde:

FEB_x = fator de expansão da biomassa;

R_x = razão de raízes ($kg.kg^{-1}$);

ba = biomassa seca acima do solo da árvore (kg);

bf = biomassa seca do fuste da árvore (kg); e

br = biomassa seca das raízes da árvore (kg).

Em seguida, as amostras de biomassa seca foram fracionadas e moídas com moinho *Tecnal Wiley*, modelo TE-648. A análise da quantidade de carbono em cada compartimento foi realizada no analisador LECO, modelo C-144, que utiliza o método de combustão a seco. Os teores de carbono obtidos foram multiplicados pela respectiva biomassa de cada parte da árvore, gerando os respectivos estoques de carbono (Eq. 4 e 5).

$$C_x = bs_t \times tc \quad (4)$$

$$C_t = \sum C_x \quad (5)$$

Onde:

C_x = estoque de carbono por compartimento em cada árvore (kg);

C_t = carbono total;

bs_t = biomassa seca total (kg); e

tc = teor de carbono (%).

4 REVISÃO BIBLIOGRÁFICA

4.1 HISTÓRICO DO DESMATAMENTO EM RONDÔNIA

A substituição da cobertura florestal nativa no estado de Rondônia iniciou-se na década de 1970, principalmente pela implantação de projetos de assentamentos coordenados pelo Instituto de Colonização e Reforma Agrária (INCRA), estes assentamentos favoreceram um fluxo migratório de pessoas oriundas de diversas regiões e estados brasileiros com intuito de adquirir terras para expansão da fronteira agropecuária, ocasionando uma expressiva alteração nas paisagens naturais do estado (BRANDÃO JUNIOR; SOUZA JUNIOR, 2006; TOURNEAU; BURSZTYN, 2010).

Um dos programas que mais se destacou foi o Programa Integrado de Desenvolvimento do Noroeste do Brasil (POLONOROESTE), implementado na década de 80 e financiado em parte pelo Banco Internacional para a Reconstrução e o Desenvolvimento ou Banco Mundial (BIRD). Este programa em especial foi o principal propulsor das desigualdades sociais influenciando diretamente a degradação florestal. Com intuito de mitigar os conflitos que o POLONOROESTE ocasionou às comunidades indígenas e comunidades rurais foi aprovado em 1992 o Plano Agropecuário e Florestal de Rondônia (PLANAFLORO), com objetivo de manejar sustentavelmente os recursos e impulsionar o crescimento econômico na região (DELAZERI, 2016).

Contudo, tal plano não foi suficiente para o progresso ambiental econômico e sustentável do estado, não conseguindo implementar seus objetivos iniciais. Esta adversidade foi imprescindível para a criação do Zoneamento Socioeconômico e Ecológico de Rondônia (ZSEE) em 2000. Este zoneamento dividiu o estado em 3 zonas: a) Zona 1: destinada ao uso agropecuário, agroflorestal e florestal, concentrando elevado grau de antropização e de ocupação humana, b) Zona 2: objetiva a conservação dos recursos naturais, passíveis de utilização através do manejo sustentável, c) Zona 3: formada por Unidades de Conservação (UC) e Terras Indígenas (RONDÔNIA, 2010; RIOTERRA, 2020a).

Apesar da promulgação do Zoneamento no estado, as áreas protegidas são acometidas frequentemente por explorações madeireiras ilegais, estas ações ocorrem principalmente nas Unidades de Conservação e em áreas que fazem fronteira com

terras Indígenas, descaracterizando o zoneamento do estado. Neste sentido, segundo PRODES (2021), Rondônia é o terceiro estado que mais desmata no Brasil, ficando atrás somente do Pará e Mato Grosso (Tabela 2).

TABELA 2 – QUANTIFICAÇÃO DO DESMATAMENTO NA AMAZÔNIA LEGAL NO PERÍODO DE 2004 A 2020

Ano	AC	AM	AP	MA	MT	PA	RO	RR	TO	AmL
Área (km²)										
2004	728	1.232	46	755	11.814	8.870	3.858	311	158	27.772
2005	592	775	33	922	7.145	5.899	3.244	133	271	19.014
2006	398	788	30	674	4.333	5.659	2.049	231	124	14.286
2007	184	610	39	631	2.678	5.526	1.611	309	63	11.651
2008	254	604	100	1.271	3.258	5.607	1.136	574	107	12.911
2009	167	405	70	828	1.049	4.281	482	121	61	7.464
2010	259	595	53	712	871	3.770	435	256	49	7.000
2011	280	502	66	396	1.120	3.008	865	141	40	6.418
2012	305	523	27	269	757	1.741	773	124	52	4.571
2013	221	583	23	403	1.139	2.346	932	170	74	5.891
2014	309	500	31	257	1.075	1.887	684	219	50	5.012
2015	264	712	25	209	1.601	2.153	1.030	156	57	6.207
2016	372	1.129	17	258	1.489	2.992	1.376	202	58	7.893
2017	257	1.001	24	265	1.561	2.433	1.243	132	31	6.947
2018	444	1.045	24	253	1.490	2.744	1.316	195	25	7.536
2019	682	1.434	32	237	1.702	4.172	1.257	590	23	10.129
2020	706	1.512	24	336	1.779	4.899	1.273	297	25	10.851
Total	6.422	13.950	664	8.676	44.861	67.987	23.564	4.161	1.268	171.553


Onde, AC: Acre, Am: Amazonas, AP: Amapá, MA: Maranhão, MT: Mato Grosso, PA: Pará, RO: Rondônia, RR: Roraima, TO: Tocantins e AmL: Amazônia Legal.

FONTE: PRODES (2021).

Especificamente no estado de Rondônia, a partir da vigência do ZSEE houve uma redução significativa dos desmatamentos ocorrido no estado (FIGURA 2), entretanto Pedlowski et al. (2005) e Piontekowski et al. (2014) observaram que algumas Unidades de Conservação (Floresta Nacional Bom Futuro, Floresta Nacional do Jamari e Reserva Extrativista de Ouro Preto) estavam sob constante pressão da extração ilegal de madeira, principalmente por problemas relacionados aos grandes fazendeiros, e posseiros que viviam dentro das Unidades ou em suas adjacências. Adicionalmente, dados publicados pelo Ministério do Meio Ambiente (MMA) demonstram que no período de 2012 a 2015, houve alta concentração do desmatamento na porção norte do estado de Rondônia e sul do estado do Amazonas região onde se localizam as rodovias federais BR-230 e BR-364, contudo, não foram

apresentadas informações precisas acerca da causa do desmatamento, sendo atribuído apenas a atividades antrópicas de modificação do uso do solo (BRASIL, 2018).

FIGURA 2 – ANÁLISE TEMPORAL DO DESMATAMENTO EM RONDÔNIA EM COMPARAÇÃO À AMAZÔNIA LEGAL



FONTE: PRODES (2021).

4.2 PLANTIOS DE RESTAURAÇÃO FLORESTAL

Com a degradação dos ambientes florestais gerado pelo modelo atual de exploração e desenvolvimento da região Amazônica, tornam-se necessárias ações para a restauração florestal e consequentemente o desenvolvimento de pesquisas nesse campo de estudo. No Brasil, a principal técnica utilizada para essa restauração é o plantio de mudas de espécies florestais nativas (LAMB; ERSKINE; PARROTTA, 2005; BRANCALION; GANDOLFI; RODRIGUES, 2015; COSTA et al., 2019; CRUZ et al., 2020). Porém, nos últimos 30 anos, a restauração florestal avançou principalmente por considerar os processos ecológicos envolvidos na dinâmica florestal, através da inserção de espécies de diferentes grupos funcionais e de alta diversidade, permitindo a auto sustentabilidade da área restaurada e reduzindo os custos e tempo de manejo (RODRIGUES et al., 2009).

Nesta perspectiva, regiões com histórico de uso e ocupação do solo marcados pela agricultura ou pecuária, com destaque para as regiões com grandes extensões de áreas mecanizadas, frequentemente apresentarão regeneração natural nula ou muito reduzida, resultando no comprometimento da resiliência do ecossistema. Deste

modo, o plantio de espécies florestais nativas tem se mostrado eficaz nessas áreas, principalmente quando se firmam em modelos sucessionais, buscando reproduzir a classificação ecológica das espécies arbóreas segundo a dinâmica de classes agrupando-as em pioneiras, secundárias e climácicas (FREITAS et al., 2019; CAMARRETTA et al., 2020).

Inserido no conceito de restauração florestal, uma outra vertente é caracterizada pela transformação de uma floresta antropizada em uma área florestal de alta diversidade florística, determinada principalmente pela incorporação de espécies regionais. Neste âmbito, pesquisas com enfoque em florestas tropicais adotaram como essencial o controle da densidade de indivíduos plantados para cada uma das espécies introduzidas nos reflorestamentos, buscando reproduzir o que ocorria em formações naturais (BRANCALION; GANDOLFI; RODRIGUES, 2015; RIGUEIRA; SANTANA, 2015).

A restauração florestal adquiriu relevante importância em nível nacional com a reformulação do código florestal, neste sentido, a obrigatoriedade da regularização ambiental das propriedades, por meio do Programa de Regularização Ambiental (PRA), é fundamentada no processo de recomposição dos passivos ambientais das propriedades rurais. O PRA pode ser definido como um conjunto de ações ou iniciativas a serem desenvolvidas por proprietários ou posseiros rurais com o objetivo de adequar e promover a regularização ambiental (BRASIL, 2012). Esse programa é implementado a partir do cadastro ambiental rural (CAR), por meio deste, os proprietários poderão regularizar as áreas nativas de florestas inseridas em suas propriedades, designadas principalmente como áreas de Reserva Legal (RL) e Áreas de Proteção Permanente (APP).

Com advento e aplicabilidade das leis referentes às florestas em 1999 foi fundado o Centro de Estudos da Cultura e do Meio Ambiente da Amazônia (RIOTERRA) caracterizada como uma Organização da Sociedade Civil de Interesse Público (OSCIP) e Instituição de Inovação, Ciência e Tecnologia (IICT) com finalidade precípua de contribuir para o desenvolvimento da região amazônica, aliando conservação e sustentabilidade à melhoria da qualidade de vida das populações locais, desenvolvendo pesquisas e projetos, visando principalmente: populações tradicionais, povos indígenas, agricultores familiares, entidades governamentais e não-governamentais, contribuindo assim, para transformações sociais, ambientais e humanas no sudoeste da Amazônia brasileira. Neste sentido, a RIOTERRA em seus

21 anos de existência promoveu o plantio de 440 mil mudas, recuperou 2.150 ha e apoiou a conservação de 1.885.725 ha em Unidades de Conservação na Amazônia (RIOTERRA, 2020b).

4.3 SENSORIAMENTO REMOTO APLICADO AO MONITORAMENTO DOS PLANTIOS DE RESTAURAÇÃO

O monitoramento é parte fundamental para quantificar a eficácia dos plantios de restauração, visando orientar atividades futuras e evitar falhas nos plantios. Quando realizada em escala local é executada com monitoramento de campo, comumente utilizando parcelas, entretanto, quando esse tem grandes áreas o monitoramento em campo torna-se inviável, sendo empregado nesse caso, o sensoriamento remoto, pois, permite observações consistentes da vegetação ao longo do tempo e do espaço (RUIZ-JAÉN; AIDE, 2005; SASAKI; ISHII; MORIMOTO, 2018; CAMARRETTA et al., 2020).

Estudos veem sendo desenvolvidos visando a melhoria das técnicas baseadas no sensoriamento remoto a fim de avaliar aspectos da diversidade florestal, estrutura, funções e serviços do ecossistêmicos. A combinação dos dados obtidos por meio dessa técnica e dados de campo é um desafio, uma vez que a escala desses dados pode diferir substancialmente com a resolução espacial dos dados obtidos por sensores orbitais ou suborbitais (MURAOKA; KOIZUMI, 2009; TURNER, 2014; WU et al., 2020). As tecnologias envolvendo esses sensores progredem para produtos de detecção remota quantitativa de alta qualidade e de longo prazo, como o Índice de área foliar (em inglês, LAI), Fração da radiação fotossinteticamente ativa absorvida (FAPAR), Produtividade Primária Bruta (em inglês, GPP) e Uso e Cobertura da Terra, esses estão comumente sendo aprimorados para monitorizar a distribuição e variação da vegetação terrestre (XIAO et al., 2016; ZHU et al., 2016; VELOSO et al., 2020; WANG et al., 2020).

Nesta perspectiva, Bourgoïn et al. (2018) utilizou dados orbitais oriundo dos satélites Landsat-8, Alos-1 e Sentinel-1 para estimar a biomassa em ambientes florestais degradados na Amazônia e concluiu que os sensores utilizados na pesquisa oferecem uma oportunidade única de caracterizar a estrutura florestal em ambientes degradados ou restaurados utilizando apenas informações provenientes a partir do dossel. Estas análises fornecem perspectivas para o futuro dos sensores orbitais

como dados oriundos do GEDI e RADAR que irão fornecer conjuntos de dados sobre a dinâmica da estrutura florestal e biomassa florestal global. Alves et al. (2003), fizeram o monitoramento no estado de Rondônia de florestas degradadas e em estágio secundário de restauração entre os anos 1985 e 1995, utilizando imagens Landsat 5, os autores supracitados concluíram que o monitoramento de longo prazo de uma área, é facilitado com a implementação de técnicas de sensoriamento remoto.

A utilização dos sensores remotos para obtenção de dados florestais favorece também a simulação de padrões desses ambientes, pode-se citar dentre outros, a influência do desmatamento no microclima local e regional (MARÉCHAUX; CHAVE, 2017; ELIAS et al., 2020), incidência de incêndios em áreas desmatadas (SILVA JUNIOR et al., 2018; ARMENTERAS et al., 2019; PRESTES et al., 2020) e impactos sobre a fauna (ZIMBRES et al., 2018; MIRANDA; IMPERATRIZ-FONSECA; GIANNINI, 2019; TEIXEIRA-SANTOS et al., 2020).

4.4 ESTOQUE DE CARBONO DAS FLORESTAS RESTAURADAS

As florestas armazenam aproximadamente o dobro da quantidade de carbono presente na atmosfera, estima-se que 15% das emissões de CO₂ podem ser reduzidas através dos plantios e manejo florestal (SUBERI et al., 2018). A biomassa florestal consiste em um dos principais estoques de carbono terrestre, e são compartimentados em: biomassa acima e abaixo do solo, necromassa e carbono do solo (DEUS et al., 2018; MAAS et al., 2020). Estimativas desses compartimentos, atuais e futuros dependem de mudanças na densidade de árvores, idade e composição das espécies. A remoção do CO₂ atmosférico e seu armazenamento em diferentes compartimentos conduzem a mudanças que podem ter impactos nas alterações climáticas (DREBENSTEDT et al., 2020; KRAMER et al., 2020; MCDOWELL et al., 2020; WU et al., 2020).

Para combater perdas nos estoques terrestres de carbono, tem sido realizado grande esforço na restauração das florestas tropicais por meio de várias iniciativas, tais como REDD+, Convenção sobre Diversidade Biológica (CBD) entre outros (SAYER; CHOKKALINGAM; POULSEN, 2004; ALEXANDER et al., 2011; CRUZ et al., 2020). A restauração de florestas secundárias é um processo lento que pode compensar a rápida perda de carbono proveniente de desmatamentos ou degradação florestal.

A taxa de recuperação florestal e de acumulação de carbono depende em grande parte do histórico de utilização da terra antes da sua degradação, assim como de um conjunto de fatores ambientais como a fertilidade do solo, clima e características da paisagem no entorno da área degradada (BANKS-LEITE et al., 2014; POORTER et al., 2016; YANG et al., 2020a). Devido à extensão das florestas em processo de restauração na Amazônia legal, a regeneração natural destas florestas é amplamente considerada como um mecanismo eficaz e de baixo custo para sequestro de carbono (CHAZDON et al., 2016a; AMARAL et al., 2020; GREENLEAF, 2020), bem como contribuem significativamente para o armazenamento de carbono (JOHNSON et al., 2001; HOUGHTON; NASSIKAS, 2018).

Pesquisas sugerem que as florestas secundárias levam cerca de 66 anos para recuperar aproximadamente 90% do carbono florestal original (POORTER et al., 2016; SILVA JUNIOR et al., 2020). No entanto, de acordo com Yang et al. (2020) estas estimativas podem exorbitar o papel das florestas secundárias na absorção do carbono atmosférico por duas razões: (1) A maioria dos países tropicais não dispõe de sistemas confiáveis de monitoramento do uso do solo e não têm dados precisos sobre as áreas de florestas secundárias, e (2) os dados disponibilizados, muitas vezes, não incluem a dinâmica das atividades de uso e ocupação do solo em relação ao processo de recuperação e regeneração das florestas.

Estimativas do estoque de carbono utilizando sensores remotos são ferramentas utilizadas para compreender o papel das florestas no ciclo do carbono e mensurar como esse estoque é dependente das fases de regeneração da floresta estudo. A taxa de assimilação do carbono é tipicamente maior no período de crescimento, vários estudos (STEININGER, 2010; EDWARDS et al., 2017; KARYATI et al., 2019) compararam o desenvolvimento da floresta com os estoques armazenados de carbono utilizando sensores remotos.

REFERÊNCIAS

- ALEXANDER, S.; NELSON, C. R.; ARONSON, J.; et al. Opportunities and Challenges for Ecological Restoration within REDD+. **Restoration Ecology**, v. 19, n. 6, p. 683–689, 2011.
- ALMEIDA, C. A. de, COUTINHO, A. C., ESQUERDO, J. C. D. M., et al. High spatial resolution land use and land cover mapping of the Brazilian Legal Amazon in 2008 using Landsat-5/TM and MODIS data. **Acta Amazonica**, v. 46, n. 3, p. 291–302, 2016.
- ALVES, D. S.; ESCADA, M. I. S.; PEREIRA, J. L. G.; DE ALBUQUERQUE LINHARES, C. Land use intensification and abandonment in Rondônia, Brazilian Amazônia. **International Journal of Remote Sensing**, v. 24, n. 4, p. 899–903, 2003.
- AMARAL, J. H. F.; MELACK, J. M.; BARBOSA, P. M.; et al. **Carbon Dioxide Fluxes to the Atmosphere From Waters Within Flooded Forests in the Amazon Basin**. 2020.
- ARMENTERAS, D.; MURCIA, U.; GONZÁLEZ, T. M.; BARÓN, O. J.; ARIAS, J. E. Scenarios of land use and land cover change for NW Amazonia: Impact on forest intactness. **Global Ecology and Conservation**, v. 17, 2019.
- BANKS-LEITE, C.; PARDINI, R.; TAMBOSI, L. R.; et al. Using ecological thresholds to evaluate the costs and benefits of set-asides in a biodiversity hotspot. **Science**, v. 345, n. 6200, p. 1041–1045, 2014.
- BEYENE, S. M.; HUSSIN, Y. A.; KLOOSTERMAN, H. E.; ISMAIL, M. H. Forest Inventory and Aboveground Biomass Estimation with Terrestrial LiDAR in the Tropical Forest of Malaysia. **Canadian Journal of Remote Sensing**, v. 46, n. 2, p. 130–145, 2020. Disponível em: <<https://doi.org/10.1080/07038992.2020.1759036>>. .
- BOURGOIN, C.; BLANC, L.; BAILLY, J. S.; et al. The potential of multisource remote sensing for mapping the biomass of a degraded Amazonian forest. **Forests**, v. 9, n. 6, p. 1–21, 2018.
- BRANCALION, P.; GANDOLFI, S.; RODRIGUES, R. R. **Restauração Florestal**. 1º ed. Oficina de Textos, 2015.
- BRANCALION, P. H. S.; CAMPOE, O.; MENDES, J. C. T.; et al. Intensive silviculture enhances biomass accumulation and tree diversity recovery in tropical forest restoration. **Ecological Applications**, v. 29, n. 2, p. e01847, 2019. Disponível em: <<https://onlinelibrary.wiley.com/doi/full/10.1002/eap.1847>>. Acesso em: 28/12/2021.
- BRANDÃO JUNIOR, A.; SOUZA JUNIOR, C. Desmatamento nos Assentamentos de Reforma Agrária na Amazônia. **Imazon**, v. 7, n. 4, 2006.
- BRASIL. Decreto Nº 7.830. Dispõe sobre o Sistema de Cadastro Ambiental Rural, o Cadastro Ambiental Rural, estabelece normas de caráter geral aos Programas de

Regularização o Ambiental, de que trata a Lei nº 12.651, de 25 de maio de 2012, e dá outras providências. , 2012. Brasília, 25 de maio de 2012.

BRASIL. Plano de Ação para Prevenção e Controle do Desmatamento e das Queimadas no Cerrado (PPCerrado) e Plano de Ação para Prevenção e Controle do Desmatamento na Amazônia Legal (PPCDAm). Fase 2016-2020. , 2018. 4ª ed. Brasília: MMA.

CAMARRETTA, N.; HARRISON, P. A.; BAILEY, T.; et al. Monitoring forest structure to guide adaptive management of forest restoration: a review of remote sensing approaches. **New Forests**, v. 51, n. 4, p. 573–596, 2020. Disponível em: <<https://doi.org/10.1007/s11056-019-09754-5>>.

CHAVE, J.; RÉJOU-MÉCHAIN, M.; BÚRQUEZ, A.; et al. Improved allometric models to estimate the aboveground biomass of tropical trees. **Global Change Biology**, v. 20, n. 10, p. 3177–3190, 2014.

CHAZDON, R. L.; BROADBENT, E. N.; ROZENDAAL, D. M. A.; et al. Carbon sequestration potential of second-growth forest regeneration in the Latin American tropics. **Science Advances**, v. 2, n. 5, 2016.

COELHO DE ABREU, J.; PEDRO, C.; SOARES, B.; et al. ALTERNATIVES TO ESTIMATE THE VOLUME OF INDIVIDUAL TREES IN FOREST FORMATIONS IN THE STATE OF MINAS GERAIS, BRAZIL. **CERNE**, v. 26, n. 3, p. 393–402, 2020. Disponível em: <<http://www.scielo.br/j/cerne/a/sLYxsdhnnJvK89Kpf7XJ8HG/abstract/?lang=en>>. Acesso em: 9/1/2022.

CORTE, A. P. D.; SOUZA, D. V.; REX, F. E.; et al. Forest inventory with high-density UAV-Lidar: Machine learning approaches for predicting individual tree attributes. **Computers and Electronics in Agriculture**, v. 179, p. 105815, 2020.

COSTA, G. B. DA; BALTHAZAR, B. L. T. DE A.; LIMA, A. M. S.; NANTES, R. A.; CÂMARA, J. B. DE A. Extractive Reserves in the State in Rondônia: A Positioning about the Occupation and Expectations / Restrictions Suffered by the Residents. **International Journal of Advanced Engineering Research and Science**, v. 6, n. 4, p. 147–154, 2019.

CUNHA NETO, E. M. DA; REX, F. E.; VERAS, H. F. P.; et al. Using high-density UAV-Lidar for deriving tree height of *Araucaria Angustifolia* in an Urban Atlantic Rain Forest. **Urban Forestry and Urban Greening**, v. 63, p. 127197, 2021.

CRUZ, D. C.; BENAYAS, J. M. R.; FERREIRA, G. C.; SANTOS, S. R.; SCHWARTZ, G. An overview of forest loss and restoration in the Brazilian Amazon. **New Forests**, , n. 0123456789, 2020. Disponível em: <<https://doi.org/10.1007/s11056-020-09777-3>>.

DELAZERI, L. Determinantes do Desmatamento nos Municípios do Arco Verde – Amazônia Legal: uma abordagem econométrica. **Revista Economia Ensaios**, v. 30, n. 2, p. 11–34, 2016. Disponível em:

<<http://200.19.146.79/index.php/revistaeconomiaensaio/article/view/28364>>. Acesso em: 4/8/2020.

DEUS, K. H. P.; FILHO, A. F.; DIAS, A. N.; BONETE, I. P. Woody necromass stock in mixed ombrophilous forest using different sampling methods. **Revista Caatinga**, v. 31, n. 3, p. 657–666, 2018.

DREBENSTEDT, I.; SCHMID, I.; POLL, C.; et al. Effects of soil warming and altered precipitation patterns on photosynthesis, biomass production and yield of barley. **Journal of Applied Botany and Food Quality**, v. 93, p. 44–53, 2020.

DUNCANSON, L.; NEUENSCHWANDER, A.; HANCOCK, S.; et al. Biomass estimation from simulated GEDI, ICESat-2 and NISAR across environmental gradients in Sonoma County, California. **Remote Sensing of Environment**, v. 242, p. 111779, 2020.

EDWARDS, D. P.; MASSAM, M. R.; HAUGAASEN, T.; GILROY, J. J. Tropical secondary forest regeneration conserves high levels of avian phylogenetic diversity. **Biological Conservation**, v. 209, p. 432–439, 2017. Disponível em: <<http://dx.doi.org/10.1016/j.biocon.2017.03.006>>. .

ELIAS, F.; FERREIRA, J.; LENNOX, G. D.; et al. Assessing the growth and climate sensitivity of secondary forests in highly deforested Amazonian landscapes. **Ecology**, v. 101, n. 3, 2020.

FREITAS, M. G.; RODRIGUES, S. B.; CAMPOS-FILHO, E. M.; et al. Evaluating the success of direct seeding for tropical forest restoration over ten years. **Forest Ecology and Management**, v. 438, n. February, p. 224–232, 2019. Disponível em: <<https://doi.org/10.1016/j.foreco.2019.02.024>>. .

GREENLEAF, M. The value of the untenured forest: land rights, green labor, and forest carbon in the Brazilian Amazon. **Journal of Peasant Studies**, v. 47, n. 2, p. 286–305, 2020. Disponível em: <<https://doi.org/10.1080/03066150.2019.1579197>>. .

HOUGHTON, R. A.; NASSIKAS, A. A. Negative emissions from stopping deforestation and forest degradation, globally. **Global Change Biology**, v. 24, n. 1, p. 350–359, 2018. Disponível em: <<http://doi.wiley.com/10.1111/gcb.13876>>. Acesso em: 8/8/2020.

HU, T.; ZHANG, Y. Y.; SU, Y.; et al. Mapping the global mangrove forest aboveground biomass using multisource remote sensing data. **Remote Sensing**, v. 12, n. 10, 2020.

JOHNSON, C. M.; VIEIRA, I. C. G.; ZARIN, D. J.; FRIZANO, J.; JOHNSON, A. H. Carbon and nutrient storage in primary and secondary forests in eastern Amazônia. **Forest Ecology and Management**, v. 147, n. 2–3, p. 245–252, 2001.

KARYATI; IPOR, I. B.; JUSOH, I.; WASLI, M. E. Allometric equations to estimate the above-ground biomass of trees in the tropical secondary forests of different ages. **Biodiversitas**, v. 20, n. 9, p. 2427–2436, 2019.

KENZO, T.; HIMMAPAN, W.; YONEDA, R.; et al. General estimation models for above- and below-ground biomass of teak (*Tectona grandis*) plantations in Thailand. **Forest Ecology and Management**, v. 457, p. 117701, 2020.

KRAMER, R. D.; ISHII, H. R.; CARTER, K. R.; et al. Predicting effects of climate change on productivity and persistence of forest trees. **Ecological Research**, , n. April, p. 1–13, 2020.

LAMB, D.; ERSKINE, P. D.; PARROTTA, J. A. Restoration of degraded tropical forest landscapes. **Science**, v. 310, n. 5754, p. 1628–1632, 2005.

LEÃO, F. M.; NASCIMENTO, R. G. M.; EMMERT, F.; et al. How many trees are necessary to fit an accurate volume model for the Amazon forest? A site-dependent analysis. **Forest Ecology and Management**, v. 480, p. 118652, 2021.

LI, Y.; LI, M.; LI, C.; LIU, Z. Forest aboveground biomass estimation using Landsat 8 and Sentinel-1A data with machine learning algorithms. **Scientific Reports** 2020 **10:1**, v. 10, n. 1, p. 1–12, 2020.

MAAS, G. C. B.; SANQUETTA, C. R.; MARQUES, R.; MACHADO, S. D. A.; SANQUETTA, M. N. I. Quantification of carbon in forest necromass: State of the art. **Cerne**, v. 26, n. 1, p. 98–108, 2020.

MARÉCHAUX, I.; CHAVE, J. An individual-based forest model to jointly simulate carbon and tree diversity in Amazonia: description and applications. **Ecological Monographs**, v. 87, n. 4, p. 632–664, 2017. Disponível em: <<http://doi.wiley.com/10.1002/ecm.1271>>. .

MCDOWELL, N. G.; ALLEN, C. D.; ANDERSON-TEIXEIRA, K.; et al. Pervasive shifts in forest dynamics in a changing world. **Science**, v. 368, n. 6494, 2020.

MIRANDA, L. S.; IMPERATRIZ-FONSECA, V. L.; GIANNINI, T. C. Climate change impact on ecosystem functions provided by birds in southeastern Amazonia. **PLoS ONE**, v. 14, n. 4, p. 1–17, 2019.

MOHD ZAKI, N. A.; ABD LATIF, Z. Carbon sinks and tropical forest biomass estimation: a review on role of remote sensing in aboveground-biomass modelling. **Geocarto International**, 2017.

MUKURALINDA, A.; KUYAH, S.; RUZIBIZA, M.; et al. Allometric equations, wood density and partitioning of aboveground biomass in the arboretum of Ruhunde, Rwanda. **Trees, Forests and People**, v. 3, p. 100050, 2021.

MURAOKA, H.; KOIZUMI, H. Satellite Ecology (SATECO)-linking ecology, remote sensing and micrometeorology, from plot to regional scale, for the study of ecosystem structure and function. **Journal of Plant Research**, v. 122, n. 1, p. 3–20, 2009.

NGUYEN, T. H.; JONES, S. D.; SOTO-BERELOV, M.; HAYWOOD, A.; HISLOP, S. Monitoring aboveground forest biomass dynamics over three decades using Landsat

time-series and single-date inventory data. **International Journal of Applied Earth Observation and Geoinformation**, v. 84, p. 101952, 2020.

OBERLEITNER, F.; EGGER, C.; OBERDORFER, S.; et al. Recovery of aboveground biomass, species richness and composition in tropical secondary forests in SW Costa Rica. **Forest Ecology and Management**, v. 479, p. 118580, 2021.

PAN, Y.; BIRDSEY, R. A.; PHILLIPS, O. L.; JACKSON, R. B. The Structure, Distribution, and Biomass of the World's Forests. <http://dx.doi.org/10.1146/annurev-ecolsys-110512-135914>, v. 44, p. 593–622, 2013. Annual Reviews . Disponível em: <<https://www.annualreviews.org/doi/abs/10.1146/annurev-ecolsys-110512-135914>>. Acesso em: 25/10/2021.

PEDLOWSKI, M. A.; MATRICARDI, E. A. T.; SKOLE, D.; et al. Conservation units: A new deforestation frontier in the Amazonian state of Rondônia, Brazil. **Environmental Conservation**, v. 32, n. 2, p. 149–155, 2005. Disponível em: <https://www.cambridge.org/core/product/identifier/S0376892905002134/type/journal_article>. Acesso em: 4/8/2020.

PIONTEKOWSKI, V. J.; MATRICARDI, E. A. T.; PEDLOWSKI, M. A.; FERNANDES, L. C. Avaliação do desmatamento no Estado de Rondônia entre 2001 e 2011. **Floresta e Ambiente**, v. 21, n. 3, p. 297–306, 2014. Disponível em: <<http://dx.doi.org/10.1590/2179-8087.068213>>. Acesso em: 4/8/2020.

POORTER, L.; BONGERS, F.; AIDE, T. M.; et al. Biomass resilience of Neotropical secondary forests. **Nature**, v. 530, n. 7589, p. 211–214, 2016. Disponível em: <<http://dx.doi.org/10.1038/nature16512>>.

PRESTES, N. C. C. DOS S.; MASSI, K. G.; SILVA, E. A.; et al. Fire Effects on Understory Forest Regeneration in Southern Amazonia. **Frontiers in Forests and Global Change**, v. 3, n. February, p. 1–15, 2020.

PRODES. Coordenação-Geral de Observação da Terra. Disponível em: <<http://www.obt.inpe.br/OBT/assuntos/programas/amazonia/prodes>>. Acesso em: 23/10/2021.

RBD, L.; CPD, O.; RLC, F.; et al. Modeling and Spatialization of Biomass and Carbon Stock Using Lidar Metrics in Tropical Dry Forest, Brazil: Preliminary Results. , 2020. Disponível em: <<https://europepmc.org/article/ppr/ppr199325>>. Acesso em: 9/1/2022.

RIGUEIRA, D.; SANTANA, J. G. Como restaurar sua floresta: cartilha. , p. 20, 2015. RIOTERRA. Contexto prévio: Rondônia. 2011. Disponível em: <http://rioterra.org.br/pt/wp-content/uploads/2011/07/analise_socioeconomica_do_entorno_da_area_de_conces_sao_publica_parte_ii.pdf>. Acesso em: 31/5/2020a.

RIOTERRA. Portfolio – Centro de Estudos Rioterra. Disponível em: <<http://rioterra.org.br/pt/portfolio/>>. Acesso em: 5/8/2020b.

RODRIGUES, R. R.; LIMA, R. A. F.; GANDOLFI, S.; NAVE, A. G. On the restoration of high diversity forests: 30 years of experience in the Brazilian Atlantic Forest. **Biological Conservation**, v. 142, n. 6, p. 1242–1251, 2009. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S0006320708004771>>. Acesso em: 4/8/2020.

RONDÔNIA. **Zoneamento Socioeconômico-ecológico do estado de Rondônia**. Porto Velho - Rondônia, 2010.

RUIZ-JAÉN, M. C.; AIDE, T. M. Vegetation structure, species diversity, and ecosystem processes as measures of restoration success. **Forest Ecology and Management**, v. 218, n. 1–3, p. 159–173, 2005.

SANQUETTA, C. . R. .; CORTE, A. P. D. .; RODRIGUES, A. L.; WATZLAWICK, L. F. . **Inventários Florestais: Planejamento e Execução**. Curitiba: Multi-Graphic, 2014.

SANTOS, J. C.; ANJOS, D. V.; DE ALMEIDA, W. R.; AGUIAR, J. J. M.; DELABIE, J. H. C. Ground-dwelling ant diversity in Amazonian secondary forests and neighboring pastures. **Tropical Ecology 2021 62:2**, v. 62, n. 2, p. 279–287, 2021.

SASAKI, T.; ISHII, H.; MORIMOTO, Y. Evaluating restoration success of a 40-year-old urban forest in reference to mature natural forest. **Urban Forestry and Urban Greening**, v. 32, n. January, p. 123–132, 2018. Disponível em: <<https://doi.org/10.1016/j.ufug.2018.04.008>>. .

SAYER, J.; CHOKKALINGAM, U.; POULSEN, J. The restoration of forest biodiversity and ecological values. **Forest Ecology and Management**, v. 201, n. 1, p. 3–11, 2004.

SMITH, C. C.; ESPÍRITO-SANTO, F. D. B.; HEALEY, J. R.; et al. Secondary forests offset less than 10% of deforestation-mediated carbon emissions in the Brazilian Amazon. **Global Change Biology**, v. 26, n. 12, p. 7006–7020, 2020.

SILVA JUNIOR, C. H. L.; ARAGÃO, L. E. O. C.; FONSECA, M. G.; et al. Deforestation-induced fragmentation increases forest fire occurrence in central Brazilian Amazonia. **Forests**, v. 9, n. 6, 2018.

SPYROGLOU, G.; FOTELLI, M.; NANOS, N.; et al. Assessing Black Locust Biomass Accumulation in Restoration Plantations. **Forests 2021, Vol. 12, Page 1477**, v. 12, n. 11, p. 1477, 2021. Disponível em: <<https://www.mdpi.com/1999-4907/12/11/1477/htm>>. Acesso em: 28/12/2021.

STEININGER, M. K. Satellite estimation of tropical secondary forest above-ground biomass: Data from Brazil and Bolivia. **International Journal of Remote Sensing**, v. 21, p. 1139–1157, 2010.

SUBERI, B.; R. TIWARI, K.; GURUNG, D. B.; M. BAJRACHARYA, R.; K. SITLAULA, B. Effect of Harvesting and Non-Harvested Forest Management on Carbon Stocks. **International Journal of Environment and Climate Change**, , n. January, p. 152–164, 2018.

SUN, X.; LI, B.; DU, Z.; et al. Surface modelling of forest aboveground biomass based on remote sensing and forest inventory data. **Geocarto International**, v. 36, n. 14, p. 1549–1564, 2021. Disponível em:

<<https://www.tandfonline.com/doi/abs/10.1080/10106049.2019.1655799>>. Acesso em: 9/1/2022.

TEIXEIRA-SANTOS, J.; DA CUNHA RIBEIRO, A. C.; WIIG, Ø.; et al. Environmental factors influencing the abundance of four species of threatened mammals in degraded habitats in the eastern Brazilian Amazon. **PLoS ONE**, v. 15, n. 2, p. 1–16, 2020.

THEOFANOUS, N.; CHRYSAFIS, I.; MALLINIS, G.; et al. Aboveground Biomass Estimation in Short Rotation Forest Plantations in Northern Greece Using ESA's Sentinel Medium-High Resolution Multispectral and Radar Imaging Missions.

Forests 2021, Vol. 12, Page 902, v. 12, n. 7, p. 902, 2021. Disponível em: <<https://www.mdpi.com/1999-4907/12/7/902/html>>. Acesso em: 28/12/2021.

TOURNEAU, F. M.; BURSZTYN, M. Assentamentos rurais na Amazônia: Contradições entre a política agrária e a política ambiental. **Ambiente e Sociedade**, v. 13, n. 1, p. 111–130, 2010. Disponível em:

<http://www.scielo.br/scielo.php?script=sci_arttext&pid=S1414-753X2010000100008&lng=pt&nrm=iso&tlng=pt>. Acesso em: 4/8/2020.

TURNER, W. Sensing biodiversity: Sophisticated networks are required to make the best use of biodiversity data from satellites and in situ sensors. **Science**, v. 346, n. 6207, p. 301–302, 2014.

VAN BREUGEL, M.; RANSIJN, J.; CRAVEN, D.; BONGERS, F.; HALL, J. S. Estimating carbon stock in secondary forests: Decisions and uncertainties associated with allometric biomass models. **Forest Ecology and Management**, v. 262, n. 8, p. 1648–1657, 2011. Elsevier.

VELOSO, G. A.; FERREIRA, M. E.; FERREIRA JÚNIOR, L. G.; BARBOSA DA SILVA, B. Modelling gross primary productivity in tropical savanna pasturelands for livestock intensification in Brazil. **Remote Sensing Applications: Society and Environment**, v. 17, n. December 2019, 2020.

VIRGULINO-JÚNIOR, P. C. C.; CARNEIRO, D. N.; NASCIMENTO, W. R.; COUGO, M. F.; FERNANDES, M. E. B. Biomass and carbon estimation for scrub mangrove forests and examination of their allometric associated uncertainties. (M.-H. Li, Org.) **PLOS ONE**, v. 15, n. 3, p. e0230008, 2020.

WANG, F.; DING, Y.; SAYER, E. J.; et al. Tropical forest restoration: Fast resilience of plant biomass contrasts with slow recovery of stable soil C stocks. **Functional Ecology**, v. 31, n. 12, p. 2344–2355, 2017. Blackwell Publishing Ltd. Disponível em: <<https://onlinelibrary.wiley.com/doi/full/10.1111/1365-2435.12925>>. Acesso em: 28/12/2021.

WANG, R.; GAMON, J. A.; EMMERTON, C. A.; et al. Detecting intra- and inter-

annual variability in gross primary productivity of a North American grassland using MODIS MAIAC data. **Agricultural and Forest Meteorology**, v. 281, n. November 2019, p. 107859, 2020. Disponível em: <<https://doi.org/10.1016/j.agrformet.2019.107859>>. .

WU, J.; CHEN, B.; REYNOLDS, G.; et al. **Monitoring tropical forest degradation and restoration with satellite remote sensing: A test using Sabah Biodiversity Experiment**. 1º ed. Elsevier Ltd., 2020.

WU, Z.; DAI, E.; WU, ZHIFENG; LIN, M. **Assessing differences in the response of forest aboveground biomass and composition under climate change in subtropical forest transition zone**. Elsevier B.V, 2020.

XIAO, Z.; LIANG, S.; WANG, J.; et al. Long-Time-Series Global Land Surface Satellite Leaf Area Index Product Derived from MODIS and AVHRR Surface Reflectance. **IEEE Transactions on Geoscience and Remote Sensing**, v. 54, n. 9, p. 5301–5318, 2016.

YANG, Y.; SAATCHI, S.; XU, L.; et al. Interannual Variability of Carbon Uptake of Secondary Forests in the Brazilian Amazon (2004-2014). **Global Biogeochemical Cycles**, v. 34, n. 6, p. 1–14, 2020.

ZHU, Z.; PIAO, S.; MYNENI, R. B.; et al. Greening of the Earth and its drivers. **Nature Climate Change**, v. 6, n. 8, p. 791–795, 2016.

ZIMBRES, B.; PERES, C. A.; PENIDO, G.; MACHADO, R. B. Thresholds of riparian forest use by terrestrial mammals in a fragmented Amazonian deforestation frontier. **Biodiversity and Conservation**, v. 27, n. 11, p. 2815–2836, 2018. Disponível em: <<https://doi.org/10.1007/s10531-018-1571-5>>. .

ZWIENER, V. P.; LIMA, R. A. F. DE; SÁNCHEZ-TAPIA, A.; ROCHA, D. S. B.; MARQUES, M. C. M. Tree Diversity in the Brazilian Atlantic Forest: Biases and General Patterns Using Different Sources of Information. **The Atlantic Forest**, p. 115–131, 2021. Disponível em: <https://link.springer.com/chapter/10.1007/978-3-030-55322-7_6>. Acesso em: 9/1/2022.

CAPÍTULO I: DINÂMICA DA BIOMASSA EM PLANTIOS DE RESTAURAÇÃO FLORESTAL NO PERÍODO DE 2016 A 2020

RESUMO

Plantios de restauração são caracterizadas por áreas que foram anteriormente desmatadas e passaram por processos antrópicos de plantio visando sua restauração. Em geral essas florestas são caracterizadas principalmente por espécies de rápido crescimento e são uma alternativa para redução das emissões líquidas de carbono, e desta forma atenuar as mudanças climáticas. Entretanto, esses ambientes florestais ainda são pouco estudados, neste âmbito, este trabalho visou ajustar modelos preditivos de biomassa em relação à altura e diâmetro das árvores, analisando temporalmente e quantitativamente os estoques de biomassa em áreas de plantios florestal de restauração situados em Rondônia, Amazônia Ocidental, visando à quantificação de biomassa aérea nesses ecossistemas e discutir a implicação da abundância de indivíduos nas estimativas. Para o ajuste das equações alométricas foi necessário a medição de todas as árvores com circunferência à altura do peito acima de 15 cm em 20 parcelas com 200m², após as medições foi selecionada uma árvore da parcela que representasse a árvore média em relação ao diâmetro à 1,30 m de altura, sendo a mesma derrubada visando o cálculo de sua biomassa. As equações ajustadas apresentaram R^2_{aj} variando de 0,49 a 0,57, raiz quadrada do erro médio (RMSE) de 247 a 296 kg e Erro padrão da estimativa (S_{yx}) de 49 a 53 kg. Em 2016 as parcelas continham em média 41,47 t.ha⁻¹ de biomassa e 2020 contabilizou-se 81,66 t.ha⁻¹. Neste sentido, observamos um incremento total de 96,92% entre 2016 e 2020. Por meio das estimativas de biomassa foi possível observar que os plantios de restauração florestal são estoques de biomassa potencialmente significativo devido às rápidas taxas de incremento desse componente. Portanto, os estoques de biomassa foram acrescidos em relação aos anos de estudo, demonstrando a capacidade de crescimento de biomassa em florestas em processo de restauração.

Palavras-chave: Equações alométricas; Recuperação florestal; Bioma amazônico.

ABSTRACT

Restoration plantings are characterized by areas that were previously deforested and have undergone anthropic planting processes aimed at their restoration. In general, these forests are characterized mainly by fast-growing species and are an alternative for reducing net carbon emissions, and thus mitigate climate change. However, these forest environments are still poorly studied, in this context, this work aimed to adjust predictive models of biomass in relation to height and diameter of trees, analyzing temporally and quantitatively the biomass stocks in areas of forest restoration plantations located in Rondônia, Eastern Amazon, aiming to quantify the aerial biomass in these ecosystems and discuss the implication of the abundance of individuals in the estimates. To adjust the allometric equations it was necessary to measure all trees with circumference at breast height above 15 cm in 20 plots of 200m². After the measurements a tree was selected from the plot that represented the average tree in relation to diameter at 1.30 m height, and it was cut down in order to calculate its biomass. The adjusted equations showed $R^2_{aj.}$ ranging from 0.49 to 0.57, square root of the mean error (RMSE) from 247 to 296 kg and Standard Error of the estimate (Syx) from 49 to 53 kg. In 2016 the plots contained an average of 41.47 t.ha⁻¹ of biomass and 2020 accounted for 81.66 t.ha⁻¹. In this sense, we observed a total increment of 96.92% between 2016 and 2020. Through the biomass estimates it was possible to observe that restoration plantings are a potentially significant biomass sink due to the rapid increment rates of this component. Therefore, biomass stocks were increased in relation to the study years, demonstrating the capacity for biomass growth in forests in the restoration process.

Keywords: Allometric equations; Forest recovery; Amazon biome; Temporal analysis; Tropical Rainforest.

1 INTRODUÇÃO

A expansão humana no bioma Amazônico resultou na conversão de grandes áreas de floresta tropical em estágio clímax em paisagens que consistem principalmente de pastagem, agricultura e mosaicos de florestas secundárias. Esse tipo de floresta é definido como aquelas formadas em consequência de fatores decorrentes do impacto humano sobre as áreas com cobertura florestal. De acordo com Cruz et al. (2021) e Nunes et al. (2020), os plantios florestais de restauração são reconhecidos como um meio eficaz de conter a perda de biodiversidade e aumentar o desempenho dos serviços ecossistêmicos, como o sequestro de carbono e a proteção e manutenção dos recursos hídricos, em geral essas florestas são caracterizadas principalmente por espécies de rápido crescimento (pioneiras) e são uma boa alternativa para reduzir as emissões líquidas de carbono, mitigando as mudanças climáticas (CHAZDON et al., 2016).

Nos últimos anos, novas formas de recomposição florestal e ecológica foram testadas e podem oferecer formas de conversões das florestas tropicais degradadas. Estas incluem melhorias no manejo de florestas secundárias, reflorestamento e plantio de enriquecimento como formas mais complexas de reflorestamento onde a cobertura florestal foi totalmente perdida (MATOS et al., 2019; BARROS et al., 2020). Enquanto a perda florestal continua no Brasil a taxas variáveis, são implantadas técnicas visando o desenvolvimento das florestas secundárias onde as florestas primárias foram completamente removidas por processos antrópicos.

A extensão e a idade dos plantios florestais de restauração na Amazônia brasileira são altamente dinâmicos (NUNES et al., 2020; WANG et al., 2020). Nesse contexto, essas florestas são um componente primordial na Amazônia brasileira, pois a sua cobertura restabelece a estrutura e a ciclagem de nutrientes no solo. Apesar da importância destas florestas para o planejamento da conservação, a política ambiental e o manejo das áreas florestais na Amazônia brasileira, historicamente têm sido menos estudadas em comparação às florestas tropicais primárias (BARLOW et al., 2007; CARVALHO et al., 2019; TEIXEIRA-SANTOS et al., 2020).

A compreensão dos estoques de biomassa em plantios florestais é essencial para a gestão e restauração florestal, portanto, as estimativas de biomassa são altamente sensíveis a escolha de uma equação alométrica particular (CHAVE et al., 2005; SANQUETTA et al., 2014b, 2014a; VAN BREUGEL et al., 2011; CORTE et al.,

2020). Embora modelos alométricos locais tenham geralmente um bom desempenho para um determinado local ou tipo florestal, eles são imprecisos nas estimativas de biomassa quando aplicadas para outras localidades e florestas de com tipologia distinta (CHAVE et al., 2005; FENG et al., 2017; TEJADA et al., 2020).

A estimativa da biomassa em diferentes escalas, depende principalmente de equações ou de técnicas de sensoriamento remoto para predição e análise em escala regional e nacional de mapeamento (MITCHELL; ROSENQVIST; MORA, 2017; MOHD ZAKI; ABD LATIF, 2017; TRIPATHI; PATEL; KUSHWAHA, 2018). Essas equações são modelos estatísticos usados para prever a biomassa com base em características dendrométricas medidas durante os processos de inventário florestal, a estimativa da biomassa é particularmente desafiadora nas florestas tropicais, devido às dificuldades ligadas à coleta de dados de campo nesses ecossistemas, que são caracterizados por uma grande heterogeneidade de indivíduos e variáveis dendrométricas, assim como sua estrutura vertical e distribuição horizontal.

As equações alométricas são importantes para sua aplicação nas avaliações de biomassa e carbono florestal tanto local como a nível nacional. Diversos modelos pan-tropicais generalizados de equações de estimativa da biomassa foram desenvolvidos por diversos pesquisadores (KENZO et al., 2020; ROMERO et al., 2020; VIRGULINO-JÚNIOR et al., 2020; LATIFAH et al., 2021; SAHA et al., 2021; ZHOU et al., 2021). Os ajustes de tais equações foram obtidos por meio da medição de múltiplas espécies arbóreas e várias localidades distintas e são destinados a serem aplicados a uma ampla variedade de florestas tropicais. No entanto, um grande erro é observado quando são geradas estimativas por meio da adoção de equações alométricas pan-tropicais genéricas para tipos florestais específicos (NGOMANDA et al., 2014; VINH et al., 2019).

Com pesquisas limitadas sobre os plantios florestais de restauração e consequentemente seus estoques de biomassa, é possível que esses estoques sejam quantificados por meio de equações alométricas advindos de medições e observações em campo, e que esta predição possa ser utilizada para análise temporal desses estoques nesses ambientes florestais. Neste sentido este trabalho objetivou ajustar modelos alométricos de biomassa acima do solo em relação ao diâmetro e altura total das árvores, analisando temporalmente e quantitativamente os estoques de biomassa em áreas de plantios florestais de restauração situados em Rondônia, Amazônia

Ocidental, visando a quantificação de biomassa aérea nesses ecossistemas e discutir a implicação da abundância de indivíduos nas estimativas.

2 MATERIAL E MÉTODOS

2.1 AJUSTE DAS EQUAÇÕES

Os dados obtidos em campo: ht, Biomassa (W) e CAP (posteriormente convertido para diâmetro à altura do peito 1,30 m de altura (DAP)), foram utilizados para ajuste de equações visando a estimativa da biomassa individual das árvores. Para ajuste das equações foi utilizado o software R versão 4.04 (R CORE TEAM, 2021), com o pacote *olsrr*, do qual inserindo as variáveis (dependente e independentes) é possível obter todas as combinações entre as variáveis independentes. Além das equações lineares também foram analisados modelos não-lineares, exponenciais, logarítmicos e polinomiais como demonstra a Tabela 3.

TABELA 3 – MODELOS MATEMÁTICOS UTILIZADAS NOS AJUSTES
Modelos genéricos

$$\begin{aligned}
 &y = x_1 + \dots + x_k \\
 &y = x_1 + \dots + x_k + [\log(x_1 + \dots + x_k)] \\
 &y = x_1^2 + \dots + x_k^2 \\
 &y = \log(x_1 + \dots + x_k) \\
 &y = \frac{x_1 + \dots + x_k}{x_2 + \dots + x_k} \\
 &\log y = x_1 + \dots + x_k \\
 &\log y = x_1^2 + \dots + x_k^2 \\
 &\log y = x_1^2 + \dots + x_k^2 + [\log(x_1 + \dots + x_k)] \\
 &y = x_1^{x_2} + \dots + x_k^{x_j} \\
 &y = x_1^{\beta_1} + \dots + x_k^{\beta_j} \\
 &y = \exp(x_1 + \dots + x_k) \\
 &y = \exp(x_1^2 + \dots + x_k^2)
 \end{aligned}$$

FONTE: o autor (2021).

Para todos os modelos testados foi utilizado como variável dependente (y) a biomassa acima do solo (kg) e como variáveis independentes o DAP e ht. Neste sentido foi utilizado o teste de normalidade de *Kolmogorov-Smirnov*, que verifica a normalidade dos resíduos da variável dependente em relação à independente e o teste de homogeneidade da variância de *Bartlett*, do qual, permite comparar a variância de duas ou mais amostras para decidir se elas são tiradas de populações com variância igual.

A seleção do modelo que mais se adequava aos dados foi realizada utilizando-se as métricas de ajuste: SQE (soma de quadrado dos erros), R² (coeficiente de

determinação), R^2_{aj} (coeficiente de determinação ajustado), RMSE (raiz quadrada do erro médio), Viés, X^2 (qui-quadrado), $S_{yx}\%$ (erro padrão da estimativa percentual) e S_{yx} (erro padrão da estimativa). Foi utilizado o Fator de Correção de Meyer para a correção da discrepância logarítmica nos modelos em que a variável dependente foi submetida à transformação logarítmica.

A validação dos modelos foi realizada utilizando até técnica *K-fold* com separação de 10 subconjuntos ($k = 10$), esse método de validação cruzada envolve a divisão do conjunto de dados em k -subconjuntos. Cada subconjunto é mantido enquanto o modelo é treinado em todos os outros subconjuntos, o modelo ajustado é então utilizado para testar o subconjunto que não foi empregado no ajuste.

Os modelos que obtiveram as melhores métricas estatísticas de ajustes foram submetidos à análise visual das suas retas de ajuste (Dados observados versus Dados ajustados) e análise dos resíduos padronizados.

3 RESULTADOS


A Tabela 4 demonstra as características das 30 árvores cortadas em seções e respectivamente pesadas. Estes indivíduos representavam 22 espécies e 11 famílias (Tabela 2). Os diâmetros variaram de 5,41 a 13,06 cm, com média de 9,47 cm e desvio padrão de 2,57 cm. As alturas variaram de 5,23 a 11,80 m, com média de 8,18 m e desvio padrão de 1,75 m.

TABELA 4 – ESPÉCIES COLETADAS E A ESTATÍSTICA DESCRITIVA DOS DIÂMETROS E ALTURAS DAS ÁRVORES ABATIDAS PARA CÁLCULO DA BIOMASSA

Família	Epíteto	DAP (cm)	ht (m)
Anacardiaceae	<i>Anacardium</i> sp.	9,87	8,90
Bignoniaceae	<i>Handroanthus serratifolius</i> (Vahl) S.Grose	10,83	7,02
Bixaceae	<i>Bixa orellana</i> L.	7,17	7,00
Boraginaceae	<i>Cordia alliodora</i> (Ruiz & Pav.) Cham.	12,19	10,97
Euphorbiaceae	<i>Hevea brasiliensis</i> L.	8,12	9,35
	<i>Stryphnodendron</i> sp.	10,50	8,80
	<i>Hymenolobium pulcherrimum</i> Ducke	6,05	6,15
	<i>Inga cylindrica</i> (Vell.) Mart.	10,98	8,60
	<i>Schizolobium amazonicum</i> Huber ex Ducke.	12,73	10,80
	<i>Parkia multijuga</i> Benth.	11,94	7,70
Fabaceae	<i>Hymenaea courbaril</i> L.	13,05	9,80
	<i>Enterolobium schomburgkii</i> (Benth.) Benth.	5,73	6,30
	<i>Apuleia leiocarpa</i> (Vogel) J. F. Macbr.	9,90	9,50
	<i>Dipteryx odorata</i> (Aubl.) Forsyth F.	7,48	6,55
	<i>Enterolobium schomburgkii</i> (Benth.) Benth.	9,24	9,90
	<i>Acacia mangium</i> Wild.	13,06	9,20
Hypericaceae	<i>Vismia guianensis</i> (Aubl.) Choisy	5,41	7,00
Malvaceae	<i>Ceiba pentandra</i> (L.) Gaertn.	10,66	6,25
Melastomataceae	<i>Bellucia grossularioides</i> (L.) Triana	8,92	6,40
Meliaceae	<i>Cedrela odorata</i> L.	7,51	6,65
Estatísticas descritivas		DAP (cm)	ht (m)
	Média	9,56	8,14
	Erro padrão	0,54	0,36
	Mediana	9,88	8,15
	Desvio padrão	2,44	1,61
	Variância da amostra	6,00	2,59
	Mínimo	5,41	6,15
	Máximo	13,06	10,97

FONTE: o autor (2021).

A Figura 3 demonstra as distribuições diamétricas referentes a 2016 e 2020 das quais, no primeiro ano de monitoramento foram mensuradas mais árvores, mas 96% dos indivíduos estavam inclusos na classe de DAP de 0 a 20 cm, no entanto em 2020 foram medidos menos indivíduos. Contudo foi observado que os indivíduos se distribuíam majoritariamente até os 30 cm de DAP, denotando o acréscimo médio nesta variável, assim como foi possível observar árvores com diâmetros acima de 35 cm.



FONTE: o autor (2021).

3.1 EQUAÇÕES AJUSTADAS

O teste de *Kolmogorov-Smirnov* demonstrou que os resíduos são normais ($p = 0,2514$), desta forma foi possível ajustar os modelos sem a necessidade de transformação das variáveis, também foi observado a homogeneidade da variância obtida por meio do teste de *Bartlett* ($p = 0,4304$).

A Tabela 5 demonstra os cinco melhores ajustes para a predição da biomassa acima do solo utilizando as variáveis DAP e altura total, o Modelo 1 apresentou os

melhores valores em relação as estatísticas comparativas. Posteriormente, foi utilizado esse modelo para realizar o cálculo da biomassa acima do solo para todas as árvores mensuradas nas parcelas para cada ano.

TABELA 5 – CINCO MELHORES EQUAÇÕES OBTIDAS NOS AJUSTES, SEGUNDO OS CRITÉRIOS ESTATÍSTICOS


Equações	SQE	R ²	R ² _{ajus}	Viés	RMSE	Syx	Syx%	χ ²
$w = 142,54 - 35,25DAP - 18,08ht + 5,77DAP.ht$	7416,86	0,552	0,571	-9,28x10 ⁻¹⁵	247,22	15,72	49,30	201,16
$w = 525,23 - 161,41DAP - 100,41ht - 20,30log DAP.ht$	7745,75	0,541	0,553	5,58x10 ⁻¹⁶	258,19	16,06	50,38	204,84
$w = -34,46 + \frac{1,65DAP}{0,02DAP.ht}$	8836,56	0,476	0,494	5,57x10 ⁻¹⁶	294,55	17,16	53,81	218,31
$w = -6,04 + 1,72ht^2 - 1,52DAP$	8868,51	0,474	0,492	-2,04x10 ⁻¹⁵	295,61	17,19	53,91	218,61
$w = -6,04 + \frac{-1,52ht}{1,72DAP}$	8889,78	0,472	0,491	-1,85x10 ⁻¹⁵	296,32	17,21	53,97	214,07

Onde: SQE = Soma de quadrado dos erros, R² = coeficiente de determinação, R²_{ajus} = coeficiente de determinação ajustado, RMSE = raiz quadrada do erro médio, χ² = qui-quadrado e Syx = erro padrão da estimativa e Syx% = erro padrão da estimativa em porcentagem.

FONTE: o autor (2021).

A Figura 4 demonstra a comparação dos dados observados e ajustados dos cinco melhores modelos, esses apresentaram comportamentos semelhantes em relação ao ajuste, tendo uma superestimativa quando a biomassa supera os 35 kg. Os resíduos demonstram que essa superestimativa pode chegar até 25 kg a mais que a biomassa observada e com valores menores que 35 kg há uma subestimativa variando até 25 kg a menos.


FIGURA 4 – COMPARAÇÃO DOS CINCO MELHORES MODELOS EM RELAÇÃO AOS DADOS OBSERVADOS E AJUSTADOS



FONTE: o autor (2021).

Os resíduos apresentados na Figura 5 demonstram que as variâncias dos erros são constantes (homocedásticos) e que as variáveis independentes (DAP e ht) possuem relação linear com a variável dependente (W). Foi observado que os resíduos padronizados ficaram dispersos aleatoriamente em torno de zero, com variância constante, concentrados entre -1 e 1.

FIGURA 5 – DISTRIBUIÇÃO GRÁFICA DOS RESÍDUOS PADRONIZADOS DE BIOMASSA TOTAL PARA OS CINCO MELHORES MODELOS AJUSTADOS, O EIXO Y INDICA OS RESÍDUOS PADRONIZADOS, ENQUANTO O X INDICA O TOTAL DE OBSERVAÇÕES.




FONTE: o autor (2021).

3.2 BIOMASSA ESTIMADA

A Figura 6 demonstra a aplicação do modelo ajustado para todas as árvores mensuradas nas parcelas em relação ao diâmetro e à altura. Há uma concentração maior de árvores nas classes até 20 cm de diâmetros com biomassa até 200 kg, no entanto, a partir da classe com 20 cm observa-se uma menor quantidade de indivíduos com biomassas acima dos 200 kg por árvore (Figura 6A). Em relação às alturas observa-se uma concentração de árvores acima de 5 m e menores que 15 m.

FIGURA 6 – DISTRIBUIÇÃO DA BIOMASSA EM RELAÇÃO AO INTERVALO DE CLASSE DOS DIÂMETROS (A) E ALTURAS (B).



FONTE: o autor (2021).

3.3 ESTOQUE DE BIOMASSA ACIMA DO SOLO NAS PARCELAS


A predição da biomassa para as parcelas demonstrou que, com exceção das Parcelas 6, 7, 18 e 19, o restante foi acometida por uma tendência de aumento no estoque de biomassa entre os anos 2016 a 2020, no entanto, em quatro parcelas (1, 2, 17 e 18) não foi possível obter dados em todos os anos do inventário. Foram observadas as seguintes porcentagens de crescimento entre os anos em estudo: Parcela 3 (93,42%), Parcela 4 (30,39%), Parcela 5 (89,69%), Parcela 6 (25,96%), Parcela 7 (115,23%), Parcela 8 (73,39%), Parcela 9 (66,09%), Parcela 10 (94,32%), Parcela 11 (175,54%), Parcela 12 (123,87%), Parcela 13 (65,59%), Parcela 14 (141,46%), Parcela 15 (137,28%), Parcela 16 (113,84%), Parcela 18 (117,55%) e Parcela 19 (90,74%) (Figura 7)

Em 2016, o maior estoque de biomassa acima do solo entre as parcelas inventariadas foi observado na Parcela 18 (55,42 t.ha⁻¹) e o menor na Parcela 14 (15,86 t.ha⁻¹), enquanto que em 2020 a Parcela 11 caracterizou-se com o maior estoque (135,23 t.ha⁻¹), e o menor valor foi 30,91 t.ha⁻¹ (Parcela 6). Observa-se que as Parcelas 6, 15, 18 e 19 apresentaram entre 2019 e 2020 uma redução do seu estoque (-4,99, -2,25, -6,25 e -18,31 t.ha⁻¹, respectivamente).

Em relação à abundância de indivíduos por hectare foi possível observar que as Parcelas 3, 12, 13, 16 e 19 não foram acometidas por redução de indivíduos em

2019, enquanto nas demais parcelas houve decréscimo na quantidade de árvores. A média de árvores nas parcelas foi: 2016 (1.198 árv.ha⁻¹), 2018 (1.466 árv.ha⁻¹), 2019 (1.118 árv.ha⁻¹), 2020 (1.468 árv.ha⁻¹). Observa-se que a Parcela 8 possui a maior abundância (2.200 árv.ha⁻¹), enquanto que a 16 possuía apenas 738 árv.ha⁻¹.

FIGURA 7 – ESTOQUE DE BIOMASSA DAS PARCELAS INVENTARIADAS NOS ANOS DE 2016 A 2020




FONTE: o autor (2021).

A Figura 8 demonstra a distribuição do estoque de biomassa nas parcelas em relação aos anos que ocorrem os inventários. Em 2016 as parcelas continham em média 41,47 t.ha⁻¹ e desvio de 12,29 t.ha⁻¹; 2018 apresentou um total de 57,02 t.ha⁻¹ e 19,20 t.ha⁻¹ de desvio; 2019 apresentou 71,64 t.ha⁻¹ de média e 24,77 t.ha⁻¹ de desvio; contudo, 2020 registrou no total de 81,66 t.ha⁻¹ de média e 28,99 t.ha⁻¹ de desvio. Neste sentido, foi observado um incremento de 37,50% entre 2016 e 2018,

25,64% de 2018 para 2019 e 13,99% de 2019 para 2020, portanto foi observado um incremento total entre 2016 e 2020 de 96,92%.

FIGURA 8 – ESTOQUE DE BIOMASSA ACIMA DO SOLO TOTAL DAS PARCELAS INVENTARIADAS NOS ANOS 2016 A 2020



FONTE: o autor (2021).

4 DISCUSSÃO

A alocação e determinação de biomassa desempenhará um papel importante tomando como base as florestas anteriormente degradadas que foram submetidas aos processos de restauração/recuperação. Neste âmbito, os modelos ajustados visando a predição da biomassa a partir do DAP e ht, demonstram que há uma baixa correlação entre as variáveis dependentes e independentes, pois os coeficientes de correlação ajustados variaram de 0,49 a 0,57, fato que pode ser explicado pela diversidade de espécies que foram amostradas, aumentando a variabilidade das biomassas medidas, seus diâmetros e alturas entre as árvores amostradas.

Ao analisar o Modelo 1, escolhido dentre os cinco melhores, foi possível observar que a predição da biomassa com esse modelo foi satisfatória pois apresentou valores condizentes com a área e com os valores obtidos em campo, entretanto, Romero et al. (2020) observaram métricas estatísticas superiores ao estimar a biomassa de árvores colhidas no sudeste da Amazônia e relatou que a qualidade dos ajustes realizados foi caracterizada pela expressiva quantidade de amostras coletadas (223 indivíduos). Contudo, Karyati et al. (2019), observando plantios florestais em processo de recuperação apresentou resultados semelhantes ao desse estudo, concluíram que a heterogeneidade das florestas secundárias reduz significativamente as relações entre os diâmetros, alturas com a biomassa,

Nesse sentido, diversos fatores influenciam no desenvolvimento das espécies arbóreas em plantios florestais em restauração, deste modo, características como arquitetura de copa, capacidade produtiva do local e competição por luz podem estar relacionadas aos baixos valores estatísticos observados para as estimativas realizadas nesse estudo. Além destes fatores, em florestas nativas, florestas em processo de restauração e em plantios mistos, é de se esperar maior heterogeneidade no desenvolvimento das árvores, ocasionada pela existência de competição interespecífica, o que contribui para obtenção de valores de erro padrão da estimativa mais elevada (SANQUETTA et al., 2017; LIMA et al., 2021).

A redução observada no estoque de biomassa nas parcelas 6, 7, 18 e 19, pode ser explicada devido a mortalidade das árvores e cortes ilegais responsáveis pela redução da biomassa nas parcelas supracitadas, reduzindo a densidade de árvores e consequentemente os valores totais dos estoques de biomassa. Em especial, as

parcelas 18 e 19 que estão localizadas em fronteira com cultivos de soja foram acometidas por remoção parcial da vegetação florestal para implantação da soja.

Os resultados obtidos nesse estudo foram condizentes com os observados em Yang et al. (2020), em que os autores estimaram a biomassa acima do solo utilizando técnicas de sensoriamento remoto, para áreas em processo de restauração com idades que variaram de 1 a 8 anos com biomassas variando de 20 a 70 t.ha⁻¹. Cassol et al. (2019), observaram que áreas na Amazônia em processo de restauração a 10 anos possuem menos de 100 t.ha⁻¹, com dados obtidos por meio do Alos/Palsar-2. A dificuldade na obtenção das biomassas em campo é o fator determinante para aquisição dessa variável por meio de sensores remotos.

Estudos apontam que quanto maior a densidade de indivíduos em uma área, maior será a produção de biomassa por unidade de área, ou seja, os espaçamentos entre os indivíduos mais densos proporcionam maiores quantidades de biomassa que os menores (PEREIRA, 2013; ELOY et al., 2016; CASTANHO et al., 2020; FAVERO; DAIGNEAULT; SOHNGEN, 2020; NÆSSET et al., 2020; SHEN et al., 2020), entretanto, foi possível observar nesse estudo que Parcelas com menores abundâncias por hectare também podem ter estoques de biomassa equivalentes a Parcelas com maior abundância, pois, a dimensão (altura e DAP) dos indivíduos influenciou diretamente no valor médio da biomassa. A Parcela 6 e 16 tinham em 2020 um número igual de árvores por hectare (1.300 árv.ha⁻¹), entretanto as biomassas foram respectivamente 30,91 e 82,09 t.ha⁻¹, fato vinculado às médias dos diâmetros e alturas das árvores nas parcelas que foi maior para a Parcela 15 com média de DAP de 15,6 cm e altura média de 9,4 m, enquanto que na Parcela 6 obteve como médias 12,8 cm e 7,4 m.

As informações apresentadas a respeito dos plantios florestais de restauração são essenciais para o monitoramento e gestão destas áreas pois subsidiam políticas e propostas de gestão ambiental na Amazônia. Essas florestas são uma possível solução para absorção de carbono e controle das mudanças climáticas, além de conservarem a biodiversidade. Portanto, a redução do desmatamento, agricultura e pecuária aliado a manutenção das áreas florestais são vitais para amenizar os impactos ocasionados pelas alterações climáticas.

5 CONCLUSÕES

Os modelos ajustados que utilizam como variáveis independentes o diâmetro à 1,30 m de altura (DAP) e a altura total (ht) apresentam estatísticas satisfatórias, podendo ser utilizados para estimar a biomassa de árvores acima do solo.

Os resultados demonstram que poucas árvores com grandes dimensões são responsáveis pela maior parte do estoque de biomassa nas áreas em restauração, enquanto a abundância de indivíduos por hectare influencia no estoque de biomassa, entretanto o principal fator nesses estoques foram as alturas e os diâmetros, nesse sentido, quanto maior as árvores maiores os estoques de biomassa.

Por meio das estimativas de biomassa foi possível observar que as florestas em processo de restauração são estoques de biomassa potencialmente significativo devido às rápidas taxas de acúmulo desse componente. Portanto, os estoques de biomassa foram acrescidos em relação aos anos de estudo, demonstrando a capacidade de crescimento de biomassa em florestas em processo de restauração.

REFERÊNCIAS

- BARLOW, J.; GARDNER, T. A.; ARAUJO, I. S.; et al. Quantifying the biodiversity value of tropical primary, secondary, and plantation forests. **Proceedings of the National Academy of Sciences of the United States of America**, v. 104, n. 47, p. 18555–18560, 2007. Disponível em: <<https://pubmed.ncbi.nlm.nih.gov/18003934/>>. Acesso em: 24/4/2021.
- BARROS, T. C.; ELIAS, F.; ROMANO, L. L.; FERREIRA, J. Natural recovery of plant species diversity in secondary forests in Eastern Amazonia: contributions to passive forest restoration. **Revista Brasileira de Botânica**, v. 43, n. 1, p. 165–175, 2020. Disponível em: <<https://doi.org/10.1007/s40415-020-00585-9>>. Acesso em: 25/4/2021.
- VAN BREUGEL, M.; RANSIJN, J.; CRAVEN, D.; BONGERS, F.; HALL, J. S. Estimating carbon stock in secondary forests: Decisions and uncertainties associated with allometric biomass models. **Forest Ecology and Management**, v. 262, n. 8, p. 1648–1657, 2011.
- CARVALHO, R.; ADAMI, M.; AMARAL, S.; BEZERRA, F. G.; DE AGUIAR, A. P. D. Changes in secondary vegetation dynamics in a context of decreasing deforestation rates in Pará Brazilian Amazon. **Applied Geography**, v. 106, p. 40–49, 2019. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S0143622818307100>>. Acesso em: 24/4/2021.
- CASSOL, H. L. G.; CARREIRAS, J. M. DE B.; MORAES, E. C.; et al. Retrieving Secondary Forest Aboveground Biomass from Polarimetric ALOS-2 PALSAR-2 Data in the Brazilian Amazon. **Remote Sensing**, v. 11, p. 034053, 2019. Disponível em: <<https://doi.org/10.3390/rs11010059>>.
- CASTANHO, A. D. A.; COE, M. T.; BRANDO, P.; et al. Potential shifts in the aboveground biomass and physiognomy of a seasonally dry tropical forest in a changing climate. **Environmental Research Letters**, v. 15, n. 3, p. 034053, 2020. Disponível em: <<https://doi.org/10.1088/1748-9326/ab7394>>. Acesso em: 25/4/2021.
- CHAVE, J.; ANDALO, C.; BROWN, S.; et al. Tree allometry and improved estimation of carbon stocks and balance in tropical forests. **Oecologia**, v. 145, n. 1, p. 87–99, 2005. Disponível em: <<http://link.springer.com/10.1007/s00442-005-0100-x>>. Acesso em: 24/4/2021.
- CHAZDON, R. L.; BROADBENT, E. N.; ROZENDAAL, D. M. A.; et al. Carbon sequestration potential of second-growth forest regeneration in the Latin American tropics. **Science Advances**, v. 2, n. 5, 2016.
- CORTE, A. P. D.; SOUZA, D. V.; REX, F. E.; et al. Forest inventory with high-density UAV-Lidar: Machine learning approaches for predicting individual tree attributes. **Computers and Electronics in Agriculture**, v. 179, p. 105815, 2020.

ELOY, E.; SILVA, D. A. DA; SCHMIDT, D.; et al. Effect of planting age and spacing on energy properties of *Eucalyptus grandis* W. Hill EX Maiden. **Revista Árvore**, v. 40, n. 4, p. 749–758, 2016. Disponível em: <http://dx.doi.org/10.1590/0100-67622016000400019%5Cnhttp://www.scielo.br/scielo.php?script=sci_arttext&pid=S0100-67622016000400749&lng=en&tlng=en>. .

FAVERO, A.; DAIGNEAULT, A.; SOHNGEN, B. Forests: Carbon sequestration, biomass energy, or both? **Science Advances**, v. 6, n. 13, p. eaay6792, 2020.

FENG, Y.; LU, D.; CHEN, Q.; et al. Examining effective use of data sources and modeling algorithms for improving biomass estimation in a moist tropical forest of the Brazilian Amazon. **International Journal of Digital Earth**, v. 10, n. 10, p. 996–1016, 2017. Disponível em: <<https://www.tandfonline.com/doi/full/10.1080/17538947.2017.1301581>>. Acesso em: 24/4/2021.

KARYATI; IPOR, I. B.; JUSOH, I.; WASLI, M. E. Allometric equations to estimate the above-ground biomass of trees in the tropical secondary forests of different ages. **Biodiversitas**, v. 20, n. 9, p. 2427–2436, 2019.

KENZO, T.; HIMMAPAN, W.; YONEDA, R.; et al. General estimation models for above- and below-ground biomass of teak (*Tectona grandis*) plantations in Thailand. **Forest Ecology and Management**, v. 457, p. 117701, 2020. Elsevier B.V.

LATIFAH, S.; PURWOKO, A.; SRI HARTINI, K.; AMALIA FACHRUDIN, K. Allometric models to estimate the aboveground biomass of forest: A literature review. **IOP Conference Series: Materials Science and Engineering**, v. 1122, n. 1, p. 012047, 2021. Disponível em: <<https://iopscience.iop.org/article/10.1088/1757-899X/1122/1/012047>>. Acesso em: 25/4/2021.

LIMA, R. C.; SARDINHA, M. A.; SOUZA, J. DOS S.; et al. Composition and structure of a stretch of tropical forest in the Eastern Amazon. **Ciência Rural**, v. 51, n. 4, p. 2021. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0103-84782021000400301&tlng=en>. Acesso em: 25/3/2021.

MATOS, F. A. R.; MAGNAGO, L. F. S.; AQUILA CHAN MIRANDA, C.; et al. Secondary forest fragments offer important carbon and biodiversity cobenefits. **Global Change Biology**, v. 26, n. 2, p. 509–522, 2019. Disponível em: <<https://onlinelibrary.wiley.com/doi/abs/10.1111/gcb.14824>>. Acesso em: 25/4/2021.

MITCHELL, A. L.; ROSENQVIST, A.; MORA, B. Current remote sensing approaches to monitoring forest degradation in support of countries measurement, reporting and verification (MRV) systems for REDD+. **Carbon Balance and Management**, 1. dez. 2017. Disponível em: <<https://pubmed.ncbi.nlm.nih.gov/28417324/>>. Acesso em: 24/4/2021.

MOHD ZAKI, N. A.; ABD LATIF, Z. Carbon sinks and tropical forest biomass estimation: a review on role of remote sensing in aboveground-biomass modelling. **Geocarto International**, 3. jul. 2017.

NÆSSET, E.; MCROBERTS, R. E.; PEKKARINEN, A.; et al. Use of local and global maps of forest canopy height and aboveground biomass to enhance local estimates of biomass in miombo woodlands in Tanzania. **International Journal of Applied Earth Observation and Geoinformation**, v. 93, p. 102138, 2020.

NGOMANDA, A.; ENGONE OBIANG, N. L.; LEBAMBA, J.; et al. Site-specific versus pantropical allometric equations: Which option to estimate the biomass of a moist central African forest? **Forest Ecology and Management**, v. 312, p. 1–9, 2014.

NUNES, S. MIA; OLIVEIRA, L.; SIQUEIRA, J. O.; MORTON, D. C.; SOUZA, C. M. Unmasking secondary vegetation dynamics in the Brazilian Amazon. **Environmental Research Letters**, v. 15, n. 3, p. 034057, 2020. Disponível em: <<https://doi.org/10.1088/1748-9326/ab76db>>. Acesso em: 25/4/2021.

PEREIRA, M. G. A seção de método de um artigo científico. **Epidemiologia e Serviços de Saúde**, v. 22, n. 1, p. 183–184, 2013. Disponível em: <http://scielo.iec.pa.gov.br/scielo.php?script=sci_arttext&pid=S1679-49742013000100020&lng=en&nrm=iso&tlng=en>.

POORTER, L.; BONGERS, F.; AIDE, T. M.; et al. Biomass resilience of Neotropical secondary forests. **Nature**, v. 530, n. 7589, p. 211–214, 2016. Disponível em: <<http://dx.doi.org/10.1038/nature16512>>.

R Core Team (2021). R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria. URL <https://www.R-project.org/>

ROMERO, F. M. B.; JACOVINE, L. A. G.; RIBEIRO, S. C.; et al. Allometric Equations for Volume, Biomass, and Carbon in Commercial Stems Harvested in a Managed Forest in the Southwestern Amazon: A Case Study. **Forests**, v. 11, n. 8, p. 874, 2020. Disponível em: <<https://www.mdpi.com/1999-4907/11/8/874>>. Acesso em: 23/3/2021.

SAHA, C.; MAHMOOD, H.; NAYAN, S. N. S.; et al. Allometric biomass models for the most abundant fruit tree species of Bangladesh: A Non-destructive approach. **Environmental Challenges**, v. 3, p. 100047, 2021.

SANQUETTA, C. R.; BEHLING, A.; CORTE, A. P. D.; et al. Eficiência de conversão da radiação fotossintética interceptada em Fitomassa de mudas de *Eucalyptus dunii* Maiden em função da densidade de plantas e do ambiente de cultivo. **Scientia Forestalis/Forest Sciences**, v. 42, n. 104, p. 573–580, 2014.

SANQUETTA, C. R.; BEHLING, A.; DALLA CORTE, A. P.; et al. A model based on environmental factors for diameter distribution in black wattle in Brazil. **PLoS ONE**, v. 9, n. 6, 2014.

SANQUETTA, C. R.; SANQUETTA, M. N. I.; BASTOS, A.; QUEIROZ, A.; DALLA CORTE, A. P. Estimativa da altura e do volume em povoamentos jovens de restauração florestal em Rondônia. **BIOFIX Scientific Journal**, v. 2, n. 2, p. 23,

2017. Disponível em: <<https://revistas.ufpr.br/biofix/article/view/54124>>. Acesso em: 25/3/2021.

SHEN, G.; WANG, Z.; LIU, C.; HAN, Y. Mapping aboveground biomass and carbon in Shanghai's urban forest using Landsat ETM+ and inventory data. **Urban Forestry and Urban Greening**, v. 51, p. 126655, 2020.

TEIXEIRA-SANTOS, J.; DA CUNHA RIBEIRO, A. C.; WIIG, Ø.; et al. Environmental factors influencing the abundance of four species of threatened mammals in degraded habitats in the eastern Brazilian Amazon. **PLoS ONE**, v. 15, n. 2, p. 1–16, 2020.

TEJADA, G.; GÖRGENS, E. B.; OVANDO, A.; OMETTO, J. P. Mapping data gaps to estimate biomass across Brazilian Amazon forests. **Forest Ecosystems**, v. 7, n. 1, p. 25, 2020. Disponível em: <<https://forestecosyst.springeropen.com/articles/10.1186/s40663-020-00228-1>>. Acesso em: 24/4/2021.

TRIPATHI, P.; PATEL, N. R.; KUSHWAHA, S. P. S. Estimating net primary productivity in tropical forest plantations in India using satellite-driven ecosystem model. **Geocarto International**, v. 33, n. 9, p. 988–999, 2018. Disponível em: <<https://www.tandfonline.com/doi/abs/10.1080/10106049.2017.1323963>>. Acesso em: 24/4/2021.

VINH, T. VAN; MARCHAND, C.; LINH, T. V. K.; VINH, D. D.; ALLENBACH, M. Allometric models to estimate above-ground biomass and carbon stocks in *Rhizophora apiculata* tropical managed mangrove forests (Southern Viet Nam). **Forest Ecology and Management**, v. 434, p. 131–141, 2019. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S0378112718311551>>. Acesso em: 24/4/2021.

VIRGULINO-JÚNIOR, P. C. C.; CARNEIRO, D. N.; NASCIMENTO, W. R.; COUGO, M. F.; FERNANDES, M. E. B. Biomass and carbon estimation for scrub mangrove forests and examination of their allometric associated uncertainties. (M.-H. Li, Org.). **PLOS ONE**, v. 15, n. 3, p. e0230008, 2020. Disponível em: <<https://dx.plos.org/10.1371/journal.pone.0230008>>. Acesso em: 24/4/2021.

WANG, R.; GAMON, J. A.; EMMERTON, C. A.; et al. Detecting intra- and inter-annual variability in gross primary productivity of a North American grassland using MODIS MAIAC data. **Agricultural and Forest Meteorology**, v. 281, n. November 2019, p. 107859, 2020. Disponível em: <<https://doi.org/10.1016/j.agrformet.2019.107859>>.

WANG, Y.; ZIV, G.; ADAMI, M.; et al. Upturn in secondary forest clearing buffers primary forest loss in the Brazilian Amazon. **Nature Sustainability**, v. 3, n. 4, p. 290–295, 2020. Disponível em: <<http://www.nature.com/articles/s41893-019-0470-4>>. Acesso em: 24/4/2021.

YANG, Y.; SAATCHI, S.; XU, L.; et al. Interannual Variability of Carbon Uptake of Secondary Forests in the Brazilian Amazon (2004-2014). **Global Biogeochemical Cycles**, v. 34, n. 6, p. 1–14, 2020.

ZHOU, X.; YANG, M.; LIU, Z.; et al. Dynamic allometric scaling of tree biomass and size. **Nature Plants**, v. 7, n. 1, p. 42–49, 2021. Disponível em: <<https://www.nature.com/articles/s41477-020-00815-8>>. Acesso em: 25/4/2021.

CAPÍTULO II: DINÂMICA DA DISTRIBUIÇÃO ESPACIAL DE BIOMASSA ACIMA DO SOLO EM PLANTIOS DE RESTAURAÇÃO EM RONDÔNIA NA AMAZÔNIA OCIDENTAL

RESUMO

O conhecimento à cerca da biomassa acima do solo em plantios florestais em processo de restauração pode ser aprimorado com a utilização de índices de vegetação (IV) obtidos a partir de sensores orbitais. O objetivo deste trabalho foi avaliar a dinâmica da distribuição espacial da biomassa acima do solo de plantios de restauração florestal em Rondônia no período de 2016 a 2020. Para tanto, utilizaram-se dados orbitais oriundos dos satélites Sentinel-2A e Landsat-8 e dados de inventários florestais realizados em plantios florestais de restauração em Rondônia. A Biomassa acima do solo (AGB) foi relacionada com os índices de vegetação e transformações de bandas adquiridos por meio de sensores orbitais utilizando como parâmetro de extração os polígonos das parcelas. A partir dos modelos ajustados foi escolhido o modelo que possuía a melhor performance estatística do qual foi inserido na plataforma online *Google Earth Engine* (GEE), para espacialização da AGB em florestas em restauração. De forma geral, a AGB e os IVs apresentaram valores de correlação baixos, e os modelos ajustados apresentaram R^2_{aj} variando de 0,489 a 0,772. A distribuição espacial da AGB demonstrou que em 2016 a área de estudo possuía 237.483.130 t de biomassa, enquanto em 2020 o estoque foi 375.761.230 t, ou seja, um acréscimo de 138.278.100 t (+63,2% em relação ao ano do início dos plantios). A espacialização entre os anos 2016 e 2020 foi condizente com os dados coletados em campo e os descritos na literatura.

Palavra-chave: *Google Earth Engine*. Índices de vegetação. Recuperação florestal. Rondônia.

ABSTRACT

The knowledge about the aboveground biomass in forest plantations in the restoration process can be improved with the use of vegetation indices (IV) obtained from orbital sensors. The objective of this work was to evaluate the dynamics of the spatial distribution of aboveground biomass of forest restoration plantations in Rondônia in the period from 2016 to 2020. To this end, we used orbital data from the Sentinel-2A and Landsat-8 satellites and data from forest inventories conducted in forest restoration plantations in Rondônia. The above ground biomass (AGB) was related to the vegetation indices and band transformations acquired by means of orbital sensors using as extraction parameter the polygons of the plots. From the fitted models, the model with the best statistical performance was chosen and inserted in the online platform Google Earth Engine (GEE), for spatialization of AGB in restoring forests. In general, the AGB and the IVs presented low correlation values, and the fitted models presented R^2_{aj} ranging from 0.489 to 0.772. The spatial distribution of AGB showed that in 2016 the study area had 237.483.130 t of biomass, while in 2020 the stock was 375.761.230 t, that is, an increase of 138.278.100 t (+ 63.2% compared to the year of the beginning of the plantations). The spatialization between the years 2016 and 2020 was consistent with the data collected in the field and those described in the literature.

Keywords: *Google Earth Engine*. Forest recovery. Rondônia. Vegetation indices.

1 INTRODUÇÃO

Processos antrópicos de degradação das florestas primárias representam uma ameaça constante para os serviços ecossistêmicos e biodiversidade vegetal e animal. Contudo, métodos que visam mitigar esses processos são comumente utilizados para restabelecimento dos recursos anteriormente existentes, neste sentido plantios florestais de restauração são propulsoras do processo regenerativos das áreas anteriormente atingidas. A restauração da vegetação, também conhecida como sucessão secundária, pode ser uma estratégia eficaz para aumentar a cobertura florestal, a biodiversidade associada e as funções do solo (ROCHA et al., 2018; TEIXEIRA et al., 2020).

A alta capacidade das florestas tropicais em se recuperar de distúrbios e consequentemente recuperar sua biomassa acima do solo após esses eventos é primordial para o sucesso de recuperação de áreas degradadas. Essa taxa de recuperação contribui para o armazenamento de carbono e mitigação das mudanças climáticas (POORTER et al., 2016b; HOUGHTON; NASSIKAS, 2018; VIRGULINO-JÚNIOR et al., 2020; LIMA et al., 2021). Embora os padrões de alterações na composição e estrutura da vegetação ao longo da sucessão secundária se tornem cada vez mais evidentes, os efeitos da sucessão nos estoques de biomassa acima do solo ainda são pouco explorados.

No contexto da mitigação das mudanças climáticas, a avaliação das taxas de acumulação de biomassa acima do solo em florestas em processo de restauração é, portanto, essencial para reduzir as incertezas nas modelagens nos estoques de carbono das florestas. A alta variabilidade nas taxas de acúmulo de biomassa mostradas por esses plantios em escalas regionais e globais enfatiza a necessidade de estimativas desta variável validadas em campo para as regiões tropicais (BOJÓRQUEZ et al., 2020; ELIAS et al., 2020; YANG et al., 2020b).

As estimativas da biomassa são geralmente realizadas por meio de modelos alométricos relacionando biomassa (variável dependente) à altura total, peso, densidade e diâmetro à 1,30 m de altura (DAP) (variáveis independentes). Esses modelos podem ser classificados em duas categorias principais: modelos específicos por espécie que geralmente fornecem estimativas mais precisas; e modelos generalizados que resultam da análise de várias espécies em uma única equação preditiva que intrinsecamente pode levar a maiores imprecisões devido à alta

variabilidade interespecífica, particularmente em espécies comunidades ricas (CHAVE et al., 2014; NGOMANDA et al., 2014; TRIPATHI; PATEL; KUSHWAHA, 2018; BOJÓRQUEZ et al., 2020).

Neste sentido, técnicas têm sido desenvolvidas para inserção de variáveis independentes que utilizam dados de sensores orbitais, dos quais auxiliam na estimativa de biomassa e carbono. Os dados dos satélites fornecem informações de áreas florestais que comumente são inacessíveis, ou difíceis para análises de campo. Outro fator preponderante é o mapeamento de grandes extensões de áreas e caracterização de coberturas florestais bastante diversificadas, principalmente em regiões tropicais (NATHAWAT, 2015; GHOSH; BEHERA, 2018; MOTLAGH et al., 2018; SINHA; SHARMA; WANG et al., 2020). Entretanto, os dados de sensoriamento remoto não estimam diretamente os valores de biomassa, mas são calculados usando relações estatísticas entre as respostas espectrais tomadas do sensor, que compreendem principalmente índices de vegetação, informações de bandas espectrais e suas transformações.

Os índices de vegetação estão entre as técnicas de processamento mais importantes e mais comumente aplicadas para atributos estruturais de floresta, são utilizados geralmente satélites de média resolução para aquisição dos dados espectrais, e estes são utilizados para prever e monitorar biomassa em ambientes florestais. Para as abordagens indiretas na estimativa de biomassa usando dados de satélite, a precisão é altamente dependente da resolução temporal e da qualidade das observações ópticas do satélite (GUERINI FILHO; KUPLICH; QUADROS, 2020; LI et al., 2021; ZUMO; HASHIM; HASSAN, 2021).

O uso de diferentes processos metodológicos na quantificação e espacialização da distribuição espacial da biomassa fornece resultados distintos, essas metodologias podem ser aplicadas a um mesmo conjunto de dados e de variáveis ambientais? Há vantagem na utilização de dados orbitais na quantificação da distribuição espacial da biomassa acima do solo? Deste modo, estimativas da biomassa em plantios de restauração são cada vez mais importantes em relação aos estoques de carbono que essas áreas possuem, portanto, o sensoriamento remoto orbital é uma ferramenta útil para estimativa de biomassa e monitoramento de grandes extensões de terra. Neste âmbito, o objetivo deste trabalho foi avaliar a dinâmica da distribuição espacial da biomassa acima do solo de plantios de restauração florestal

de 2016 a 2020, utilizando dados orbitais oriundos dos satélites Sentinel-2A e Landsat 8 e dados coletados em campo em Rondônia, Amazônia Ocidental.

2 MATERIAL E MÉTODOS

2.1 OBTENÇÃO DOS DADOS ORBITAIS

A aquisição e processamento dos dados espaciais das cenas dos satélites Sentinel-2A (resolução espacial de 10 m) e Landsat-8 (resolução espacial de 15 m) foi realizada utilizando a plataforma online *Google Earth Engine* (GEE), da qual foram obtidos os dados referentes às reflectâncias das bandas e realizados os cálculos referentes aos índices de vegetação e transformações espectrais.

Os valores das transformações e índices de vegetação foram extraídos das imagens por meio da extração por máscara, da qual foi utilizada os arquivos vetoriais das parcelas. A aquisição das cenas foi em função das datas em que foram coletadas as árvores para a obtenção da biomassa.

2.2 ÍNDICES DE VEGETAÇÃO (IV)

Os índices de vegetação (IV) utilizados são apresentados na Tabela 6, dos quais foram escolhidos de acordo com os índices mais utilizados na literatura para estimativas de AGB.

TABELA 6 – ÍNDICES DE VEGETAÇÃO (IV) UTILIZADOS E SUAS RESPECTIVAS FÓRMULAS

ÍNDICES DE VEGETAÇÃO	Fórmula
NDVI (Índice de Vegetação da Diferença Normalizada)	$\frac{\rho_{nir} - \rho_{red}}{\rho_{nir} + \rho_{red}}$
SAVI (Índice de Vegetação Ajustado ao Solo)	$(1 + L_1) \frac{\rho_{nir} - \rho_{red}}{\rho_{nir} + \rho_{red} + L_1}$
EVI (Índice de Realce da Vegetação)	$2,5 \times \frac{\rho_{nir} - \rho_{red}}{\rho_{nir} + (C_1 \times \rho_{red}) - (C_2 \times \rho_{blue}) + L}$
ARVI (Índice de Vegetação Resistente a Atmosfera)	$\frac{(\rho_{nir} - \rho_{red}) - \delta(\rho_{nir} - \rho_{red})}{(\rho_{nir} + \rho_{red}) - \delta(\rho_{nir} - \rho_{red})}$
MSAVI (Índice de Vegetação Modificado Ajustado ao Solo)	$\frac{2 \times (\rho_{nir} + 1) - \sqrt{2 \times (\rho_{nir} + 1)^2 - \delta(\rho_{nir} - \rho_{red})}}{2}$
WDRVI (Índice de Vegetação de Ampla Faixa Dinâmica)	$\frac{0,1 \times (\rho_{nir} - \rho_{red})}{0,1 \times (\rho_{nir} + \rho_{red})}$
SR (Índice de Razão Simples)	$\frac{\rho_{nir}}{\rho_{red}}$

Onde: ρ_{NIR} : Reflectância da banda do infravermelho próximo, ρ_{RED} : Reflectância da banda do vermelho, ρ_{BLUE} : Reflectância da banda do azul, L_1 : fatores de ajuste = 0,5, L_2 = fatores de ajuste = 0,5, C_1 : constante = 6, C_2 : constante = 7,5 e δ : quociente derivado da refletância atmosférica das bandas azul e vermelha.

FONTE: o autor (2021).

2.3 TRANSFORMAÇÃO TASSELED CAP

As cenas dos satélites Sentinel-2A e Landsat-8 foram submetidas à transformação espectral *Tasseled Cap* proposta inicialmente por Kauth e Thomas (1976), que consiste na obtenção de novos valores para as reflectâncias utilizando as combinações lineares das reflectâncias originais das bandas. Os coeficientes de transformação são calculados inicialmente pela variabilidade espectral dos *pixels* que compõem uma cena, dos quais são resultantes de ortogonalizações sucessivas do “plano do solo”.

Foram utilizados para o Landsat-8 os coeficientes ajustados por Baig et al. (2014) e para o Sentinel-2A os ajustados por Crist e Ciccone (1984), demonstrados na Tabela 7. A partir desta transformação foi possível extrair três variáveis: *Brightness* (Brig), *Greenness* (green) e *Wetness* (Wet).

TABELA 7 – COEFICIENTES UTILIZADOS PARA A TRANSFORMAÇÃO TASSELED CAP PARA OS SATÉLITES LANDSAT-8 E SENTINEL-2A

		Banda 2	Banda 3	Banda 4	Banda 5	Banda 6	Banda 7
Landsat-8	<i>Brightness</i>	0,3029	0,2786	0,4733	0,599	0,5080	0,1872
	<i>Greenness</i>	-0,2941	-0,2430	-0,5424	0,7276	0,0713	-0,1608
	<i>Wetness</i>	0,1511	0,1973	0,3283	0,3407	-0,7117	-0,4549
Sentinel-2A	<i>Brightness</i>	0,3037	0,2793	0,4743	0,5585	0,5082	0,1863
	<i>Greenness</i>	-0,2848	-0,2435	-0,5436	0,7243	0,0840	0,1800
	<i>Wetness</i>	0,1509	0,1973	0,3279	0,3406	0,7112	0,4572

FONTE: o autor (2021).

2.4 TRANSFORMAÇÃO RGB - HSV

A conversão do sistema *Red*, *Green* e *Blue* (RGB) para *Hue*, *Saturation* e *Value* (HSV) foi realizada pois, o RGB não considera o efeito de luminância, o que causa incorreções na interpretação das imagens. O HSV fornece informações de cores como *Hue* (ou profundidade de cor), *Saturation* (ou pureza de cor) e *Value* (ou brilho de cor).

O *Hue* refere-se às cores vermelha, azul e amarela e tem o intervalo de 0 a 360. Ao utilizar o espaço de cores HSV, não é necessário a obtenção da percentagem de azul ou verde que é necessária para produzir uma cor, para isso é ajustada o *Hue* para se obter a cor desejada. *Saturation* significa pureza da cor e abrange os valores de 0 a 100%. O *Value* varia de 0 a 100. A partir deste espaço de cor, H e S fornecem as informações necessárias sobre os componentes inseridos nos *pixels* da imagem (SCHNEIDER et al., 2003; GRINEVICH; LEFANOVA; BELYAEVA, 2019; KUMAR; JINDAL, 2019).

Desta transformação é possível extrair três variáveis: *Hue*, *Saturation* (sat) e *Value* e um índice denominado Índice de Diferença Normalizada *Saturation-Value* (NSVDI), calculado a partir da Equação (6).

$$NSVDI = \frac{\rho_{saturation} - \rho_{value}}{\rho_{saturation} + \rho_{value}} \quad (6)$$

2.5 TRANSFORMAÇÃO UTILIZANDO COMPONENTES PRINCIPAIS

A análise de componentes principais (PCA) é uma técnica de transformação que mantém a maior parte da informação encontrada nos dados da imagem original (PECHENIZKIY et al., 2006). Esta transformação preserva as características espectrais, espaciais e constrói uma imagem combinada de várias imagens de entrada como uma sobreposição ponderada. As imagens resultantes contêm informações melhoradas em comparação com imagens individuais de entrada, pois é um método de enfoque na nitidez. Fornece imagens de boa qualidade e evita a distorção da cor utilizada para reduzir conjuntos de dados multidimensionais em dimensões inferiores para análises posteriores, convertendo variáveis correlacionadas em variáveis não correlacionadas chamadas componentes principais (YANG et al., 2013; NANDAL et al., 2019).

Para o Sentinel-2A foram utilizadas as bandas 2, 3, 4, 8, 11 e 12 e o *Landsat-8* as bandas 2, 3, 4, 5, 6 e 7, resultando em seis componentes principais (pc1, pc2, pc3, pc4, pc5 e pc6), dos quais foram utilizados como variáveis independentes.

2.6 SELEÇÃO DAS VARIÁVEIS

Para seleção das variáveis para ajuste dos modelos foram utilizadas 3 técnicas:

Stepwise: é uma ferramenta que utiliza a significação estatística para selecionar as variáveis independentes que serão utilizadas posteriormente em modelos simples ou múltiplos (SMITH, 2018). Para implementação do mesmo, foi utilizada a função *ols_step_both_aic* do pacote *olsrr* (HEBBALI; HEBBALI, 2017) do software R versão 4.04 (R CORE TEAM, 2021), onde é realizada um ajuste de modelo com todas as variáveis e o resultado desse é utilizado como entrada na função mencionada.

Correlação: estatística que analisa o grau da correlação linear entre duas variáveis quantitativas. Resulta em valores que variam de -1 a +1 (adimensionais), que refletem a intensidade de uma relação linear entre dois conjuntos de dados. Entretanto, pode estar inserida outra dependência (não linear), que resultaria em uma correlação nula, neste sentido devem ser utilizados outros métodos de seleção (LIRA; NETO, 2006). Para realização desta etapa foi inserido na função *cor* do pacote *Stats* (TEAM et al., 2016) todas as variáveis, a fim de se obter as correlações entre as mesmas.

Valor de Importância: as funções de avaliação de importância podem ser separadas em dois grupos: as que utilizam a informação do modelo ajustado e as que não o fazem. A vantagem de utilizar uma abordagem baseada em modelos ajustados é que essa é mais relacionada ao desempenho do modelo e é capaz de incorporar a correlação estrutural entre os preditores no cálculo da importância. As variáveis são retiradas e inseridas no modelo, e em cada etapa do processo é calculado o Erro quadrado médio (MSE), as variáveis que inseridas no modelo exibirem os maiores MSE podem ser retiradas do modelo (KUHN, 2007). O modelo ajustado com todas as variáveis foi inserido na função *varImp* que estrutura o pacote *Caret* (KUHN, 2012), resultando em um vetor de variáveis classificado de acordo com seu grau de importância para o modelo.

Para seleção das variáveis independentes utilizadas nos ajustes das modelos foram comparados os resultados dos três métodos. As variáveis não cotadas em nenhum dos métodos não foram utilizadas nos ajustes, ao passo que as variáveis que ocorreram ao menos em duas técnicas foram utilizadas para os ajustes.

2.7 AJUSTE DE MODELOS

Para todos os modelos testados foi utilizado como variável dependente AGB (t.ha^{-1}) e como variáveis independentes o DAP e ht. Neste sentido foi utilizado o teste de normalidade de *Kolmogorov-Smirnov*, do qual verifica a normalidade dos resíduos da variável dependente em relação à independente e o teste de homogeneidade da variância de *Bartlett*, do qual, permite comparar a variância de duas ou mais amostras para decidir se elas são tiradas de populações com variância igual.

O modelo que mais se adequava aos dados foi escolhido utilizando as métricas de ajuste: SQE (soma de quadrado dos erros), R^2 (coeficiente de determinação), R^2_{aj} (Coeficiente de determinação ajustado), RMSE (raiz quadrada do erro médio), Viés, χ^2 (qui-quadrado), $S_{yx}\%$ (erro padrão da estimativa percentual) e S_{yx} (erro padrão da estimativa). Foi utilizado o Fator de Correção de Meyer para a correção da discrepância logarítmica nos modelos em que a variável dependente foi submetida à transformação logarítmica.

A validação dos modelos foi realizada utilizando até técnica K-fold com separação de 10 subconjuntos ($k = 10$), esse método de validação cruzada envolve a divisão do conjunto de dados em k-subconjuntos. Cada subconjunto é mantido enquanto o modelo é treinado em todos os outros subconjuntos, o modelo ajustado é então utilizado para testar o subconjunto que não foi empregado no ajuste.

Os modelos que obtiveram as melhores métricas estatísticas de ajustes foram submetidos à análise visual das suas retas de ajuste (Dados observados versus Dados ajustado) e análise dos resíduos padronizados.

2.8 ESPACIALIZAÇÃO DA AGB

A partir do modelo que obteve melhores resultados foi realizada a espacialização da biomassa no ano da implantação dos plantios (2016 e 2020), para tanto, foi utilizada a somente as áreas de restauração florestal obtidas em (BRASIL, 2020), das quais foi aplicada a equação que obteve melhores resultados estatísticos, por meio da plataforma *Google Earth Engine* (GEE).


3 RESULTADOS

3.1 SELEÇÃO DAS VARIÁVEIS


Como resultado das transformações e índices de vegetação obtidos do satélite Sentinel-2A foram obtidas das imagens 34 variáveis independentes, a correlação entre as mesmas é apresentada na Figura 9A. Observa-se no correlograma que as maiores correlações positivas foram observadas entre a variável dependente Biomassa (AGB) e as independentes: b1, b2, b3, b4, b5, green, hue, pc3 e value. Os maiores valores de correlação negativa foram observados entre as variáveis: NSVDI, B10, brig, pc1, pc2, pc4, pc5 e sat.

A Figura 9B demonstra o correlograma entre as variáveis obtidas por meio do satélite Landsat (variáveis independentes) com a variável dependente, foi observada correlação significativa entre Bio e pc4. Entretanto, as maiores correlações observadas foram negativas, entre a variável dependente e as variáveis B10, B11 e brig. Em nenhum dos correlogramas foram observadas correlações significativas entre a variável dependente (AGB) e os índices de vegetação, utilizando a significação de 95%.

FIGURA 9 – CORRELOGRAMA ENTRE AS VARIÁVEIS INDEPENDENTES E A VARIÁVEL DEPENDENTE (BIOMASSA ACIMA DO SOLO), OS VALORES AUSENTES DEMONSTRAM A FALTA DE SIGNIFICÂNCIA À 95%. A – SENTINEL-2A E B – LANDSAT-8



Ao utilizar técnicas de *Machine Learning* foram obtidos valores referentes ao quadrado médio do erro ao retirar cada uma das variáveis independentes do modelo, desta forma as 10 variáveis obtidas do Sentinel-2A que promoveriam os menores erros médios foram: pc1, ARVI, pc2, pc3, Brig, Green, SR, Hue, value e NSDVI (Figura 10A). Nas variáveis do Landsat-8 as variáveis com maiores importâncias obtidas foram ARVI, Brig, SR, pc2, SAVI, MSAVI2, NSVDI, Sat, NDVI e Wet (Figura 10B).



FONTE: o autor (2021).

Na Tabela 8 são apresentadas as variáveis selecionadas nos três métodos de seleção (*Stepwise*, Correlação e Importância), no método *Stepwise* são selecionados menos variáveis se comparado com os outros métodos. Nas variáveis oriundas do Landsat 8 não foi observada nenhuma variável que foi selecionada pelos três métodos, ao passo que os IV: SAVI, ARVI, MSAVI2 e SR, foram selecionados nos métodos de *Stepwise* e Importância, assim como, Brig, Wet, NSDVI, Sat e pc2 foram selecionadas pela Correlação e Importância. Das variáveis obtidas por meio do Sentinel-2A, somente pc3 e Brig foram selecionadas pelos três métodos, no entanto SR e NSVDI foram selecionadas na Correlação e Importância.

TABELA 8 – VARIÁVEIS SELECIONADAS NOS TRÊS MÉTODOS (STEPWISE, CORRELAÇÃO E VALOR DE IMPORTÂNCIA), PARA OS DADOS OBTIDOS DOS SATÉLITES SENTINEL-2A E LANDSAT-8

Landsat-8	Step.	Correl.	Imp.	Sentinel-2A	Step.	Correl.	Imp.
NDVI			x	NDVI	x		
SAVI	x		x	SAVI	x		
ARVI	x		x	ARVI			x
EVI				EVI			
MSAVI2	x		x	MSAVI2			
SR	x		x	SR		x	x
WDRVI				WDRVI			
BRIG		x	x	BRIG	x	x	x
WET		x	x	WET			
GREEN				GREEN			x
NSVDI		x	x	NSVDI		x	x
HUE				HUE			x
SATURATION		x	x	SATURATIO		x	
VALUE				VALUE	x		x
PC1				PC1			x
PC2		x	x	PC2			x
PC3				PC3	x	x	x
PC4		x		PC4			
PC5		x		PC5			
PC6				PC6			
B1				TBWI		x	
B10		x		B1			
B11		x		B10		x	
B2				B11			
B3				B12			
B4				B2			
B5		x		B3		x	
B6				B4		x	
B7				B5		x	
B8				B6			
B9				B7			
				B8			
				B8A			
				B9			

Onde: Step - Stepwise, Correl – Correlação e Imp – Valor de Importância

FONTE: o autor (2021).

3.2 AJUSTE DAS EQUAÇÕES

A Tabela 9 apresenta os cinco melhores modelos ajustados para cada sensor, nesses, o modelo com melhores resultados estatísticos foi utilizando os dados obtidos

pelo satélite Sentinel-2A, do qual, apresentou maiores coeficientes de determinação R^2 (0,759) e R^2_{aj} (0,772) e menores soma de quadrados (SQE) ($3,69 \times 10^6$), raiz do erro quadrático médio (RMSE) (19.455,41) e qui-quadrado (χ^2) (212,161). O melhor modelo ajustado utilizando os dados referentes ao satélite Landsat obteve as seguintes estatísticas comparativas: R^2 (0,748), R^2_{aj} (0,770), SQE ($1,21 \times 10^5$), RMSE (14,514) e χ^2 (200,882).

TABELA 9 – CINCO MELHORES MODELOS UTILIZANDO AS VARIÁVEIS INDEPENDENTES OBTIDAS POR MEIO DO SATÉLITE SENTINEL-2A E LANDSAT-8

	Modelos	SQE	R^2	R^2_{aj}	Viés	RMSE	S_{yx}	$S_{yx}\%$	χ^2
Sentinel-2A	Bio = (SR x Brig x NSDVI x Value x Pc3)	$3,69 \times 10^6$	0,759	0,772	$1,88 \times 10^{-1}$	19455,41	139,48	9,461	212,16
	Bio = (SR + Brig + NSDVI)/(log(Value ²))	$1,90 \times 10^6$	0,641	0,660	$4,05 \times 10^{-16}$	100071,11	316,34	21,458	1455,47
	Bio = (SR x Brig x (log(NSDVI)))	$2,52 \times 10^6$	0,489	0,516	$1,91 \times 10^{-1}$	132980,85	364,66	24,736	1945,64
	Bio = (Brig/NSDVI) + (SR/Value) + Pc3	$2,65 \times 10^6$	0,461	0,489	$-1,62 \times 10^{-15}$	139938,65	374,08	25,375	2232,21
	Bio = SR x (Brig ²)	$2,91 \times 10^6$	0,433	0,463	$-1,62 \times 10^{-15}$	161348,86	441,03	29,917	2611,66
Landsat-8	Bio = SAVI x ARVI x MSAVI2 x SR x Brig	$3,69 \times 10^6$	0,748	0,770	$4,05 \times 10^{-16}$	19456,95	139,55	9,472	212,88
	Bio = SR x Brig x Wet x NSDVI	$5,28 \times 10^5$	0,727	0,741	$-1,62 \times 10^{-15}$	27831,41	166,82	11,316	335,54
	Bio = (SAVI + ARVI + MSAVI2) ² /(Brig + SR) ²	$1,16 \times 10^6$	0,718	0,723	$-4,05 \times 10^{-16}$	61426,35	247,84	16,812	932,82
	Bio = (exp(SAVI) + exp(ARVI) + exp(MSAVI2) + exp(SR) + exp(Brig))	$1,28 \times 10^5$	0,702	0,718	$-1,21 \times 10^{-16}$	67782,51	260,35	17,660	1120,41
	Bio = (SAVI + ARVI + MSAVI2) / log(SR ²)	$1,40 \times 10^6$	0,676	0,693	$1,21 \times 10^{-15}$	73826,86	271,71	18,431	1158,43

SQE: Soma dos Quadrados do Erro, R^2 : Coeficiente de Determinação, R^2_{aj} : Coeficiente de Determinação ajustado, RMSE: Raiz do Erro Quadrático Médio, e χ^2 : Qui-quadrado.

FONTE: o autor (2021).


3.3 DISTRIBUIÇÃO ESPACIAL DA BIOMASSA NAS ÁREAS EM PROCESSO DE RESTAURAÇÃO

A Figura 11 demonstra a espacialização da biomassa nas áreas em processo de restauração, em 2016 a área abrangida possuía um estoque de biomassa de 237.483.130 t, enquanto em 2020 o estoque foi 375.761.230 t, um acréscimo de 138.278.100 t, aumento de 63,2% em relação ao ano do início dos plantios. Observa-

se que em toda área de abrangência foi acometida por acréscimos nos estoques de biomassa. Foi observado que 2016 a área possui em média $24,71 \text{ t.ha}^{-1}$ e em 2020 foi observado $44,40 \text{ t.ha}^{-1}$ acréscimo de 79,68% (Figura 11A).

As áreas acometidas pelos valores de classe 0,1 a 30 t.ha^{-1} , são abrangidas por vegetação rarefeita ou plantios recentes de restauração, no entanto os valores de 90 a 300 t.ha^{-1} abrangem florestas secundárias em avançado estágio de recuperação que foram pouco alteradas por intervenções antrópicas.


FIGURA 11 – DISTRIBUIÇÃO ESPACIAL DA BIOMASSA DOS ANOS 2016 (A) E 2020 (B)



FONTE: o autor (2021).

A Figura 12 apresenta a diferença entre as distribuições espaciais da biomassa estimada em 2016 em comparação com a de 2020, em 2018 e 2020 foram observadas reduções de 64.348.688 (22%) e 119.066.884 t.ha^{-1} (32%), respectivamente, os aumentos foram observados em 2017 e 2019 com diferenças de 136.694.247 (38%) e 200.571.063 t.ha^{-1} (41%). No entanto as maiores reduções entre os anos 2016 e 2020 se concentraram na região central e sudoeste da área de estudo, ao passo que os aumentos foram observados nas regiões norte e noroeste.

FIGURA 12 – DIFERENÇA ENTRE AS DISTRIBUIÇÕES ESPACIAIS OBTIDAS EM 2016 E 2020



FONTE: o autor (2021).

4 DISCUSSÃO

A análise de correlação é útil para identificar quais variáveis estão relacionadas com a variável dependente, entretanto, foi utilizado neste estudo técnicas de *Machine Learning* para seleção de variáveis que mais se adequam ao modelo por meio do Valor de Importância. Foi observado que a maioria das variáveis derivadas dos sensores Landsat-8 e Sentinel-2A está pouco correlacionada com a biomassa dos plantios de restauração assim como os índices de vegetação. A principal razão para baixa correlação entre as variáveis é a variação na estrutura dos povoamentos, pois os sensores óticos capturam principalmente as informações da copa das árvores assim como informações espectrais a respeito das suas sombras, portanto a informação obtida no pixel há contrastes entre as características das copas e suas sombras.

Na área de estudo, a maioria dos plantios relativos às florestas em restauração possuíam menos de 10 anos, nesta idade, a densidade de mudas e árvores jovens é alta, e elas são responsáveis pela maior parte da biomassa acima do solo (LU; BATISTELLA, 2005; CHAZDON et al., 2016a; NUNES et al., 2020), neste sentido não há estratificação clara entre a copa das árvores e as camadas inferiores do solo. Assim, as assinaturas espectrais dos sensores não podem obter efetivamente as diferenças de biomassa entre locais de florestas maduras e outros tipos florestais em processo de restauração, embora suas quantidades de biomassa variem significativamente. Wu et al. (2020) expõem que as transformações das bandas podem reduzir os impactos das sombras e extraem mais efetivamente as informações de biomassa para as florestas em restauração, aumentando assim as correlações entre os índices e a biomassa florestal, no entanto neste estudo as transformações não foram capazes de aumentar as correlações entre a biomassa e as variáveis obtidas.

Tanto em florestas em estágios mais avançados de sucessão como em florestas em processo de restauração, a biomassa acima do solo e a densidade da vegetação podem variar consideravelmente dependendo das condições do solo, da composição das espécies e da topografia dos locais (VICHARNAKORN et al., 2014; WU et al., 2020). A seleção de índices de vegetação e transformações de bandas adequadas para a estimativa de biomassa e mesmo as que foram escolhidas

utilizando as outras técnicas estatísticas podem não extrair efetivamente informações de biomassa.

Florestas em restauração de até 15 anos não se assemelham espectralmente se comparados com florestas maduras, neste sentido a faixa óptica mais sensível às mudanças de copa das árvores durante a sucessão é a do infravermelho médio, no entanto a reflectância obtida no infravermelho próximo é elevada se comparados entre os estratos florestais, presumivelmente por causa da alta cobertura das folhas da copa das árvores (STEININGER, 2010). Os índices de vegetação derivados dos sensores orbitais têm demonstrado uma boa correlação com a biomassa florestal de áreas homogêneas, como florestas temperadas (GHOSH; BEHERA, 2018), entretanto em áreas com florestas caracterizadas pela heterogeneidade das espécies é observado baixas correlações, independente do sensor utilizado (AKHTAR et al., 2020; HOSSEINI et al., 2021; PANDE et al., 2021).

As áreas onde foram observadas grandes acréscimos de biomassa, dos quais não poderiam ser acumulados em apenas quatro anos são associados a tendências em que os sensores ópticos têm uma sensibilidade limitada para reproduzir a estrutura do dossel de florestas densas, o que pode levar a superestimativa de biomassa, portanto, há uma tendência do modelo de regressão de superestimar a biomassa em áreas com vegetações menos densas e subestimar as condições biomassa em áreas cobertas com florestas mais densas, o que pode levar a estimativas saturadas de biomassa (XIAO, X.; SHEN; QIN, 2001; CASSOL et al., 2019; KENZO et al., 2020).

Nas estimativas em 2020 foi possível notar que houve áreas em que biomassa decresceu em relação a 2016, neste aspecto essas áreas são caracterizadas por uma dinâmica de ocupação pautada na extração de madeiras e implantação da agricultura (principalmente arroz, soja e milho) e pastagem (SILVA; MICHALSKI, 2020; SOUZA et al., 2020). Entretanto, vários projetos de incentivos a manutenção das florestas primárias e implantação e acompanhamento de florestas em processo de restauração vêm sendo difundidos visando a mitigação das degradações que a Amazônia está acumulando ao longo do tempo, contudo a fragmentação das florestas primárias dificulta a criação de corredores entre as florestas secundárias, o que torna a manutenção dessas áreas em processo de restauração muito mais difícil e demorada, demonstrado assim a fragilidade dessa formação florestal perante as pressões antrópicas.

5 CONCLUSÃO

Nas estimativas da biomassa em florestas em restauração, os modelos ajustados utilizando somente os dados espectrais do satélite Sentinel-2A obtiveram métricas estatísticas superiores, se comparados com os modelos utilizando dados do Landsat 8. Neste âmbito, as técnicas de seleção das variáveis independentes foram fundamentais para que fossem ajustados modelos que melhor representassem a variação espacial da biomassa nestes ambientes florestais. A utilização das imagens de satélite com alta resolução espacial, juntamente com diferentes técnicas de modelagem espacial foram essenciais para estimativa da distribuição espacial da biomassa acima do solo.

Os dados orbitais podem ser utilizados para estimativas de biomassa acima do solo, no entanto devem ser observadas características da vegetação, pois os modelos ajustados devem ser utilizados apenas para a vegetação da qual foi ajustado, em caso contrário os erros nas estimativas serão altos e, portanto, não obtendo dados que caracterizem realmente a biomassa de determinada vegetação.

De forma geral, observou-se que a espacialização da biomassa entre os anos 2016 e 2020 apresentou valores condizentes com os dados coletados em campo e os descritos na literatura. Neste sentido, os modelos ajustados podem ser utilizados para simulações e previsões futuras ou pretéritas visando o manejo das áreas em processo de restauração.

REFERÊNCIAS

- AKHTAR, A. M.; QAZI, W. A.; RASHID AHMAD, S.; et al. Integration of high-resolution optical and SAR satellite remote sensing datasets for aboveground biomass estimation in subtropical pine forest, Pakistan. **Environmental Monitoring and Assessment**, 2020. Disponível em: <<https://doi.org/10.1007/s10661-020-08546-1>>. Acesso em: 28/5/2021.
- BOJÓRQUEZ, A.; MARTÍNEZ-YRÍZAR, A.; BÚRQUEZ, A.; et al. Improving the accuracy of aboveground biomass estimations in secondary tropical dry forests. **Forest Ecology and Management**, 15. out. 2020.
- BRASIL, I. D. S. **Dinâmica da fragmentação da Floresta Amazônica no estado de Rondônia**, 2020. Dissertação (Mestrado), Programa de Pós-Graduação em Engenharia Florestal, Universidade Federal do Paraná.
- CASSOL, H. L. G.; CARREIRAS, J. M. DE B.; MORAES, E. C.; et al. Remote sensing Retrieving Secondary Forest Aboveground Biomass from Polarimetric ALOS-2 PALSAR-2 Data in the Brazilian Amazon. **Remote Sensing**, v. 11, p. 59, 2019. Disponível em: <https://doi.org/10.3390/rs11010059>
- CHAVE, J.; RÉJOU-MÉCHAIN, M.; BÚRQUEZ, A.; et al. Improved allometric models to estimate the aboveground biomass of tropical trees. **Global Change Biology**, v. 20, n. 10, p. 3177–3190, 2014. Disponível em: <<https://pubmed.ncbi.nlm.nih.gov/24817483/>>. Acesso em: 29/5/2021.
- CHAZDON, R. L.; BROADBENT, E. N.; ROZENDAAL, D. M. A.; et al. Carbon sequestration potential of second-growth forest regeneration in the Latin American tropics. **Science Advances**, v. 2, n. 5, 2016.
- ELIAS, F.; FERREIRA, J.; LENNOX, G. D.; et al. Assessing the growth and climate sensitivity of secondary forests in highly deforested Amazonian landscapes. **Ecology**, v. 101, n. 3, 2020.
- GHOSH, S. M.; BEHERA, M. D. Aboveground biomass estimation using multi-sensor data synergy and machine learning algorithms in a dense tropical forest. **Applied Geography**, v. 96, n. March, p. 29–40, 2018. Disponível em: <<https://doi.org/10.1016/j.apgeog.2018.05.011>>.
- GUERINI FILHO, M.; KUPLICH, T. M.; QUADROS, F. L. F. D. Estimating natural grassland biomass by vegetation indices using Sentinel 2 remote sensing data. **International Journal of Remote Sensing**, v. 41, n. 8, p. 2861–2876, 2020. Disponível em: <<https://www.tandfonline.com/doi/abs/10.1080/01431161.2019.1697004>>. Acesso em: 29/5/2021.
- HOSSEINI, Z.; LATIFI, H.; NAGHAVI, H.; BAKHTIARVAND BAKHTIARI, S.; FASSNACHT, F. E. Influence of plot and sample sizes on aboveground biomass

estimations in plantation forests using very high resolution stereo satellite imagery. **Forestry**, v. 94, n. 2, p. 278–291, 2021.

HOUGHTON, R. A.; NASSIKAS, A. A. Negative emissions from stopping deforestation and forest degradation, globally. **Global Change Biology**, v. 24, n. 1, p. 350–359, 2018. Disponível em: <<http://doi.wiley.com/10.1111/gcb.13876>>. Acesso em: 8/8/2020.

KENZO, T.; HIMMAPAN, W.; YONEDA, R.; et al. General estimation models for above- and below-ground biomass of teak (*Tectona grandis*) plantations in Thailand. **Forest Ecology and Management**, v. 457, p. 117701, 2020.

LI, X.; WIGNERON, J. P.; FRAPPART, F.; et al. Global-scale assessment and inter-comparison of recently developed/reprocessed microwave satellite vegetation optical depth products. **Remote Sensing of Environment**, v. 253, p. 112208, 2021.

LIMA, R. C.; SARDINHA, M. A.; SOUZA, J. DOS S.; et al. Composition and structure of a stretch of tropical forest in the Eastern Amazon. **Ciência Rural**, v. 51, n. 4, p. 2021. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0103-84782021000400301&lng=en>. Acesso em: 25/3/2021.

LU, D.; BATISTELLA, M. Exploring TM image texture and its relationships with biomass estimation in Rondônia, Brazilian Amazon. **Acta Amazonica**, v. 35, n. 2, p. 249–257, 2005.

MOTLAGH, M. G.; KAFKY, S. B.; MATAJI, A.; AKHAVAN, R. Estimating and mapping forest biomass using regression models and Spot-6 images (case study: Hyrcanian forests of north of Iran). **Environmental Monitoring and Assessment**, v. 190, n. 6, p. 1–14, 2018. Disponível em: <<https://doi.org/10.1007/s10661-018-6725-0>>. Acesso em: 29/5/2021.

NGOMANDA, A.; ENGONE OBIANG, N. L.; LEBAMBA, J.; et al. Site-specific versus pantropical allometric equations: Which option to estimate the biomass of a moist central African forest? **Forest Ecology and Management**, v. 312, p. 1–9, 2014.

NUNES, S. MIA; OLIVEIRA, L.; SIQUEIRA, J. O.; MORTON, D. C.; SOUZA, C. M. Unmasking secondary vegetation dynamics in the Brazilian Amazon. **Environmental Research Letters**, v. 15, n. 3, p. 034057, 2020. Disponível em: <<https://doi.org/10.1088/1748-9326/ab76db>>. Acesso em: 25/4/2021.

PANDE, C. B.; MOHARIR, K. N.; SINGH, S. K.; et al. Estimation of crop and forest biomass resources in a semi-arid region using satellite data and GIS. **Journal of the Saudi Society of Agricultural Sciences**, 2021. Disponível em: <<https://doi.org/10.1016/j.jssas.2021.03.002>>. Acesso em: 28/5/2021.

POORTER, L.; BONGERS, F.; AIDE, T. M.; et al. Biomass resilience of Neotropical secondary forests. **Nature**, v. 530, n. 7589, p. 211–214, 2016. Disponível em: <<http://www.nature.com/articles/nature16512>>. Acesso em: 24/4/2021.

ROCHA, R.; OVASKAINEN, O.; LÓPEZ-BAUCELLS, A.; et al. Secondary forest regeneration benefits old-growth specialist bats in a fragmented tropical landscape. **Scientific Reports**, n. 8, v. 1, p. 3819. 2018. Disponível em: <https://doi.org/10.1038/s41598-018-21999-2>

SILVA, R. G. DA C.; MICHALSKI, A. A caminho do Norte: cartografia dos impactos territoriais do agronegócio em Rondônia (Amazônia ocidental). **Confins**, n. 45, 2020. Disponível em: <<http://journals.openedition.org/confins/28017>>. Acesso em: 28/5/2021.

SINHA, S.; SHARMA, L. K.; NATHAWAT, M. S. Improved Land-use/Land-cover classification of semi-arid deciduous forest landscape using thermal remote sensing. **Egyptian Journal of Remote Sensing and Space Science**, v. 18, n. 2, p. 217–233, 2015.

SOUZA, A. DE; MOURA, V.; SILVA, G.; et al. O Desmatamento na Amazônia Legal Brasileira: Case Região do Cone-Sul de Rondônia Deforestation in the Brazilian Legal Amazon : Case of the Southern Cone of Rondônia. **Revista UD Y la Geomática**, n. 15, p. 50–58, 2020.

STEININGER, M. K. Satellite estimation of tropical secondary forest above-ground biomass: Data from Brazil and Bolivia. **International Journal of Remote Sensing**, v. 21, p. 1139–1157, 2010.

TEIXEIRA, H. M.; CARDOSO, I. M.; BIANCHI, F. J. J. A.; et al. Linking vegetation and soil functions during secondary forest succession in the Atlantic forest. **Forest Ecology and Management**, v. 457, n. October 2019, p. 117696, 2020. Elsevier. Disponível em: <<https://doi.org/10.1016/j.foreco.2019.117696>>.

TRIPATHI, P.; PATEL, N. R.; KUSHWAHA, S. P. S. Estimating net primary productivity in tropical forest plantations in India using satellite-driven ecosystem model. **Geocarto International**, v. 33, n. 9, p. 988–999, 2018. Disponível em: <<https://www.tandfonline.com/doi/abs/10.1080/10106049.2017.1323963>>. Acesso em: 24/4/2021.

VICHARNAKORN, P.; SHRESTHA, R. P.; NAGAI, M.; SALAM, A. P.; KIRATIPRAYOON, S. Carbon stock assessment using remote sensing and forest inventory data in Savannakhet, Lao PDR. **Remote Sensing**, v. 6, n. 6, p. 5452–5479, 2014.

VIRGULINO-JÚNIOR, P. C. C.; CARNEIRO, D. N.; NASCIMENTO, W. R.; COUGO, M. F.; FERNANDES, M. E. B. Biomass and carbon estimation for scrub mangrove forests and examination of their allometric associated uncertainties. (M.-H. Li, Org.). **PLOS ONE**, v. 15, n. 3, p. e0230008, 2020. Disponível em: <<https://dx.plos.org/10.1371/journal.pone.0230008>>. Acesso em: 24/4/2021.

WANG, R.; GAMON, J. A.; EMMERTON, C. A.; et al. Detecting intra- and inter-annual variability in gross primary productivity of a North American grassland using MODIS MAIAC data. **Agricultural and Forest Meteorology**, v. 281, n. November

2019, p. 107859, 2020. Disponível em:
<<https://doi.org/10.1016/j.agrformet.2019.107859>>.

WU, J.; CHEN, B.; REYNOLDS, G.; et al. **Monitoring tropical forest degradation and restoration with satellite remote sensing: A test using Sabah Biodiversity Experiment**. 1o ed. Elsevier Ltd., 2020.

XIAO, X.; SHEN, Z.; QIN, X. Assessing the potential of VEGETATION sensor data for mapping snow and ice cover: A Normalized Difference Snow and Ice Index. **International Journal of Remote Sensing**, v. 22, n. 13, p. 2479–2487, 2001.

YANG, Y.; SAATCHI, S.; XU, L.; et al. Interannual Variability of Carbon Uptake of Secondary Forests in the Brazilian Amazon (2004-2014). **Global Biogeochemical Cycles**, v. 34, n. 6, 2020. Disponível em:
<<https://onlinelibrary.wiley.com/doi/10.1029/2019GB006396>>. Acesso em: 24/3/2021.

ZUMO, I. M.; HASHIM, M.; HASSAN, N. D. Mapping grass above-ground biomass of grazing-lands using satellite remote sensing. **Geocarto International**, 2021. Disponível em:
<<https://www.tandfonline.com/doi/abs/10.1080/10106049.2021.1899309>>. Acesso em: 29/5/2021.

CAPÍTULO III: DIRETRIZES PARA RESTAURAÇÃO DA FLORESTA AMAZÔNICA: DETECÇÃO AUTOMÁTICA DE ESPÉCIES A PARTIR DE IMAGENS UAV¹

RESUMO

Avaliações precisas da composição das espécies florestais podem ser utilizadas para analisar padrões de biodiversidade, estimar estoques de madeira e melhorar as estimativas de carbono estocado. Portanto, o objetivo deste trabalho foi avaliar a utilização de imagens de alta resolução obtidas por *Unmanned Aerial Vehicle* (UAV) na identificação de espécies florestais em áreas de regeneração florestal na Amazônia. As redes neurais convolucionais (CNN) foram treinadas utilizando o pacote *Keras-Tensorflow* com o modelo *faster_rcnn_inception_v2_pets*. Amostras de seis espécies florestais foram utilizados para treinar a CNN, a partir destas, foram realizados testes com o número de *thresholds* e identificação das espécies confrontando os resultados obtidos com dados obtidos em campo. Os resultados demonstraram que a redução do *threshold* diminui a exatidão na identificação, assim como a sobreposição dos polígonos de identificação das espécies, no entanto, em comparação com os dados coletados em campo, observa-se que há uma alta correlação entre as árvores identificadas pela CNN e às observadas nas parcelas. As métricas estatísticas utilizadas para validar as classificações evidenciaram que a CNN é capaz de identificar as espécies com acurácia acima de 90%. Portanto, as redes neurais convolucionais é uma ferramenta eficaz na classificação de objetos em imagens UAV, demonstrando boa acurácia e precisão na identificação das espécies em estudo.

Palavras-chave: *Deep learning*. Drone. Identificação Florestal

¹ Capítulo publicado na revista *Remote Sensing*. Towards Amazon Forest Restoration: Automatic Detection of Species from UAV Imagery. *Remote Sensing*, v. 13, p. 2627, 2021. doi.org/10.3390/rs13132627

ABSTRACT

Precise assessments of forest species composition can be used to analyze biodiversity patterns, estimate wood stock and improve stock carbon estimates. Therefore, the objective of this work was to evaluate the use of high-resolution images obtained by Unmanned Aerial Vehicle (UAV) in the identification of forest species in areas of forest regeneration in the Amazon. Convolutional neural networks (CNN) were trained using the *Keras-Tensorflow* package with the *faster_rcnn_inception_v2_pets* model. Samples of six forest species were used to train CNN, from these, tests were performed with the number of thresholds and species identification comparing the results obtained with field data. The results showed that the reduction of the threshold decreases the accuracy of identification, as well as the overlap of the polygons of species identification, however, in comparison with the data collected in the field, it is observed that there is a high correlation between the trees identified by the CNN and those observed in the plots. The statistical metrics used to validate the classifications showed that the CNN is able to identify species with accuracy above 90%. Therefore, convolutional neural networks are an effective tool in classifying objects in UAV images, demonstrating good accuracy and precision in the identification of species under study.

Keywords: Deep learning. Drone. Forest identification

1 INTRODUÇÃO

Sensores ópticos acoplados em *Unmanned Aerial Vehicle* (UAV) são comumente utilizados para aquisição de características geométricas da floresta, como altura e diâmetro das copas das árvores. Adicionalmente, além de informações quantitativas, esses sensores podem gerar atributos qualitativos sobre os ambientes florestais potencializando a possibilidade de caracterização de espécies florestais.

No entanto, para tal caracterização, apenas as ferramentas tradicionais de processamento de imagens obtidas por UAV, não tem se mostrado eficazes (CASAPIA et al., 2020; NATESAN; ARMENAKIS; VEPAKOMMA, 2020), de tal maneira que ainda são necessários testes e implementação de ferramentas adicionais ao processamento dessas imagens. Neste âmbito, as Redes Neurais Convolucionais (ou, em inglês, *Convolutional Neural Networks* – CNN) têm sido amplamente utilizadas em detecções de objetos diversos (CAO; CHEN; GAO, 2020; PI; NATH; BEHZADAN, 2020; WU, Y. et al., 2020; YAO; HU; LEI, 2020; ZHANG et al., 2020) e também na caracterização de ambientes florestais (FROMM et al., 2019; SYRRIS et al., 2019; QIAO et al., 2020; ROSLAN et al., 2020; XIAO; QIN; HUANG, 2020).

CNNs são consideradas como um modelo matemático de classificação inspirado no sistema biológico de processamento de dados visuais. Na literatura, esses algoritmos dispõem de resultados satisfatórios para uma diversidade de problemas envolvendo imagens, incluindo classificação vegetal. Estas classificações utilizam descritores morfológicos como folhas, caule, flores ou frutos (TASHAKKORI; PARRY, 2015; GU et al., 2018; JASSMANN).

A realização de inventários com sensores remotos e, conseqüentemente a composição das espécies florestais utilizando uma plataforma de imagens ao invés de levantamentos de campo, acarreta na redução de custos e tempo de aquisição, além de favorecer a análise da composição das espécies em grandes extensões territoriais (WULDER, 1998; SILVA et al., 2018; HYYPPÄ et al., 2000). Avaliações precisas da composição das espécies de florestas promovem um ganho na pesquisa e administração dessas áreas, uma vez que se pode utilizar esse conhecimento para analisar padrões de biodiversidade, estimar estoques de madeira e melhorar as estimativas de carbono estocado.

Entretanto, em uma revisão sobre classificação de espécies florestais Fassnacht et al. (2016), evidenciou que o mapeamento de árvores individuais a partir

de imagens de sensoriamento remoto é um desafio, principalmente devido à falta de (1) imagens espaciais e espectrais de alta resolução; (2) classificadores de aprendizagem de máquinas sensíveis sofisticados o suficiente para identificar a iluminação, forma, tamanho e padrão das árvores, copas e folhas, bem como a mistura espectral nas próprias copas; e (3) dados espaciais precisos para treinar os classificadores. Contudo, essas dificuldades estão sendo resolvidas aos poucos, com o advento de novas tecnologias, sobretudo as imagens de alta resolução espacial obtidas por meio dos UAVs.

As imagens UAV possuem qualidade adequada para análise e caracterização de áreas florestais (plantadas ou nativas). Por este motivo têm sido amplamente utilizados em detrimento da sua versatilidade e facilidade na aquisição de dados em grandes áreas. Além disso, estas imagens também são utilizadas como suporte no monitoramento e análise visual da vegetação, sobretudo em áreas de florestas nativas e em processo de regeneração na Amazônia legal.

Neste contexto, o sensoriamento remoto está sendo aprimorado continuamente, mas novas ferramentas de classificação são necessárias para preencher a lacuna entre imagens de sensoriamento remoto e a necessidade de informações de alta resolução sobre as florestas. Portanto, o objetivo deste trabalho foi testar o desempenho de imagens de alta resolução obtidas por UAV para a identificação de espécies florestais em áreas de plantio de restauração florestal na Amazônia através da aplicação de algoritmo de aprendizado de máquinas.

2 MATERIAL E MÉTODOS

2.1 AQUISIÇÃO E PRÉ-PROCESSAMENTO DAS IMAGENS

As imagens foram adquiridas por um UAV *DJI Phantom 4 pro*, utilizando uma câmera RGB, suas características principais estão descritas na TABELA 100. As imagens foram obtidas em novembro de 2017, 2018 e 2019, sempre das 8 h às 15 h aproveitando a iluminação solar e reduzindo o sombreamento das imagens.

TABELA 10 - CARACTERÍSTICAS DAS IMAGENS OBTIDAS DO UAV *DJI PHANTOM 4 PRO*

Denominação	Tipo
Largura	5.472 pixels
Altura	3.648 pixels
Modelo da câmera	FC6310
Tempo de exposição	1/400 s
Valor da abertura	4,97EV (f/5,6)
Taxa de velocidade (ISO)	100
Resolução do pixel	2,2 cm
Tipo da imagem	.jpeg
Distância focal	8,8 mm

FONTE: o autor (2021).

As imagens foram processadas no software *Pix4D mapper*, com intuito de confeccionar o ortomosaico das áreas em questão. Salienta-se que não foram realizadas quaisquer correções de tonalidade e contrastes nas imagens brutas ou mosaicos finais.

Cecropia juranyiana C.Mart (Urticaceae) é uma espécie pioneira amplamente encontrada em áreas florestais que foram antropizadas e em florestas secundárias. Tem uma altura média de 15 m, e folhas folioladas com até 14 folíolos (BERG, 1978). *Hymenaea courbaril* L. (Fabaceae) é uma árvore semi-caducifolia, de até 35 m de altura e 80 cm de diâmetro, com folhas compostas com 2 folíolos e uma copa larga (CNCFLORA, 2012; PINTO; TOZZI; MANSANO, 2020). *Bauhinia acreana* Harms (Fabaceae) é uma espécie com uma copa larga com folhas bilobadas e frutos deiscentes um forma de vagem (VAZ, 2020). *Anacardium occidentale* L. (Anacardiaceae) é uma árvore de até 10 m de altura e 40 cm de diâmetro, com uma copa larga e folhas pecioladas simples, que podem mudar sua coloração de acordo

com a época do ano, com folhas mais jovens rosa e verdes para as folhas maduras (LORENZI, 2000; SILVA-LUZ et al., 2020). *Handroanthus serratifolius* (Vahl) S. Grooe (Bignoneaceae) é uma árvore de até 30 m de altura, 80 cm de diâmetro, com folhas palmáceas, com 5 - 7 lóbulos e uma margem serrilhada. Nos meses de floração, a espécie permanece apenas com flores (HARRI LORENZI, 2014; LOHMANN, 2020). *Anadenanthera* sp. Speg (Fabaceae) atinge cerca de 25 m de altura, com folhas compostas (LORENZI, 2000; MORIM, 2020).

2.2 TREINAMENTO DAS REDES NEURAIS CONVOLUCIONAIS

As 683 árvores (amostras) foram inseridas no software *Labelimg*, o qual possibilita a seleção da região de interesse por meio de polígonos que podem ter formas retangulares e quadradas (subamostras). Ao todo foram obtidas 2.437 subamostras (Tabela 11), sendo que para alcançar tal número foi necessário a seleção de subamostras de uma mesma árvore, de modo que em um único indivíduo eram selecionadas a maior quantidade de amostras possíveis, a depender do tamanho da copa (Figura 13).

FIGURA 13 – REPRESENTAÇÃO DA SELEÇÃO DE AMOSTRAS EM UM INDIVÍDUO. O POLÍGONO VERMELHO REPRESENTA A CÔPA DA ÁRVORE (*Handroanthus* spp.) E OS RETÂNGULOS AMARELOS REPRESENTAM AS SUBAMOSTRAS OBTIDAS PARA ESTA ESPÉCIE




FONTE: o autor (2021).

As amostras possuem diferentes tamanhos, no entanto, a CNN faz o mesmo ajuste para todas as imagens em série, mesmo que sejam de tamanhos diferentes; a rede neural faz a identificação usando todos os parâmetros referentes às amostras selecionadas, textura, contraste, intensidade de cor, brilho, padrões de brilho e sombra, valores de brilho e sombras são minimizados nas camadas internas da rede neural; ou seja, as amostras são padronizadas internamente com o objetivo de mitigar estes fatores. Independentemente do tamanho da amostra, as transformações que a CNN faz internamente são apresentadas na Figura 14. A partir das características

apresentadas (forma, textura, brilho, contraste etc.), é possível distinguir entre as espécies em estudo na rede.

FIGURA 14 – REPRESENTAÇÃO DAS TRANSFORMAÇÕES REALIZADAS INTERNAMENTE NA CNN PARA A ESPÉCIE *Cecropia juranyiana* C.MART (URTICACEAE)



FONTE: o autor (2021).

Ao final do processo de seleção das amostras, o *software* fornece um arquivo no formato .csv, contendo: nome do arquivo, altura, largura, classe, xmin, xmax, ymin e ymax (TZUTALIN, 2020). A partir do arquivo .csv oriundo do *Labelimg* foi possível criar aleatoriamente dois conjuntos de amostras, sendo eles: Treino (70%, ou seja, 1.706 amostras) e Teste (30%, ou seja, 731 amostras). Para a validação foram separados das amostras de Treino 487 imagens para serem aplicadas na Validação, garantido assim que o modelo não apresentasse *Overfitting* (Tabela 11).

TABELA 11 – ESPÉCIES FLORESTAIS UTILIZADAS E QUANTIDADE DE AMOSTRAS PARA O TREINAMENTO DAS REDES CONVOLUCIONAIS

Espécies	Amostras (n)	Subamostras (n)	
	Árvores	Teste (30%)	Treino (70%)
<i>Cecropia</i> spp.	157	158	369
<i>Hymenaea</i> spp.	102	126	294
<i>Bauhinia</i> spp.	96	108	252
<i>Anacardium</i> spp.	90	80	186
<i>Handroanthus</i> spp.	106	116	270
<i>Anadenanthera</i> spp.	132	144	336
Total	683	731	1706

Onde: n = número de árvores de cada espécie.

FONTE: o autor (2021).

Para implementação das redes neurais convolucionais foi utilizada a linguagem computacional *Py2hon*, com o pacote *Keras-TensorFlow*. Esse sistema de código aberto do Google é utilizado e implementando nos algoritmos de aprendizagem de redes neurais. Neste pacote foi inserido o modelo *faster_rcnn_inception_v2_pets*, o qual foi modificado para treinar as amostras das espécies alvo.

A rede neural aprende os padrões a partir dos dados de entrada lendo o conjunto de dados de entrada e aplicando diferentes cálculos a ele. Entretanto, a rede neural não faz isso apenas uma vez; ela aprende repetidamente usando o conjunto de dados de entrada e também os resultados de testes anteriores. Cada passo no aprendizado a partir do conjunto de dados de entrada é chamado de Época. Ou seja, uma época refere-se a um ciclo em todo o conjunto de dados de treinamento (TAQI et al., 2018; FRANKLE; SCHWAB; MORCOS, 2020). Inicialmente, a CNN foi treinada com um grande número de épocas (iterações) para garantir que a menor perda estaria dentro dessa faixa de etapas. Após o primeiro treinamento, determinamos um número ideal de etapas para obter a menor perda para otimizar as análises e repetições que seriam realizadas; este teste serviu fundamentalmente para saber quantas épocas seriam necessárias para o ajuste final do modelo; esta etapa foi essencial porque um número excessivo de épocas leva o modelo a se ajustar em excesso, ou seja, neste caso, ele apresentará resultados com métricas estatísticas muito boas, mas com identificação errônea de espécies.

Portanto, os testes foram realizados reduzindo ou aumentando os limites que são funções que limitam os resultados da saída da CNN. Valores iguais a 1 sugerem identificação máxima nas saídas do modelo, o que pode levar à identificação de espécies que não são reconhecidas no campo, e valores de 0 sugerem nenhuma identificação de qualquer espécie, portanto, o ajuste manual do Limiar é essencial

para o ajuste fino da saída do modelo, evitando que as saídas apresentem resultados que serão considerados falso-positivos. Após o treinamento inicial, foi observado que a modificação do limiar resultou no não reconhecimento de algumas espécies ou falso reconhecimento. Isto levou a um modelo de treinamento com variação no número de espécies e limiares. Todos os resultados foram comparados com os dados de campo para obter um modelo que melhor refletisse as condições reais da área estudada. Estes limiares modificam a saída de acordo com os limites de entrada. A rede recebe entradas, então aplica uma combinação linear e, se essa combinação for maior ou menor que o valor limite especificado, produzirá uma saída de 1 ou 0, respectivamente. Portanto, os resultados com probabilidades baixas seriam rejeitados. A Equação (7) representa a função limite, onde Sigma (Σ) é a soma dos pares de entrada (x) e peso (w).

$$\text{Saída} = \begin{cases} 0 & \text{se } \sum_i w_i x_i < \text{Threshold} \\ 1 & \text{se } \sum_i w_i x_i \geq \text{Threshold} \end{cases} \quad (7)$$

2.3 VALIDAÇÃO DA CLASSIFICAÇÃO

A validação das classificações foi realizada no conjunto de dados para o teste. Para isto, foram utilizadas métricas estatísticas para avaliar e testar o desempenho da CNN ajustada. As métricas são especificadas na Tabela 12, das quais são calculadas de acordo com os resultados das classificações. O índice Kappa é uma medida de concordância utilizada em escalas nominais que fornece uma ideia de quão distante as observações se desviam daquelas esperadas, ao acaso, indicando-nos, assim, quão legítimas são as interpretações. Ele mede a porcentagem dos valores dos dados na diagonal principal da tabela e depois ajusta esses valores para a quantidade de concordância que pode ser esperada (COHEN, 1960). A exatidão é um índice que reflete a taxa na qual os indivíduos são corretamente classificados na categoria que contém sua pontuação verdadeira. A precisão de classificação é geralmente atribuída ao grau de adequação e validade de suas decisões, com base na pontuação obtida. Um valor grande para o índice indica uma alta taxa de acerto dos indivíduos nas categorias corretas, e um valor baixo indica uma taxa mais baixa de classificação correta dos indivíduos (SAMMUT; WEBB, 2010).

TABELA 12 – ÍNDICES ESTATÍSTICOS UTILIZADOS PARA VERIFICAÇÃO DA CLASSIFICAÇÃO

Índice Estatístico	Fórmula	Descrição	Referência
Kappa	$\text{Kappa} = \frac{\text{ACC}_{\text{overall}} - \text{RACC}_{\text{overall}}}{1 - \text{RACC}_{\text{overall}}}$	Varia de 1 a -1, onde 1 indica uma classificação perfeita e -1 representa uma classificação não confiável	Cohen, (1960)
Acurácia	$\text{ACC} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}}$	Número de classificações corretas de todas as predições realizadas	Sammur and Webb, (2010)
<i>F-score</i> ajustado	$\text{AGF} = \sqrt{\left[5 \times \frac{\text{PPV} \times \text{TPR}}{(4 \times \text{PPV}) + \text{TPR}} \right] \times \left[(1 + 0.5^2) \times \frac{\text{NPV} \times \text{TNR}}{(0.5^2 \times \text{NPV}) + \text{TNR}} \right]}$	Utilizada para usar todos os elementos da matriz de confusão e fornecer mais pesos às amostras que estão corretamente classificadas na menor classe.	Maratea et al. (2014)
Coeficiente de Correlação de Mathews	$\text{MCC} = \frac{\text{TP} \times \text{TN} - \text{FP} \times \text{FN}}{\sqrt{(\text{TP} + \text{FP}) \times (\text{TP} + \text{FN}) \times (\text{TN} + \text{FP}) \times (\text{TN} + \text{FN})}}$	Coeficiente de correlação de classificações binárias observadas e previstas, onde: Negligenciável - < 0.3 Fraco - 0.3 – 0.5 Moderado - 0.5 – 0.7 Forte - 0.7 – 0.9 Muito forte - > 0.9	Matthews, (1975)
Similaridade	$\text{sInd} = 1 - \sqrt{\frac{(1 - \text{TNR})^2 + (1 - \text{TPR})^2}{2}}$	Varia de 0 a 1, onde: 0 - sem classificações corretas 1 - classificação perfeita	Ballabio et al., (2018)

Onde, $\text{ACC}_{\text{overall}}$: conformidade relativa observada entre os classificadores; $\text{RACC}_{\text{overall}}$: conformidade hipotética de probabilidade utilizando os dados observados para calcular as probabilidades de cada classificador identificar aleatoriamente cada categoria; TP: verdadeiro positivo; TN: verdadeiro negativo; FP: falso positivo; FN: falso negativo; PPV: valor preditivo positivo; TPR: taxa positiva verdadeira; NPV: valor preditivo negativo; TNR: verdadeira taxa negativa.

FONTE: o autor (2021).


O *F-score* ajustado é um índice que agrupa todos os elementos da matriz de confusão original e dá mais peso a padrões corretamente classificados em classes corretamente classificadas (FRANKLE; SCHWAB; MORCOS, 2020). O Coeficiente de Correlação Matthews tem um intervalo de -1 a 1, e quando tem um valor -1, indica um classificador binário completamente errado, enquanto 1 indica um classificador binário completamente correto. Este índice permite avaliar o desempenho de seu modelo de classificação (TAQI et al., 2018), enquanto a similaridade é uma métrica que varia de 0 (classificação errada) a 1 (classificação perfeita) calculada a partir das médias das classificações das classes de interesse (COHEN, 1960).

3 RESULTADOS

A partir dos testes iniciais utilizando a CNN, o treinamento com seis espécies e um limiar variável, foi observado que um aumento ou redução no parâmetro de limiar interferia na precisão de caracterização das espécies. Neste sentido, com este parâmetro igual a 0,9, a precisão das taxas de reconhecimento das espécies foi maior; entretanto, neste caso, apenas duas espécies foram identificadas. Quando o mesmo valor foi reduzido para 0,8, a rede identificou três espécies; o mesmo aconteceu para 0,7 e 0,6 (Figura 15). A diminuição do limiar reduziu a precisão da identificação, assim como a sobreposição de polígonos de identificação de espécies. Entretanto, ao comparar os resultados obtidos pela rede neural e os dados de campo, observamos uma relação entre as árvores identificadas pela CNN e aquelas observadas no campo. Além disso, observamos maior incerteza de classificação nas áreas com mais sombras ou sobreposição das copas em comparação com as espécies com copas mais altas e sem sombra.


A Figura 16. mostra a perda na inserção da espécie, onde 1 espécie: *C. juranyiana*; 2 espécies: *C. juranyiana* + *H. courbaril*; 3 espécies: *C. juranyiana* + *H. courbaril* + *B. acreana*; 4 Espécies: *C. juranyiana* + *H. courbaril* + *B. acreana* + *A. occidentale*; 5 espécies: *C. juranyiana* + *H. courbaril* + *B. acreana* + *A. occidentale* + *H. serratifolius*; 6 espécies: *C. juranyiana* + *H. courbaril* + *B. acreana* + *A. occidentale* + *H. serratifolius* + *Anadenanthera* sp. No início do treinamento, a perda era alta e diminuía a cada época até atingir o valor mais baixos. A partir deste ponto, a perda começou a aumentar, mostrando ajustes com pouca precisão no reconhecimento das espécies (Figura 16). A partir deste primeiro treinamento, observamos que o reconhecimento de apenas 1 espécie, 2 espécies, 3 espécies, 4 espécies, 5 espécies e 6 espécies exigia 494, 541, 892, 976, 993, e 1042 épocas, respetivamente. Além disso, ao mudar o limiar, e incluindo mais espécies (caraterísticas), o tempo de treinamento da rede foi relativamente aumentado, tornando este processo mais demorado.

FIGURA 15 – APLICAÇÃO DO MODELO INCLUINDO AS 6 ESPÉCIES NO TREINAMENTO, SENDO: A - *THRESHOLD* = 0.9, B - *THRESHOLD* = 0.8, C - *THRESHOLD* = 0.7, D - *THRESHOLD* = 0.6



FONTE: o autor (2021).


FIGURA 16 – VARIAÇÃO DA PERDA EM RELAÇÃO ÀS ÉPOCAS E QUANTIDADE DE ESPÉCIES UTILIZADAS NO TREINAMENTO



FONTE: o autor (2021).

A Figura 17 demonstra a variação da perda na validação do modelo ajustado utilizando todas as espécies. Tal modelo convergiu ao seu menor valor de perda com 439 épocas, demonstrando que com essa quantidade é possível identificar nas imagens oriundas do UAV as 6 espécies utilizadas para o treinamento.


FIGURA 17 – VARIAÇÃO DA PERDA DO MODELO AJUSTADO COM AS 6 ESPÉCIES



FONTE: o autor (2021).

A Figura 18 demonstra a localização das árvores nas parcelas bem como a funcionalidade do modelo em localizar as árvores, foi observado que árvores com copas que possuem maior perímetro são mais facilmente localizadas ao comparar com as menores. O falso reconhecimento está associado com a sobreposição das copas ou a semelhança entre as características foliares. Árvores com menores circunferências de copa são mais acuradas na identificação do gênero pelo modelo, enquanto copas com folhagem menos densas o modelo não identifica as espécies em estudo ou classifica de forma errônea. Copas que possuem folhas com um contraste (brilho, cor) maior em relação às demais são identificadas com maior acurácia, no entanto, foi observado que algumas árvores que possuem alguma discrepância em relação à folhagem ou à copa das árvores do mesmo gênero houve maior taxa de erro na classificação.

FIGURA 18 – LOCALIZAÇÃO DAS ÁRVORES NAS PARCELAS E UTILIZANDO O MODELO DE RECONHECIMENTO DAS ESPÉCIES



FONTE: o autor (2021).

Observou-se que o treinamento com o *threshold* = 0,7, apresentou resultados satisfatórios em relação ao tempo de processamento e reconhecimento das espécies, portanto, foi utilizado esse valor para o cálculo da matriz de confusão com todas as espécies, obtendo uma exatidão global de 91,80%. Houve falsos reconhecimentos das características em todas as espécies, contudo, o maior erro de classificação (falso positivo) concentrou-se entre a *Cecropia* sp. e *Handroanthus* sp. com a *Bauhinia* sp., na qual houve falsa caracterização em 26 ocasiões (Tabela 13).

A matriz de confusão demonstrou que os menores valores observados para a acurácia do produtor e usuário foram respectivamente 79,76% e 87,01%, para a *Bauhinia* sp. Contudo, os maiores valores observados para a acurácia do produtor foram das espécies *Cecropia* sp. (96,48%) e *Hymenaea* sp. (95,58%) e para a acurácia do usuário, *Hymenaea* sp. (94,30%) e *Anadenanthera* sp. (93,81%).

TABELA 13 – MATRIZ DE CONFUSÃO COM INSERÇÃO DAS 6 ESPÉCIES NA REDE NEURAL CONVOLUCIONAL COM THRESHOLD = 0.7

	<i>Cecropia</i>	<i>Hymenaea</i>	<i>Bauhinia</i>	<i>Anacardium</i>	<i>Handroanthus</i>	<i>Anadenanthera</i>	Total	Usuário
<i>Cecropia</i>	356	0	26	4	0	0	386	92,23%
<i>Hymenaea</i>	0	281	0	0	5	12	298	94,30%
<i>Bauhinia</i>	4	12	201	4	5	5	235	87,01%
<i>Anacardium</i>	4	0	8	171	0	1	184	92,93%
<i>Handroanthus</i>	0	1	12	7	240	9	269	89,22%
<i>Anadenanthera</i>	5	0	5	0	11	318	335	93,81%
Total	369	294	252	186	261	345	1.707	-
Produtor	96,48%	95,58%	79,76%	91,94%	91,95%	92,17%	-	1.567
Exatidão Global	91,80%							

FONTE: o autor (2021).

Na Tabela 14 são demonstrados todos os índices estatísticos utilizados para validação das classificações, o índice Kappa calculado foi de 0,9006, o que indica boa classificação, resultados semelhantes foram verificados nas métricas de Acurácia, *F-score* ajustado e Similaridade. Contudo, na correlação de Matthews as espécies *Bauhinia* sp. e *Handroanthus* sp. obtiveram classificação forte, enquanto para as demais espécies esta estatística foi muito forte, assim como na Sensitividade as mesmas espécies obtiveram resultados abaixo de 0,9.

TABELA 14 – ESTATÍSTICAS OBTIDAS NO PROCESSO DE CLASSIFICAÇÃO DO CONJUNTO DE DADOS DO TREINAMENTO

Índice	<i>Cecropia</i>	<i>Hymenaea</i>	<i>Bauhinia</i>	<i>Anacardium</i>	<i>Handroanthus</i>	<i>Anadenanthera</i>
Kappa				0,9006		
Acurácia	0,9748	0,9824	0,9525	0,9836	0,9707	0,9718
<i>F-score</i> Ajustado	0,9706	0,9667	0,9135	0,9587	0,9594	0,9589
Correlação de Matthews	0,9272 ¹	0,9387 ¹	0,8057 ²	0,9151 ¹	0,8884 ²	0,9123 ¹
Similaridade	0,9222	0,9429	0,8701	0,9293	0,8921	0,938

¹ - Muito forte e ² - Forte

FONTE: o autor (2021).

4 DISCUSSÃO

O reconhecimento de espécies ou gêneros florestais em campo ou utilizado as técnicas de sensoriamento remoto é um grande desafio para pesquisadores da área florestal. No entanto, as particularidades relacionadas com a estrutura da copa e folhas (características dendrométricas) das espécies foram determinantes para boa acurácia do modelo.

Como relatado em Ferreira et al. (2019), as características das copas influenciam diretamente no classificador, *Cecropia* e *Bauhinia* possuem as menores perímetros de copas das espécie em estudo, contudo, os indicadores estatísticos demonstraram resultados acima de 0,9, pois, sua copa possui uma desuniformidade em relação aos galhos e folhas. *Hymenaea* e *Anadenanthera* possuem folhas menores e copas mais amplas, destacando-se em relação as demais. *Anacardium* e *Handroanthus*, possuem maior quantidade de folhas e copas que também se destacam no dossel da floresta, e por isso, o classificador foi eficientemente capaz de distingui-los das demais.

Em comparação à experimentos realizados em ambientes com menos espécies arbóreas, tais como Fromm et al. (2019) e Mubin et al. (2019), as métricas de classificação foram superiores se comparados com este estudo, pois, há menores possibilidades de confusão nas características das espécies. No entanto, limitados trabalhos têm relatado suas experiências em detecção de objetos em relação à seleção do *threshold*, Freudenberg et al. (2019) utilizou tal parâmetro com valor 0,5 para detecção de palmeiras, resultando em um *F-score* variando de 0,875 a 0,957, valores próximos aos observados nesta pesquisa.

Neste âmbito, Gollob et al. (2019) compararam a altura do sensor com a variação do *threshold* na predição de variáveis dendrométricas, os autores concluíram que com o aumento da distância do sensor em relação ao objeto alvo, era necessário retrainar a CNN com aumento do *threshold*, assim obtiveram resultados melhores na acurácia e erro. Wang et al. (2019), relata que não há valor predeterminado deste limiar e argumenta que o valor mais adequado depende diretamente da base de dados e método computacional utilizado.

Ao analisar as classificações com diferentes *thresholds*, os resultados demonstraram uma sobreposição dos polígonos de detecção da CNN, resultado semelhante foi observado por Sarabia et al. (2020) e Xiong et al. (2020), nestes

trabalhos foram relatados problemas na interpretação das bordas das árvores em relação às vizinhas. Por este motivo, a redução do valor do *threshold* foi crucial para que esta incerteza fosse notada, entretanto, tal fator não influenciou na correta identificação da espécie, somente alterou a visualização do polígono de identificação e reduziu o valor referente à probabilidade de acerto na caracterização da espécie. No tocante a quantidade de épocas, estudos sugerem que este valor é proporcional a quantidade de características que são inseridas no modelo (FRICKER et al., 2019; MUBIN et al., 2019; CAO; CHEN; GAO, 2020; OSCO et al., 2020).

As métricas estatísticas utilizadas para determinar a acurácia do modelo apontaram correlações muito fortes entre as detecções das espécies, entretanto, os resultados de *Bauhinia* spp. demonstram que a existência de poucas amostras de uma determinada espécie, acarreta menores valores de Acurácia, *F-score* ajustado, Correlação de Matthews, Sensitividade e Similaridade (Tabela 14). Contudo, a espécie *Hymenaea* spp. possuía menos amostras que a *Cecropia* spp. e obteve melhores resultados, o que está relacionado, principalmente, ao tamanho reduzido das copas e folhas de *Cecropia* spp. em comparação às outras espécies. Por possuir galhos mais longos e folhas somente nas pontas destes, as copas das árvores vizinhas se entrecruzam nestes galhos, ocasionando imprecisão na detecção e falsa caracterização da espécie, tal característica também foi relatada em Wagner et al. (2019), os autores demonstram resultados da acurácia semelhantes ao desta pesquisa ao comparar o consórcio de espécies no bioma Mata Atlântica, das quais, possuem características fisionômicas parecidas com a Amazônia.

A Similaridade e Correlação de Matthews são métricas de classificação consideradas pouco tendenciosas quanto ao uso de múltiplas variáveis de entrada, pois incorporam tanto o desequilíbrio do conjunto quanto a quantidade de dados referentes às classes (SHIN, 2020). Neste aspecto, a inclusão das espécies ocasionou menores valores das métricas citadas em comparação à Acurácia e *F-score*, visto que, estas possuem *bias* (viés) relacionados a quantidade de características inclusas e especificamente o *F-score* independe dos verdadeiros negativos (TN). A alta Similaridade demonstra que o classificador é capaz de identificar satisfatoriamente os verdadeiros negativos, assim como a alta Sensitividade indica que o classificador conseguiu identificar bem os verdadeiros positivos (LUQUE et al., 2019).

Os UAVs operam geralmente a baixa altitude e podem adquirir imagens em resoluções espaciais melhores do que as imagens captadas via satélite, possibilitando

informações mais detalhadas não só da floresta, mas também a nível individual de espécie. Em relação aos custos, as operações com UAVs são menores se comparados com imageamento aerotransportado tradicional ou aquisição de alta resolução de sensores orbitais. Assim, é possível adquirir imagens com maior frequência, favorecendo o monitoramento periódico da floresta e estudo da sua dinâmica.

6 CONCLUSÕES

O treinamento da rede neural convolucional usando o modelo de rede neural forneceu resultados satisfatórios na identificação das características das espécies. Ele provou ser uma ferramenta eficaz na classificação de objetos em imagens de UAV sem a necessidade de modificar as propriedades da imagem. Neste sentido, o treinamento da CNN demonstrou boa precisão na identificação das espécies em estudo; entretanto, a inserção de espécies fez com que o treinamento consumisse muito tempo. Além disso, foi observado que existe uma maior classificação errônea quando as copas das espécies se sobrepõem umas às outras, juntamente com o sombreamento em imagens. A qualidade das imagens de UAV foi observada como sendo um componente essencial para a obtenção dos padrões característicos das espécies e para o treinamento em rede. Também impacta a frequência de obtenção das imagens, o que amplia o número de amostras a serem obtidas. Neste caso, o número de amostras utilizadas no treinamento da CNN foi considerado suficiente para reconhecer as características das espécies florestais e os padrões intrínsecos.

A identificação de árvores individuais fornece subsídios para novas informações sobre ecossistemas de restauração florestal, e esperamos que nosso estudo encoraje futuros pesquisadores a desenvolverem estudos para obter informações sobre distinções na caracterização florestal relativas às estações do ano, fenologia da vegetação durante os meses do ano, condições atmosféricas, e outros sensores, adicionando mais informações ao modelo.

REFERÊNCIAS

- ALLABIO, D.; GRISONI, F.; TODESCHINI, R. Multivariate comparison of classification performance measures. **Chemometrics and Intelligent Laboratory Systems**, v. 174, p. 33–44, 2018. Disponível em: <<https://doi.org/10.1016/j.chemolab.2017.12.004>>.
- BERG, C. C. Espécies de *Cecropia* da Amazônia Brasileira. **Acta Amazonica**, v. 8, n. 2, p. 149–182, 1978.
- CAO, D.; CHEN, Z.; GAO, L. An improved object detection algorithm based on multi-scaled and deformable convolutional neural networks. **Human-centric Computing and Information Sciences**, v. 10, n. 1, 2020. Disponível em: <<https://doi.org/10.1186/s13673-020-00219-9>>.
- CASAPIA, X. T.; FALEN, L.; BARTHOLOMEUS, H.; et al. Identifying and quantifying the abundance of economically important palms in tropical moist forest using UAV imagery. **Remote Sensing**, v. 12, n. 1, 2020.
- CNCFLORA. *Hymenaea courbaril* in Lista Vermelha da flora brasileira versão 2012. 2012. Centro Nacional de Conservação da Flora. Disponível em: <http://cncflora.jbrj.gov.br/portal/pt-br/profile/Hymenaea_courbaril>.
- COHEN, J. A coefficient of agreement for nominal scales. **Educational and Psychological Measurement**, v. 20, n. 1, p. 37–46, 1960.
- FASSNACHT, F. E.; LATIFI, H.; STERENÍCZAK, K.; et al. Review of studies on tree species classification from remotely sensed data. **Remote Sensing of Environment**, v. 186, p. 64–87, 2016.
- FERREIRA, M. P.; WAGNER, F. H.; ARAGÃO, L. E. O. C.; SHIMABUKURO, Y. E.; DE SOUZA FILHO, C. R. Tree species classification in tropical forests using visible to shortwave infrared WorldView-3 images and texture analysis. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 149, p. 119–131, 2019. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S0924271619300280>>. Acesso em: 9/7/2020.
- FRANKLE, J.; SCHWAB, D. J.; MORCOS, A. S. The Early Phase of Neural Network Training. **arXiv**, 2020. Disponível em: <<http://arxiv.org/abs/2002.10365>>. Acesso em: 19/3/2021.
- FREUDENBERG, M.; NÖLKE, N.; AGOSTINI, A.; et al. Large scale palm tree detection in high resolution satellite images using U-Net. **Remote Sensing**, v. 11, n. 3, p. 1–18, 2019.
- FRICKER, G. A.; VENTURA, J. D.; WOLF, J. A.; et al. A convolutional neural network classifier identifies tree species in mixed-conifer forest from hyperspectral imagery. **Remote Sensing**, v. 11, n. 19, 2019.

FROMM, M.; SCHUBERT, M.; CASTILLA, G.; LINKE, J.; MCDERMID, G. Automated detection of conifer seedlings in drone imagery using convolutional neural networks. **Remote Sensing**, v. 11, n. 21, 2019.

GOLLOB, C.; RITTER, T.; WASSERMANN, C.; NOTHDURFT, A. Influence of scanner position and plot size on the accuracy of tree detection and diameter estimation using terrestrial laser scanning on forest inventory plots. **Remote Sensing**, v. 11, n. 13, p. 1–30, 2019.

GU, J.; WANG, Z.; KUEN, J.; et al. Recent advances in convolutional neural networks. **Pattern Recognition**, v. 77, p. 354–377, 2018. Disponível em: <<https://doi.org/10.1016/j.patcog.2017.10.013>>.

HARRI LORENZI. **Árvores Brasileiras Vol 1 Editora UFV**. 2014.

HYYPÄ, J.; HYYPÄ, H.; INKINEN, M.; et al. Accuracy comparison of various remote sensing data sources in the retrieval of forest stand attributes. **Forest Ecology and Management**, v. 128, n. 1–2, p. 109–120, 2000.

JASSMANN, T. J.; TASHAKKORI, R.; PARRY, R. M. Leaf classification utilizing a convolutional neural network. **Conference Proceedings - IEEE SOUTHEASTCON**, v. 2015-June, n. June, p. 0–2, 2015.

LOHMANN, L. G. *Handroanthus* in Flora do Brasil. 2020. Jardim Botânico do Rio de Janeiro. Disponível em: <<http://floradobrasil.jbrj.gov.br/reflora/floradobrasil/FB117466>>.

LORENZI, H. **Árvores brasileiras: manual de identificação e cultivo de plantas arbóreas nativas do Brasil**. 3º ed. Nova Odessa, SP, 2000.

LUQUE, A.; CARRASCO, A.; MARTÍN, A.; DE LAS HERAS, A. The impact of class imbalance in classification performance metrics based on the binary confusion matrix. **Pattern Recognition**, v. 91, p. 216–231, 2019. Disponível em: <<https://doi.org/10.1016/j.patcog.2019.02.023>>.

MARATEA, A.; PETROSINO, A.; MANZO, M. Adjusted F-measure and kernel scaling for imbalanced data learning. **Information Sciences**, v. 257, n. April, p. 331–341, 2014. Disponível em: <<http://dx.doi.org/10.1016/j.ins.2013.04.016>>.

MATTHEWS, B. W. Comparison of the predicted and observed secondary structure of T4 phage lysozyme. **Biochimica et Biophysica Acta**, v. 405, n. 2, p. 442–451, 1975.

MORIM, M. P. *Anadenanthera* in Flora do Brasil. 2020. Jardim Botânico do Rio de Janeiro. Disponível em: <<http://floradobrasil.jbrj.gov.br/reflora/floradobrasil/FB22782>>.

MUBIN, N. A.; NADARAJOO, E.; SHAFRI, H. Z. M.; HAMEDIANFAR, A. Young and mature oil palm tree detection and counting using convolutional neural network deep

learning method. **International Journal of Remote Sensing**, v. 40, n. 19, p. 7500–7515, 2019. Disponível em: <<https://doi.org/10.1080/01431161.2019.1569282>>.

NATESAN, S.; ARMENAKIS, C.; VEPAKOMMA, U. Individual Tree Species Identification using Dense Convolutional Network (DenseNet) on multi-temporal RGB images from UAV. **Journal of Unmanned Vehicle Systems**, p. 1–52, 2020.

OSCO, L. P.; DE ARRUDA, M. DOS S.; MARCATO JUNIOR, J.; et al. A convolutional neural network approach for counting and geolocating citrus-trees in UAV multispectral imagery. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 160, n. December 2019, p. 97–106, 2020. Disponível em: <<https://doi.org/10.1016/j.isprsjprs.2019.12.010>>.

PI, Y.; NATH, N. D.; BEHZADAN, A. H. Convolutional neural networks for object detection in aerial imagery for disaster response and recovery. **Advanced Engineering Informatics**, v. 43, n. September 2019, p. 101009, 2020. em: <<https://doi.org/10.1016/j.aei.2019.101009>>.

PINTO, R. B.; TOZZI, A. M. G. A.; MANSANO, V. *Hymenaea* in Flora do Brasil. 2020. Jardim Botânico do Rio de Janeiro. Disponível em: <<http://floradobrasil.jbrj.gov.br/reflora/floradobrasil/FB22972>>.

QIAO, R.; GHODSI, A.; WU, H.; CHANG, Y.; WANG, C. Simple weakly supervised deep learning pipeline for detecting individual red-attacked trees in VHR remote sensing images. **Remote Sensing Letters**, v. 11, n. 7, p. 650–658, 2020.. Disponível em: <<https://doi.org/10.1080/2150704X.2020.1752410>>.

ROSLAN, Z.; LONG, Z. A.; HUSEN, M. N.; ISMAIL, R.; HAMZAH, R. Deep Learning for Tree Crown Detection in Tropical Forest. **Proceedings of the 2020 14th International Conference on Ubiquitous Information Management and Communication, IMCOM 2020**, 2020.

SAMMUT, C.; WEBB, G. I. **Encyclopedia of Machine Learning**. Springer US, 2010.

SARABIA, R.; AQUINO, A.; PONCE, J. M.; LÓPEZ, G.; ANDÚJAR, J. M. Automated identification of crop tree crowns from uav multispectral imagery by means of morphological image analysis. **Remote Sensing**, v. 12, n. 5, p. 1–23, 2020.

SHIN, M. Applications of computer vision to population dynamics: detecting flowering trees in high-resolution cube-sat imagery. n. May, 2020.

SILVA-LUZ, C. L.; PIRANI, J. R.; PELL, S. K.; MITCHELL, J. D. *Anacardiaceae* in Flora do Brasil. 2020. Jardim Botânico do Rio de Janeiro. Disponível em: <<http://floradobrasil.jbrj.gov.br/reflora/floradobrasil/FB4381>>.

SILVA, C. A.; KLAUBERG, C.; HENTZ, Â. M. K.; et al. Comparing the performance of ground filtering algorithms for terrain modeling in a forest environment using airborne LiDAR data. **Floresta e Ambiente**, v. 25, n. 2, 2018.

SYRRIS, V.; HASENOHR, P.; DELIPETREV, B.; et al. Evaluation of the Potential of Convolutional Neural Networks and Random Forests for Multi-Class Segmentation of Sentinel-2 Imagery. **Remote Sensing**, v. 11, n. 8, p. 907, 2019. Disponível em: <<https://www.mdpi.com/2072-4292/11/8/907>>.

TAQI, A. M.; AWAD, A.; AL-AZZO, F.; MILANOVA, M. The Impact of Multi-Optimizers and Data Augmentation on TensorFlow Convolutional Neural Network Performance. Proceedings - IEEE 1st Conference on Multimedia Information Processing and Retrieval, MIPR 2018. **Anais...** . p.140–145, 2018.

TZUTALIN. Git code. Disponível em: <<https://github.com/tzutalin/labellmg>>. VAZ, A. M. S. F. *Bauhinia* in Flora do Brasil. 2020. Jardim Botânico do Rio de Janeiro. Disponível em: <<http://floradobrasil.jbrj.gov.br/reflora/floradobrasil/FB22812>>.

WAGNER, F. H.; SANCHEZ, A.; TARABALKA, Y.; et al. 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**, p. 360–375, 2019.

WANG, D.; FENG, Y.; ATTWOOD, K.; TIAN, L. Optimal threshold selection methods under tree or umbrella ordering. **Journal of Biopharmaceutical Statistics**, v. 29, n. 1, p. 98–114, 2019. Disponível em: <<https://doi.org/10.1080/10543406.2018.1489410>>.

WU, Y.; WANG, J. J.; QIAN, K.; et al. An energy-efficient deep convolutional neural networks coprocessor for multi-object detection. **Microelectronics Journal**, v. 98, n. December 2019, 2020.

WULDER, M. Optical remote-sensing techniques for the assessment of forest inventory and biophysical parameters. **Progress in Physical Geography**, v. 22, n. 4, p. 449–476, 1998.

XIAO, C.; QIN, R.; HUANG, X. Treetop detection using convolutional neural networks trained through automatically generated pseudo labels. **International Journal of Remote Sensing**, v. 41, n. 8, p. 3010–3030, 2020. Disponível em: <<https://doi.org/10.1080/01431161.2019.1698075>>.

XIONG, J.; LIU, Z.; CHEN, S.; et al. Visual detection of green mangoes by an unmanned aerial vehicle in orchards based on a deep learning method. **Biosystems Engineering**, v. 194, p. 261–272, 2020. Disponível em: <<https://doi.org/10.1016/j.biosystemseng.2020.04.006>>.

YAO, Q.; HU, X.; LEI, H. Multiscale Convolutional Neural Networks for Geospatial Object Detection in VHR Satellite Images. **IEEE Geoscience and Remote Sensing Letters**, p. 1–5, 2020.

ZHANG, M.; CHEN, Y.; LIU, X.; LV, B.; WANG, J. Adaptive Anchor Networks for Multi-Scale Object Detection in Remote Sensing Images. **IEEE Access**, v. 8, p. 57552–57565, 2020.

CONCLUSÃO GERAL E RECOMENDAÇÕES

A partir dos resultados obtidos foi possível estimar e avaliar a dinâmica temporal da biomassa acima do solo com utilização de sensores orbitais, a distribuição espacial em escala regional e utilização de imagens UAV como subsídio para aquisição de dados de árvores individuais em florestas em processo de restauração no bioma Amazônico, portanto, os modelos ajustados e testados utilizando como variáveis independentes o diâmetro a 1,30m de altura (DAP) e a altura total (ht) apresentam estatísticas satisfatórias e podem ser utilizados para estimar a biomassa de árvores em ambientes florestais. Os resultados expostos demonstram que árvores com grandes dimensões são responsáveis pela maior parte do estoque de biomassa nas áreas em restauração, enquanto a abundância de indivíduos por hectare influencia no estoque de biomassa acima do solo, neste sentido o principal fator nesses estoques de AGB foram as alturas e os diâmetros, portanto, quanto maior as árvores maiores os estoques de biomassa acima do solo.

Por meio das estimativas de biomassa acima do solo foi possível observar que os plantios de restauração são estoques de biomassa potencialmente significativo devido às rápidas taxas de acúmulo desse componente. Esses estoques foram acrescidos em relação aos anos de estudo, demonstrando a capacidade de crescimento de biomassa em florestas em processo de restauração. No entanto, os distúrbios antrópicos frequentemente interrompem o processo de recuperação e consequentemente o estabelecimento de florestas maduras.

Em relação às estimativas utilizando como subsídio os sensores remotos aliados aos índices de vegetação, os modelos utilizando somente os dados espectrais do satélite Sentinel-2A obtiveram estatísticas melhores, se comparados com os modelos utilizando dados do Landsat 8. Neste âmbito, as técnicas de escolha das variáveis foram fundamentais para que fossem ajustados modelos que melhor representassem a variação espacial da biomassa acima do solo nos plantios de restauração. O uso de imagens de satélite com alta resolução espacial, juntamente com diferentes técnicas de modelagem pode aumentar os níveis de sucesso do modelo nos estudos a serem conduzidos para estimar a biomassa acima do solo.

Dados orbitais e índices de vegetação podem ser utilizados para estimativas de biomassa acima do solo, contudo, devem ser observadas características da

vegetação, pois os modelos ajustados devem ser utilizados apenas para a vegetação da qual foi ajustado, em caso contrário os erros nas estimativas serão altos e, portanto, não obtendo dados que caracterizem realmente a biomassa de determinada vegetação.

Após os ajustes dos modelos utilizando os índices de vegetação, observou-se que a espacialização da biomassa entre os anos 2016 e 2020 foi satisfatória e apresentou valores condizentes com os dados coletados em campo e os descritos na literatura. Neste sentido, os modelos ajustados podem ser utilizados para simulações e previsões futuras ou pretéritas visando o manejo das áreas em processo de restauração, podem ser utilizados para minimizar os erros e aumentar a precisão as medidas de diâmetro ou circunferência das copas das árvores.

A utilização de tecnologias que favorecem a implementação e desenvolvimento de plantios de restauração deve ser empregada com assistência de dados coletados em campo, neste sentido, o reconhecimento das espécies que compõe determinada fitofisionomia florestal é fundamental para o manejo e conservação destas áreas. O treinamento de rede neural convolucional usando o modelo de rede neural, forneceu resultados satisfatórios na identificação das características das espécies. Ele provou ser uma ferramenta eficaz na classificação de objetos em imagens de UAV sem a necessidade de modificar as propriedades da imagem. Portanto, o treinamento da CNN demonstrou boa precisão e precisão na identificação das espécies em estudo. A qualidade das imagens de UAV foi observada como sendo um componente essencial para a obtenção dos padrões característicos das espécies e para o treinamento em rede. Também impacta a frequência de obtenção das imagens, o que amplia o número de amostras a serem obtidas. Em nosso caso, o número de amostras utilizadas no treinamento da CNN foi considerado suficiente para reconhecer as características das espécies florestais e os padrões intrínsecos.

A identificação de árvores individuais fornece subsídios para novas informações sobre ecossistemas de restauração florestal, e esperamos que nosso estudo encoraje futuros pesquisadores a desenvolverem estudos para obter informações sobre distinções na caracterização florestal relativas às estações do ano, fenologia da vegetação durante os meses do ano, condições atmosféricas, e outros sensores, adicionando mais informações ao modelo.

REFERÊNCIAS GERAIS

- ALEXANDER, S.; NELSON, C. R.; ARONSON, J.; et al. Opportunities and Challenges for Ecological Restoration within REDD+. **Restoration Ecology**, v. 19, n. 6, p. 683–689, 2011.
- ALLABIO, D.; GRISONI, F.; TODESCHINI, R. Multivariate comparison of classification performance measures. **Chemometrics and Intelligent Laboratory Systems**, v. 174, p. 33–44, 2018. Disponível em: <<https://doi.org/10.1016/j.chemolab.2017.12.004>>.
- ALMEIDA, C. A. de, COUTINHO, A. C., ESQUERDO, J. C. D. M., et al. High spatial resolution land use and land cover mapping of the Brazilian Legal Amazon in 2008 using Landsat-5/TM and MODIS data. **Acta Amazonica**, v. 46, n. 3, p. 291–302, 2016.
- ALVES, D. S.; ESCADA, M. I. S.; PEREIRA, J. L. G.; DE ALBUQUERQUE LINHARES, C. Land use intensification and abandonment in Rondônia, Brazilian Amazônia. **International Journal of Remote Sensing**, v. 24, n. 4, p. 899–903, 2003.
- AKHTAR, A. M.; QAZI, W. A.; RASHID AHMAD, S.; et al. Integration of high-resolution optical and SAR satellite remote sensing datasets for aboveground biomass estimation in subtropical pine forest, Pakistan. **Environmental Monitoring and Assessment**, 2020. Disponível em: <<https://doi.org/10.1007/s10661-020-08546-1>>. Acesso em: 28/5/2021.
- AMARAL, J. H. F.; MELACK, J. M.; BARBOSA, P. M.; et al. **Carbon Dioxide Fluxes to the Atmosphere From Waters Within Flooded Forests in the Amazon Basin**. 2020.
- ARMENTERAS, D.; MURCIA, U.; GONZÁLEZ, T. M.; BARÓN, O. J.; ARIAS, J. E. Scenarios of land use and land cover change for NW Amazonia: Impact on forest intactness. **Global Ecology and Conservation**, v. 17, 2019.
- BANKS-LEITE, C.; PARDINI, R.; TAMBOSI, L. R.; et al. Using ecological thresholds to evaluate the costs and benefits of set-asides in a biodiversity hotspot. **Science**, v. 345, n. 6200, p. 1041–1045, 2014.
- BERG, C. C. Espécies de *Cecropia* da Amazônia Brasileira. **Acta Amazonica**, v. 8, n. 2, p. 149–182, 1978.
- BEYENE, S. M.; HUSSIN, Y. A.; KLOOSTERMAN, H. E.; ISMAIL, M. H. Forest Inventory and Aboveground Biomass Estimation with Terrestrial LiDAR in the Tropical Forest of Malaysia. **Canadian Journal of Remote Sensing**, v. 46, n. 2, p. 130–145, 2020. Disponível em: <<https://doi.org/10.1080/07038992.2020.1759036>>.
- BOJÓRQUEZ, A.; MARTÍNEZ-YRÍZAR, A.; BÚRQUEZ, A.; et al. Improving the accuracy of aboveground biomass estimations in secondary tropical dry forests. **Forest Ecology and Management**, 15. out. 2020.

BOURGOIN, C.; BLANC, L.; BAILLY, J. S.; et al. The potential of multisource remote sensing for mapping the biomass of a degraded Amazonian forest. **Forests**, v. 9, n. 6, p. 1–21, 2018.

BRANCALION, P.; GANDOLFI, S.; RODRIGUES, R. R. **Restauração Florestal**. 1º ed. Oficina de Textos, 2015.

BRANCALION, P. H. S.; CAMPOE, O.; MENDES, J. C. T.; et al. Intensive silviculture enhances biomass accumulation and tree diversity recovery in tropical forest restoration. **Ecological Applications**, v. 29, n. 2, p. e01847, 2019. Disponível em: <<https://onlinelibrary.wiley.com/doi/full/10.1002/eap.1847>>. Acesso em: 28/12/2021.

BRANDÃO JUNIOR, A.; SOUZA JUNIOR, C. Desmatamento nos Assentamentos de Reforma Agrária na Amazônia. **Imazon**, v. 7, n. 4, 2006.

BRASIL. Decreto Nº 7.830. **Dispõe sobre o Sistema de Cadastro Ambiental Rural, o Cadastro Ambiental Rural, estabelece normas de caráter geral aos Programas de Regularização Ambiental, de que trata a Lei nº 12.651, de 25 de maio de 2012, e dá outras providências.** , 2012. Brasília, 25 de maio de 2012.

BRASIL, I. D. S. **Dinâmica da fragmentação da Floresta Amazônica no estado de Rondônia, 2020**. Dissertação (Mestrado), Programa de Pós-Graduação em Engenharia Florestal, Universidade Federal do Paraná.

BRASIL. **Plano de Ação para Prevenção e Controle do Desmatamento e das Queimadas no Cerrado (PPCerrado) e Plano de Ação para Prevenção e Controle do Desmatamento na Amazônia Legal (PPCDAm)**. Fase 2016-2020. , 2018. 4ª ed. Brasília: MMA.

CAMARRETTA, N.; HARRISON, P. A.; BAILEY, T.; et al. Monitoring forest structure to guide adaptive management of forest restoration: a review of remote sensing approaches. **New Forests**, v. 51, n. 4, p. 573–596, 2020. Disponível em: <<https://doi.org/10.1007/s11056-019-09754-5>>.

CAO, D.; CHEN, Z.; GAO, L. An improved object detection algorithm based on multi-scaled and deformable convolutional neural networks. **Human-centric Computing and Information Sciences**, v. 10, n. 1, 2020. Disponível em: <<https://doi.org/10.1186/s13673-020-00219-9>>.

CASSOL, H. L. G.; CARREIRAS, J. M. DE B.; MORAES, E. C.; et al. Remote sensing Retrieving Secondary Forest Aboveground Biomass from Polarimetric ALOS-2 PALSAR-2 Data in the Brazilian Amazon. **Remote Sensing**. v. 11, p. 59, 2019. Disponível em: <https://doi.org/10.3390/rs11010059>

CASAPIA, X. T.; FALEN, L.; BARTHOLOMEUS, H.; et al. Identifying and quantifying the abundance of economically important palms in tropical moist forest using UAV imagery. **Remote Sensing**, v. 12, n. 1, 2020.

CHAVE, J.; RÉJOU-MÉCHAIN, M.; BÚRQUEZ, A.; et al. Improved allometric models to estimate the aboveground biomass of tropical trees. **Global Change Biology**, v.

20, n. 10, p. 3177–3190, 2014.

CHAZDON, R. L.; BROADBENT, E. N.; ROZENDAAL, D. M. A.; et al. Carbon sequestration potential of second-growth forest regeneration in the Latin American tropics. **Science Advances**, v. 2, n. 5, 2016.

CHAZDON, R. L.; BROADBENT, E. N.; ROZENDAAL, D. M. A.; et al. Carbon sequestration potential of second-growth forest regeneration in the Latin American tropics. **Science Advances**, v. 2, n. 5, 2016.

CNCFLORA. ***Hymenaea courbaril* in Lista Vermelha da flora brasileira versão 2012**. 2012. Centro Nacional de Conservação da Flora. Disponível em: <[http://cncflora.jbrj.gov.br/portal/pt-br/profile/Hymenaea courbaril](http://cncflora.jbrj.gov.br/portal/pt-br/profile/Hymenaea_courbaril)>.

COELHO DE ABREU, J.; PEDRO, C.; SOARES, B.; et al. Alternatives to estimate the volume of individual trees in forest formations in the state of Minas gerais, Brazil. **CERNE**, v. 26, n. 3, p. 393–402, 2020. Disponível em: <<http://www.scielo.br/j/cerne/a/sLYxsdhnnJvK89Kpf7XJ8HG/abstract/?lang=en>>. Acesso em: 9/1/2022.

COHEN, J. A coefficient of agreement for nominal scales. **Educational and Psychological Measurement**, v. 20, n. 1, p. 37–46, 1960.

CORTE, A. P. D.; SOUZA, D. V.; REX, F. E.; et al. Forest inventory with high-density UAV-Lidar: Machine learning approaches for predicting individual tree attributes. **Computers and Electronics in Agriculture**, v. 179, p. 105815, 2020.

COSTA, G. B. DA; BALTHAZAR, B. L. T. DE A.; LIMA, A. M. S.; NANTES, R. A.; CÂMARA, J. B. DE A. Extractive Reserves in the State in Rondônia: A Positioning about the Occupation and Expectations / Restrictions Suffered by the Residents. **International Journal of Advanced Engineering Research and Science**, v. 6, n. 4, p. 147–154, 2019.

CUNHA NETO, E. M. DA; REX, F. E.; VERAS, H. F. P.; et al. Using high-density UAV-Lidar for deriving tree height of *Araucaria Angustifolia* in an Urban Atlantic Rain Forest. **Urban Forestry and Urban Greening**, v. 63, p. 127197, 2021.

CRUZ, D. C.; BENAYAS, J. M. R.; FERREIRA, G. C.; SANTOS, S. R.; SCHWARTZ, G. An overview of forest loss and restoration in the Brazilian Amazon. **New Forests**, , n. 0123456789, 2020. Disponível em: <<https://doi.org/10.1007/s11056-020-09777-3>>.

DELAZERI, L. Determinantes do Desmatamento nos Municípios do Arco Verde – Amazônia Legal: uma abordagem econométrica. **Revista Economia Ensaios**, v. 30, n. 2, p. 11–34, 2016. Disponível em: <<http://200.19.146.79/index.php/revistaeconomiaensaios/article/view/28364>>. Acesso em: 4/8/2020.

DEUS, K. H. P.; FILHO, A. F.; DIAS, A. N.; BONETE, I. P. Woody necromass stock in mixed ombrophilous forest using different sampling methods. **Revista Caatinga**, v.

31, n. 3, p. 657–666, 2018.

DREBENSTEDT, I.; SCHMID, I.; POLL, C.; et al. Effects of soil warming and altered precipitation patterns on photosynthesis, biomass production and yield of barley. **Journal of Applied Botany and Food Quality**, v. 93, p. 44–53, 2020.

DUNCANSON, L.; NEUENSCHWANDER, A.; HANCOCK, S.; et al. Biomass estimation from simulated GEDI, ICESat-2 and NISAR across environmental gradients in Sonoma County, California. **Remote Sensing of Environment**, v. 242, p. 111779, 2020.

EDWARDS, D. P.; MASSAM, M. R.; HAUGAASEN, T.; GILROY, J. J. Tropical secondary forest regeneration conserves high levels of avian phylogenetic diversity. **Biological Conservation**, v. 209, p. 432–439, 2017. Disponível em: <<http://dx.doi.org/10.1016/j.biocon.2017.03.006>>. .

ELIAS, F.; FERREIRA, J.; LENNOX, G. D.; et al. Assessing the growth and climate sensitivity of secondary forests in highly deforested Amazonian landscapes. **Ecology**, v. 101, n. 3, 2020.

FASSNACHT, F. E.; LATIFI, H.; STERENÍCZAK, K.; et al. Review of studies on tree species classification from remotely sensed data. **Remote Sensing of Environment**, v. 186, p. 64–87, 2016.

FRANKLE, J.; SCHWAB, D. J.; MORCOS, A. S. The Early Phase of Neural Network Training. **arXiv**, 2020. Disponível em: <<http://arxiv.org/abs/2002.10365>>. Acesso em: 19/3/2021.

FREITAS, M. G.; RODRIGUES, S. B.; CAMPOS-FILHO, E. M.; et al. Evaluating the success of direct seeding for tropical forest restoration over ten years. **Forest Ecology and Management**, v. 438, n. February, p. 224–232, 2019. Disponível em: <<https://doi.org/10.1016/j.foreco.2019.02.024>>.

FERREIRA, M. P.; WAGNER, F. H.; ARAGÃO, L. E. O. C.; SHIMABUKURO, Y. E.; DE SOUZA FILHO, C. R. Tree species classification in tropical forests using visible to shortwave infrared WorldView-3 images and texture analysis. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 149, p. 119–131, 2019. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S0924271619300280>>. Acesso em: 9/7/2020.

FREUDENBERG, M.; NÖLKE, N.; AGOSTINI, A.; et al. Large scale palm tree detection in high resolution satellite images using U-Net. **Remote Sensing**, v. 11, n. 3, p. 1–18, 2019.

FRICKER, G. A.; VENTURA, J. D.; WOLF, J. A.; et al. A convolutional neural network classifier identifies tree species in mixed-conifer forest from hyperspectral imagery. **Remote Sensing**, v. 11, n. 19, 2019.

FROMM, M.; SCHUBERT, M.; CASTILLA, G.; LINKE, J.; MCDERMID, G. Automated detection of conifer seedlings in drone imagery using convolutional neural networks. **Remote Sensing**, v. 11, n. 21, 2019.

GHOSH, S. M.; BEHERA, M. D. Aboveground biomass estimation using multi-sensor data synergy and machine learning algorithms in a dense tropical forest. **Applied Geography**, v. 96, n. March, p. 29–40, 2018. Disponível em: <<https://doi.org/10.1016/j.apgeog.2018.05.011>>.

GOLLOB, C.; RITTER, T.; WASSERMANN, C.; NOTHDURFT, A. Influence of scanner position and plot size on the accuracy of tree detection and diameter estimation using terrestrial laser scanning on forest inventory plots. **Remote Sensing**, v. 11, n. 13, p. 1–30, 2019.

GU, J.; WANG, Z.; KUEN, J.; et al. Recent advances in convolutional neural networks. **Pattern Recognition**, v. 77, p. 354–377, 2018. Disponível em: <<https://doi.org/10.1016/j.patcog.2017.10.013>>.

GUERINI FILHO, M.; KUPLICH, T. M.; QUADROS, F. L. F. D. Estimating natural grassland biomass by vegetation indices using Sentinel 2 remote sensing data. **International Journal of Remote Sensing**, v. 41, n. 8, p. 2861–2876, 2020. Disponível em: <<https://www.tandfonline.com/doi/abs/10.1080/01431161.2019.1697004>>. Acesso em: 29/5/2021.

GREENLEAF, M. The value of the untenured forest: land rights, green labor, and forest carbon in the Brazilian Amazon. **Journal of Peasant Studies**, v. 47, n. 2, p. 286–305, 2020. Disponível em: <<https://doi.org/10.1080/03066150.2019.1579197>>.

HARRI LORENZI. **Árvores Brasileiras Vol 1 Editora UFV**. 2014.

HOUGHTON, R. A.; NASSIKAS, A. A. Negative emissions from stopping deforestation and forest degradation, globally. **Global Change Biology**, v. 24, n. 1, p. 350–359, 2018. Disponível em: <<http://doi.wiley.com/10.1111/gcb.13876>>. Acesso em: 8/8/2020.

HOSSEINI, Z.; LATIFI, H.; NAGHAVI, H.; BAKHTIARVAND BAKHTIARI, S.; FASSNACHT, F. E. Influence of plot and sample sizes on aboveground biomass estimations in plantation forests using very high resolution stereo satellite imagery. **Forestry**, v. 94, n. 2, p. 278–291, 2021.

HOUGHTON, R. A.; NASSIKAS, A. A. Negative emissions from stopping deforestation and forest degradation, globally. **Global Change Biology**, v. 24, n. 1, p. 350–359, 2018. Disponível em: <<http://doi.wiley.com/10.1111/gcb.13876>>. Acesso em: 8/8/2020

HU, T.; ZHANG, Y. Y.; SU, Y.; et al. Mapping the global mangrove forest aboveground biomass using multisource remote sensing data. **Remote Sensing**, v. 12, n. 10, 2020.

HYYPÄ, J.; HYYPÄ, H.; INKINEN, M.; et al. Accuracy comparison of various remote sensing data sources in the retrieval of forest stand attributes. **Forest Ecology and Management**, v. 128, n. 1–2, p. 109–120, 2000.

JASSMANN, T. J.; TASHAKKORI, R.; PARRY, R. M. Leaf classification utilizing a convolutional neural network. **Conference Proceedings - IEEE SOUTHEASTCON**, v. 2015-June, n. June, p. 0–2, 2015.

JOHNSON, C. M.; VIEIRA, I. C. G.; ZARIN, D. J.; FRIZANO, J.; JOHNSON, A. H. Carbon and nutrient storage in primary and secondary forests in eastern Amazônia. **Forest Ecology and Management**, v. 147, n. 2–3, p. 245–252, 2001.

KARYATI; IPOR, I. B.; JUSOH, I.; WASLI, M. E. Allometric equations to estimate the above-ground biomass of trees in the tropical secondary forests of different ages. **Biodiversitas**, v. 20, n. 9, p. 2427–2436, 2019.

KENZO, T.; HIMMAPAN, W.; YONEDA, R.; et al. General estimation models for above- and below-ground biomass of teak (*Tectona grandis*) plantations in Thailand. **Forest Ecology and Management**, v. 457, p. 117701, 2020.

KRAMER, R. D.; ISHII, H. R.; CARTER, K. R.; et al. Predicting effects of climate change on productivity and persistence of forest trees. **Ecological Research**, , n. April, p. 1–13, 2020.

LAMB, D.; ERSKINE, P. D.; PARROTTA, J. A. Restoration of degraded tropical forest landscapes. **Science**, v. 310, n. 5754, p. 1628–1632, 2005.

LEÃO, F. M.; NASCIMENTO, R. G. M.; EMMERT, F.; et al. How many trees are necessary to fit an accurate volume model for the Amazon forest? A site-dependent analysis. **Forest Ecology and Management**, v. 480, p. 118652, 2021.

LU, D.; BATISTELLA, M. Exploring TM image texture and its relationships with biomass estimation in Rondônia, Brazilian Amazon. **Acta Amazonica**, v. 35, n. 2, p. 249–257, 2005.

LI, Y.; LI, M.; LI, C.; LIU, Z. Forest aboveground biomass estimation using Landsat 8 and Sentinel-1A data with machine learning algorithms. **Scientific Reports** 2020 **10:1**, v. 10, n. 1, p. 1–12, 2020.

LI, X.; WIGNERON, J. P.; FRAPPART, F.; et al. Global-scale assessment and inter-comparison of recently developed/reprocessed microwave satellite vegetation optical depth products. **Remote Sensing of Environment**, v. 253, p. 112208, 2021.

LIMA, R. C.; SARDINHA, M. A.; SOUZA, J. DOS S.; et al. Composition and structure of a stretch of tropical forest in the Eastern Amazon. **Ciência Rural**, v. 51, n. 4, p. 2021. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0103-84782021000400301&lng=en>. Acesso em: 25/3/2021.

LOHMANN, L. G. *Handroanthus* in Flora do Brasil. 2020. Jardim Botânico do Rio de Janeiro. Disponível em: <http://floradobrasil.jbrj.gov.br/reflora/floradobrasil/FB117466>>.

LORENZI, H. **Árvores brasileiras: manual de identificação e cultivo de plantas arbóreas nativas do Brasil**. 3º ed. Nova Odessa, SP, 2000.

LUQUE, A.; CARRASCO, A.; MARTÍN, A.; DE LAS HERAS, A. The impact of class imbalance in classification performance metrics based on the binary confusion matrix. **Pattern Recognition**, v. 91, p. 216–231, 2019. Disponível em: <https://doi.org/10.1016/j.patcog.2019.02.023>>.

MAAS, G. C. B.; SANQUETTA, C. R.; MARQUES, R.; MACHADO, S. D. A.; SANQUETTA, M. N. I. Quantification of carbon in forest necromass: State of the art. **Cerne**, v. 26, n. 1, p. 98–108, 2020.

MARATEA, A.; PETROSINO, A.; MANZO, M. Adjusted F-measure and kernel scaling for imbalanced data learning. **Information Sciences**, v. 257, n. April, p. 331–341, 2014. Disponível em: <http://dx.doi.org/10.1016/j.ins.2013.04.016>>.

MATTHEWS, B. W. Comparison of the predicted and observed secondary structure of T4 phage lysozyme. **Biochimica et Biophysica Acta**, v. 405, n. 2, p. 442–451, 1975.

MARÉCHAUX, I.; CHAVE, J. An individual-based forest model to jointly simulate carbon and tree diversity in Amazonia: description and applications. **Ecological Monographs**, v. 87, n. 4, p. 632–664, 2017. Disponível em: <http://doi.wiley.com/10.1002/ecm.1271>>.

MCDOWELL, N. G.; ALLEN, C. D.; ANDERSON-TEIXEIRA, K.; et al. Pervasive shifts in forest dynamics in a changing world. **Science**, v. 368, n. 6494, 2020.

MIRANDA, L. S.; IMPERATRIZ-FONSECA, V. L.; GIANNINI, T. C. Climate change impact on ecosystem functions provided by birds in southeastern Amazonia. **PLoS ONE**, v. 14, n. 4, p. 1–17, 2019.

MORIM, M. P. *Anadenanthera* in Flora do Brasil. 2020. Jardim Botânico do Rio de Janeiro. Disponível em: <http://floradobrasil.jbrj.gov.br/reflora/floradobrasil/FB22782>>.

MOTLAGH, M. G.; KAFKY, S. B.; MATAJI, A.; AKHAVAN, R. Estimating and mapping forest biomass using regression models and Spot-6 images (case study: Hyrcanian forests of north of Iran). **Environmental Monitoring and Assessment**, v. 190, n. 6, p. 1–14, 2018. Disponível em: <https://doi.org/10.1007/s10661-018-6725-0>>. Acesso em: 29/5/2021.

MOHD ZAKI, N. A.; ABD LATIF, Z. Carbon sinks and tropical forest biomass estimation: a review on role of remote sensing in aboveground-biomass modelling. **Geocarto International**, 2017.

MUBIN, N. A.; NADARAJOO, E.; SHAFRI, H. Z. M.; HAMEDIANFAR, A. Young and mature oil palm tree detection and counting using convolutional neural network deep learning method. **International Journal of Remote Sensing**, v. 40, n. 19, p. 7500–7515, 2019. Disponível em: <<https://doi.org/10.1080/01431161.2019.1569282>>.

MUKURALINDA, A.; KUYAH, S.; RUZIBIZA, M.; et al. Allometric equations, wood density and partitioning of aboveground biomass in the arboretum of Ruhande, Rwanda. **Trees, Forests and People**, v. 3, p. 100050, 2021.

MURAOKA, H.; KOIZUMI, H. Satellite Ecology (SATECO)-linking ecology, remote sensing and micrometeorology, from plot to regional scale, for the study of ecosystem structure and function. **Journal of Plant Research**, v. 122, n. 1, p. 3–20, 2009.

NATESAN, S.; ARMENAKIS, C.; VEPAKOMMA, U. Individual Tree Species Identification using Dense Convolutional Network (DenseNet) on multi-temporal RGB images from UAV. **Journal of Unmanned Vehicle Systems**, p. 1–52, 2020.

NUNES, S. MIA; OLIVEIRA, L.; SIQUEIRA, J. O.; MORTON, D. C.; SOUZA, C. M. Unmasking secondary vegetation dynamics in the Brazilian Amazon. **Environmental Research Letters**, v. 15, n. 3, p. 034057, 2020. Disponível em: <<https://doi.org/10.1088/1748-9326/ab76db>>. Acesso em: 25/4/2021.

NGOMANDA, A.; ENGONE OBIANG, N. L.; LEBAMBA, J.; et al. Site-specific versus pantropical allometric equations: Which option to estimate the biomass of a moist central African forest. **Forest Ecology and Management**, v. 312, p. 1–9, 2014.

NGUYEN, T. H.; JONES, S. D.; SOTO-BERELOV, M.; HAYWOOD, A.; HISLOP, S. Monitoring aboveground forest biomass dynamics over three decades using Landsat time-series and single-date inventory data. **International Journal of Applied Earth Observation and Geoinformation**, v. 84, p. 101952, 2020.

OBERLEITNER, F.; EGGER, C.; OBERDORFER, S.; et al. Recovery of aboveground biomass, species richness and composition in tropical secondary forests in SW Costa Rica. **Forest Ecology and Management**, v. 479, p. 118580, 2021.

OSCO, L. P.; DE ARRUDA, M. DOS S.; MARCATO JUNIOR, J.; et al. A convolutional neural network approach for counting and geolocating citrus-trees in UAV multispectral imagery. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 160, n. December 2019, p. 97–106, 2020. Disponível em: <<https://doi.org/10.1016/j.isprsjprs.2019.12.010>>.

PAN, Y.; BIRDSEY, R. A.; PHILLIPS, O. L.; JACKSON, R. B. The Structure, Distribution, and Biomass of the World's Forests. **<http://dx.doi.org/10.1146/annurev-ecolsys-110512-135914>**, v. 44, p. 593–622, 2013. Annual Reviews . Disponível em: <<https://www.annualreviews.org/doi/abs/10.1146/annurev-ecolsys-110512-135914>>. Acesso em: 25/10/2021.

PANDE, C. B.; MOHARIR, K. N.; SINGH, S. K.; et al. Estimation of crop and forest biomass resources in a semi-arid region using satellite data and GIS. **Journal of the**

Saudi Society of Agricultural Sciences, 2021. Disponível em:
<<https://doi.org/10.1016/j.jssas.2021.03.002>>. Acesso em: 28/5/2021.

PEDLOWSKI, M. A.; MATRICARDI, E. A. T.; SKOLE, D.; et al. Conservation units: A new deforestation frontier in the Amazonian state of Rondônia, Brazil. **Environmental Conservation**, v. 32, n. 2, p. 149–155, 2005. Disponível em:
<https://www.cambridge.org/core/product/identifier/S0376892905002134/type/journal_article>. Acesso em: 4/8/2020.

POORTER, L.; BONGERS, F.; AIDE, T. M.; et al. Biomass resilience of Neotropical secondary forests. **Nature**, v. 530, n. 7589, p. 211–214, 2016. Disponível em:
<<http://www.nature.com/articles/nature16512>>. Acesso em: 24/4/2021.

PIONTEKOWSKI, V. J.; MATRICARDI, E. A. T.; PEDLOWSKI, M. A.; FERNANDES, L. C. Avaliação do desmatamento no Estado de Rondônia entre 2001 e 2011. **Floresta e Ambiente**, v. 21, n. 3, p. 297–306, 2014. Disponível em:
<<http://dx.doi.org/10.1590/2179-8087.068213>>. Acesso em: 4/8/2020.

PI, Y.; NATH, N. D.; BEHZADAN, A. H. Convolutional neural networks for object detection in aerial imagery for disaster response and recovery. **Advanced Engineering Informatics**, v. 43, n. September 2019, p. 101009, 2020. em:
<<https://doi.org/10.1016/j.aei.2019.101009>>.

PINTO, R. B.; TOZZI, A. M. G. A.; MANSANO, V. *Hymenaea* in Flora do Brasil. 2020. Jardim Botânico do Rio de Janeiro. Disponível em:
<<http://floradobrasil.jbrj.gov.br/reflora/floradobrasil/FB22972>>.

POORTER, L.; BONGERS, F.; AIDE, T. M.; et al. Biomass resilience of Neotropical secondary forests. **Nature**, v. 530, n. 7589, p. 211–214, 2016. Disponível em:
<<http://dx.doi.org/10.1038/nature16512>>.

PRESTES, N. C. C. DOS S.; MASSI, K. G.; SILVA, E. A.; et al. Fire Effects on Understory Forest Regeneration in Southern Amazonia. **Frontiers in Forests and Global Change**, v. 3, n. February, p. 1–15, 2020.

PRODES. **Coordenação-Geral de Observação da Terra**. Disponível em:
<<http://www.obt.inpe.br/OBT/assuntos/programas/amazonia/prodes>>. Acesso em: 23/10/2021.

QIAO, R.; GHODSI, A.; WU, H.; CHANG, Y.; WANG, C. Simple weakly supervised deep learning pipeline for detecting individual red-attacked trees in VHR remote sensing images. **Remote Sensing Letters**, v. 11, n. 7, p. 650–658, 2020.. Disponível em: <<https://doi.org/10.1080/2150704X.2020.1752410>>.

RBD, L.; CPD, O.; RLC, F.; et al. **Modeling and Spatialization of Biomass and Carbon Stock Using Lidar Metrics in Tropical Dry Forest, Brazil: Preliminary Results**. , 2020. Disponível em: <<https://europepmc.org/article/ppr/ppr199325>>. Acesso em: 9/1/2022.

RIGUEIRA, D.; SANTANA, J. G. **Como restaurar sua floresta**: cartilha. , p. 20,

2015.

RIOTERRA. Contexto prévio: Rondônia. 2011. Disponível em:

<[http://rioterra.org.br/pt/wp-](http://rioterra.org.br/pt/wp-content/uploads/2011/07/analise_socioeconomica_do_entorno_da_area_de_conces_sao_publica_parte_ii.pdf)

[content/uploads/2011/07/analise_socioeconomica_do_entorno_da_area_de_conces_sao_publica_parte_ii.pdf](http://rioterra.org.br/pt/wp-content/uploads/2011/07/analise_socioeconomica_do_entorno_da_area_de_conces_sao_publica_parte_ii.pdf)>. Acesso em: 31/5/2020a.

RIOTERRA. **Portfólio – Centro de Estudos Rioterra**. Disponível em:

<<http://rioterra.org.br/pt/portfolio/>>. Acesso em: 5/8/2020b.

ROCHA, R.; OVASKAINEN, O.; LÓPEZ-BAUCELLS, A.; et al. Secondary forest regeneration benefits old-growth specialist bats in a fragmented tropical landscape.

Scientific Reports, n. 8, v. 1, p. 3819. 2018. Disponível em:

<https://doi.org/10.1038/s41598-018-21999-2>

RODRIGUES, R. R.; LIMA, R. A. F.; GANDOLFI, S.; NAVE, A. G. On the restoration of high diversity forests: 30 years of experience in the Brazilian Atlantic Forest.

Biological Conservation, v. 142, n. 6, p. 1242–1251, 2009. Disponível em:

<<https://linkinghub.elsevier.com/retrieve/pii/S0006320708004771>>. Acesso em: 4/8/2020.

RONDÔNIA. **Zoneamento Socioeconômico-ecológico do estado de Rondônia**.

Porto Velho - Rondônia, 2010.

ROSLAN, Z.; LONG, Z. A.; HUSEN, M. N.; ISMAIL, R.; HAMZAH, R. Deep Learning for Tree Crown Detection in Tropical Forest. **Proceedings of the 2020 14th International Conference on Ubiquitous Information Management and Communication, IMCOM 2020**, 2020.

RUIZ-JAÉN, M. C.; AIDE, T. M. Vegetation structure, species diversity, and ecosystem processes as measures of restoration success. **Forest Ecology and Management**, v. 218, n. 1–3, p. 159–173, 2005.

SAMMUT, C.; WEBB, G. I. **Encyclopedia of Machine Learning**. Springer US, 2010.

SARABIA, R.; AQUINO, A.; PONCE, J. M.; LÓPEZ, G.; ANDÚJAR, J. M. Automated identification of crop tree crowns from uav multispectral imagery by means of morphological image analysis. **Remote Sensing**, v. 12, n. 5, p. 1–23, 2020.

SILVA-LUZ, C. L.; PIRANI, J. R.; PELL, S. K.; MITCHELL, J. D. **Anacardiaceae in Flora do Brasil. 2020**. Jardim Botânico do Rio de Janeiro. Disponível em: <<http://floradobrasil.jbrj.gov.br/reflora/floradobrasil/FB4381>>.

SILVA, C. A.; KLAUBERG, C.; HENTZ, Â. M. K.; et al. Comparing the performance of ground filtering algorithms for terrain modeling in a forest environment using airborne LiDAR data. **Floresta e Ambiente**, v. 25, n. 2, 2018.

SHIN, M. **Applications of computer vision to population dynamics: detecting flowering trees in high-resolution cube-sat imagery**. n. May, 2020.

SYRRIS, V.; HASENOHR, P.; DELIPETREV, B.; et al. Evaluation of the Potential of Convolutional Neural Networks and Random Forests for Multi-Class Segmentation of Sentinel-2 Imagery. **Remote Sensing**, v. 11, n. 8, p. 907, 2019. Disponível em: <<https://www.mdpi.com/2072-4292/11/8/907>>.

SANQUETTA, C. . R. .; CORTE, A. P. D. .; RODRIGUES, A. L.; WATZLAWICK, L. F. . **Inventários Florestais: Planejamento e Execução**. Curitiba: Multi-Graphic, 2014.

SANTOS, J. C.; ANJOS, D. V.; DE ALMEIDA, W. R.; AGUIAR, J. J. M.; DELABIE, J. H. C. Ground-dwelling ant diversity in Amazonian secondary forests and neighboring pastures. **Tropical Ecology** **2021 62:2**, v. 62, n. 2, p. 279–287, 2021.

SASAKI, T.; ISHII, H.; MORIMOTO, Y. Evaluating restoration success of a 40-year-old urban forest in reference to mature natural forest. **Urban Forestry and Urban Greening**, v. 32, n. January, p. 123–132, 2018. Disponível em: <<https://doi.org/10.1016/j.ufug.2018.04.008>>.

SAYER, J.; CHOKKALINGAM, U.; POULSEN, J. The restoration of forest biodiversity and ecological values. **Forest Ecology and Management**, v. 201, n. 1, p. 3–11, 2004.

SOUZA, A. DE; MOURA, V.; SILVA, G.; et al. O Desmatamento na Amazônia Legal Brasileira: Case Região do Cone-Sul de Rondônia Deforestation in the Brazilian Legal Amazon : Case of the Southern Cone of Rondônia. **Revista UD Y Ia Geomática**, n. 15, p. 50–58, 2020.

SMITH, C. C.; ESPÍRITO-SANTO, F. D. B.; HEALEY, J. R.; et al. Secondary forests offset less than 10% of deforestation-mediated carbon emissions in the Brazilian Amazon. **Global Change Biology**, v. 26, n. 12, p. 7006–7020, 2020.

SILVA JUNIOR, C. H. L.; ARAGÃO, L. E. O. C.; FONSECA, M. G.; et al. Deforestation-induced fragmentation increases forest fire occurrence in central Brazilian Amazonia. **Forests**, v. 9, n. 6, 2018.

SILVA, R. G. DA C.; MICHALSKI, A. A caminho do Norte: cartografia dos impactos territoriais do agronegócio em Rondônia (Amazônia ocidental). **Confinis**, n. 45, 2020. Disponível em: <<http://journals.openedition.org/confinis/28017>>. Acesso em: 28/5/2021.

SINHA, S.; SHARMA, L. K.; NATHAWAT, M. S. Improved Land-use/Land-cover classification of semi-arid deciduous forest landscape using thermal remote sensing. **Egyptian Journal of Remote Sensing and Space Science**, v. 18, n. 2, p. 217–233, 2015.

SPYROGLOU, G.; FOTELLI, M.; NANOS, N.; et al. Assessing Black Locust Biomass Accumulation in Restoration Plantations. **Forests** **2021, Vol. 12, Page 1477**, v. 12, n. 11, p. 1477, 2021. Disponível em: <<https://www.mdpi.com/1999-4907/12/11/1477/htm>>. Acesso em: 28/12/2021.

STEININGER, M. K. Satellite estimation of tropical secondary forest above-ground

biomass: Data from Brazil and Bolivia. **International Journal of Remote Sensing**, v. 21, p. 1139–1157, 2010.

SUBERI, B.; R. TIWARI, K.; GURUNG, D. B.; M. BAJRACHARYA, R.; K. SITLAULA, B. Effect of Harvesting and Non-Harvested Forest Management on Carbon Stocks. **International Journal of Environment and Climate Change**, , n. January, p. 152–164, 2018.

STEININGER, M. K. Satellite estimation of tropical secondary forest above-ground biomass: Data from Brazil and Bolivia. **International Journal of Remote Sensing**, v. 21, p. 1139–1157, 2010.

SUN, X.; LI, B.; DU, Z.; et al. Surface modelling of forest aboveground biomass based on remote sensing and forest inventory data. **Geocarto International**, v. 36, n. 14, p. 1549–1564, 2021. Disponível em: <<https://www.tandfonline.com/doi/abs/10.1080/10106049.2019.1655799>>. Acesso em: 9/1/2022.

TAQI, A. M.; AWAD, A.; AL-AZZO, F.; MILANOVA, M. The Impact of Multi-Optimizers and Data Augmentation on TensorFlow Convolutional Neural Network Performance. Proceedings - IEEE 1st Conference on Multimedia Information Processing and Retrieval, MIPR 2018. **Anais...** . p.140–145, 2018.

TEIXEIRA-SANTOS, J.; DA CUNHA RIBEIRO, A. C.; WIIG, Ø.; et al. Environmental factors influencing the abundance of four species of threatened mammals in degraded habitats in the eastern Brazilian Amazon. **PLoS ONE**, v. 15, n. 2, p. 1–16, 2020.

TEIXEIRA, H. M.; CARDOSO, I. M.; BIANCHI, F. J. J. A.; et al. Linking vegetation and soil functions during secondary forest succession in the Atlantic forest. **Forest Ecology and Management**, v. 457, n. October 2019, p. 117696, 2020. Elsevier. Disponível em: <<https://doi.org/10.1016/j.foreco.2019.117696>>.

THEOFANOUS, N.; CHRYSAFIS, I.; MALLINIS, G.; et al. Aboveground Biomass Estimation in Short Rotation Forest Plantations in Northern Greece Using ESA's Sentinel Medium-High Resolution Multispectral and Radar Imaging Missions. **Forests 2021, Vol. 12, Page 902**, v. 12, n. 7, p. 902, 2021. Disponível em: <<https://www.mdpi.com/1999-4907/12/7/902/htm>>. Acesso em: 28/12/2021.

TOURNEAU, F. M.; BURSZTYN, M. Assentamentos rurais na Amazônia: Contradições entre a política agrária e a política ambiental. **Ambiente e Sociedade**, v. 13, n. 1, p. 111–130, 2010. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S1414-753X2010000100008&lng=pt&nrm=iso&tlng=pt>. Acesso em: 4/8/2020.

TRIPATHI, P.; PATEL, N. R.; KUSHWAHA, S. P. S. Estimating net primary productivity in tropical forest plantations in India using satellite-driven ecosystem model. **Geocarto International**, v. 33, n. 9, p. 988–999, 2018. Disponível em: <<https://www.tandfonline.com/doi/abs/10.1080/10106049.2017.1323963>>. Acesso em: 24/4/2021.

TURNER, W. Sensing biodiversity: Sophisticated networks are required to make the best use of biodiversity data from satellites and in situ sensors. **Science**, v. 346, n. 6207, p. 301–302, 2014.

TZUTALIN. Git code. Disponível em: <<https://github.com/tzutalin/labelImg>>.

VAN BREUGEL, M.; RANSIJN, J.; CRAVEN, D.; BONGERS, F.; HALL, J. S. Estimating carbon stock in secondary forests: Decisions and uncertainties associated with allometric biomass models. **Forest Ecology and Management**, v. 262, n. 8, p. 1648–1657, 2011. Elsevier.

VAZ, A. M. S. F. **Bauhinia in Flora do Brasil**. 2020. Jardim Botânico do Rio de Janeiro. Disponível em: <<http://floradobrasil.jbrj.gov.br/reflora/floradobrasil/FB22812>>.

VELOSO, G. A.; FERREIRA, M. E.; FERREIRA JÚNIOR, L. G.; BARBOSA DA SILVA, B. Modelling gross primary productivity in tropical savanna pasturelands for livestock intensification in Brazil. **Remote Sensing Applications: Society and Environment**, v. 17, n. December 2019, 2020.

VIRGULINO-JÚNIOR, P. C. C.; CARNEIRO, D. N.; NASCIMENTO, W. R.; COUGO, M. F.; FERNANDES, M. E. B. Biomass and carbon estimation for scrub mangrove forests and examination of their allometric associated uncertainties. (M.-H. Li, Org.) **PLOS ONE**, v. 15, n. 3, p. e0230008, 2020.

VICHARNAKORN, P.; SHRESTHA, R. P.; NAGAI, M.; SALAM, A. P.; KIRATIPRAYOON, S. Carbon stock assessment using remote sensing and forest inventory data in Savannakhet, Lao PDR. **Remote Sensing**, v. 6, n. 6, p. 5452–5479, 2014.

WANG, F.; DING, Y.; SAYER, E. J.; et al. Tropical forest restoration: Fast resilience of plant biomass contrasts with slow recovery of stable soil C stocks. **Functional Ecology**, v. 31, n. 12, p. 2344–2355, 2017. Blackwell Publishing Ltd. Disponível em: <<https://onlinelibrary.wiley.com/doi/full/10.1111/1365-2435.12925>>. Acesso em: 28/12/2021.

WANG, R.; GAMON, J. A.; EMMERTON, C. A.; et al. Detecting intra- and inter-annual variability in gross primary productivity of a North American grassland using MODIS MAIAC data. **Agricultural and Forest Meteorology**, v. 281, n. November 2019, p. 107859, 2020. Disponível em: <<https://doi.org/10.1016/j.agrformet.2019.107859>>.

WANG, D.; FENG, Y.; ATTWOOD, K.; TIAN, L. Optimal threshold selection methods under tree or umbrella ordering. **Journal of Biopharmaceutical Statistics**, v. 29, n. 1, p. 98–114, 2019. Disponível em: <<https://doi.org/10.1080/10543406.2018.1489410>>.

WAGNER, F. H.; SANCHEZ, A.; TARABALKA, Y.; et al. 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**, p. 360–375, 2019.

WU, J.; CHEN, B.; REYNOLDS, G.; et al. **Monitoring tropical forest degradation and restoration with satellite remote sensing: A test using Sabah Biodiversity Experiment**. 1^o ed. Elsevier Ltd., 2020.

WU, Z.; DAI, E.; WU, ZHIFENG; LIN, M. **Assessing differences in the response of forest aboveground biomass and composition under climate change in subtropical forest transition zone**. Elsevier B.V, 2020.

WU, J.; CHEN, B.; REYNOLDS, G.; et al. **Monitoring tropical forest degradation and restoration with satellite remote sensing: A test using Sabah Biodiversity Experiment**. 1^o ed. Elsevier Ltd., 2020.

WU, Y.; WANG, J. J.; QIAN, K.; et al. An energy-efficient deep convolutional neural networks coprocessor for multi-object detection. **Microelectronics Journal**, v. 98, n. December 2019, 2020.

WULDER, M. Optical remote-sensing techniques for the assessment of forest inventory and biophysical parameters. **Progress in Physical Geography**, v. 22, n. 4, p. 449–476, 1998.

YANG, Y.; SAATCHI, S.; XU, L.; et al. Interannual Variability of Carbon Uptake of Secondary Forests in the Brazilian Amazon (2004-2014). **Global Biogeochemical Cycles**, v. 34, n. 6, p. 1–14, 2020.

ZHU, Z.; PIAO, S.; MYNENI, R. B.; et al. Greening of the Earth and its drivers. **Nature Climate Change**, v. 6, n. 8, p. 791–795, 2016.

ZIMBRES, B.; PERES, C. A.; PENIDO, G.; MACHADO, R. B. Thresholds of riparian forest use by terrestrial mammals in a fragmented Amazonian deforestation frontier. **Biodiversity and Conservation**, v. 27, n. 11, p. 2815–2836, 2018. Disponível em: <<https://doi.org/10.1007/s10531-018-1571-5>>. .

ZWIENER, V. P.; LIMA, R. A. F. DE; SÁNCHEZ-TAPIA, A.; ROCHA, D. S. B.; MARQUES, M. C. M. Tree Diversity in the Brazilian Atlantic Forest: Biases and General Patterns Using Different Sources of Information. **The Atlantic Forest**, p. 115–131, 2021. Disponível em: <https://link.springer.com/chapter/10.1007/978-3-030-55322-7_6>. Acesso em: 9/1/2022.

XIAO, X.; SHEN, Z.; QIN, X. Assessing the potential of VEGETATION sensor data for mapping snow and ice cover: A Normalized Difference Snow and Ice Index. **International Journal of Remote Sensing**, v. 22, n. 13, p. 2479–2487, 2001.

XIAO, Z.; LIANG, S.; WANG, J.; et al. Long-Time-Series Global Land Surface Satellite Leaf Area Index Product Derived from MODIS and AVHRR Surface Reflectance. **IEEE Transactions on Geoscience and Remote Sensing**, v. 54, n. 9, p. 5301–5318, 2016.

XIAO, C.; QIN, R.; HUANG, X. Treetop detection using convolutional neural networks trained through automatically generated pseudo labels. **International Journal of Remote Sensing**, v. 41, n. 8, p. 3010–3030, 2020. Disponível em: <<https://doi.org/10.1080/01431161.2019.1698075>>.

XIONG, J.; LIU, Z.; CHEN, S.; et al. Visual detection of green mangoes by an unmanned aerial vehicle in orchards based on a deep learning method. **Biosystems Engineering**, v. 194, p. 261–272, 2020. Disponível em: <<https://doi.org/10.1016/j.biosystemseng.2020.04.006>>.

YANG, Y.; SAATCHI, S.; XU, L.; et al. Interannual Variability of Carbon Uptake of Secondary Forests in the Brazilian Amazon (2004-2014). **Global Biogeochemical Cycles**, v. 34, n. 6, 2020. Disponível em: <<https://onlinelibrary.wiley.com/doi/10.1029/2019GB006396>>. Acesso em: 24/3/2021.

YAO, Q.; HU, X.; LEI, H. Multiscale Convolutional Neural Networks for Geospatial Object Detection in VHR Satellite Images. **IEEE Geoscience and Remote Sensing Letters**, p. 1–5, 2020.

ZHANG, M.; CHEN, Y.; LIU, X.; LV, B.; WANG, J. Adaptive Anchor Networks for Multi-Scale Object Detection in Remote Sensing Images. **IEEE Access**, v. 8, p. 57552–57565, 2020.

ZUMO, I. M.; HASHIM, M.; HASSAN, N. D. Mapping grass above-ground biomass of grazing-lands using satellite remote sensing. **Geocarto International**, 2021. Disponível em: <<https://www.tandfonline.com/doi/abs/10.1080/10106049.2021.1899309>>. Acesso em: 29/5/2021.