

# TAXA DE CRESCIMENTO DA BIOMASSA ACIMA DO SOLO EM FLORESTAS SECUNDÁRIAS AMAZÔNICAS ESTIMADA POR SENSORIAMENTO REMOTO LIDAR E HIPERESPECTRAL

Catherine Torres de Almeida<sup>1</sup>, Lênio Soares Galvão<sup>2</sup>, Jean Pierre Henry Balbaud Ometto<sup>2</sup>, Aline Daniele Jacon<sup>2</sup>, Francisca Rocha de Souza Pereira<sup>2</sup>, Luciane Yumie Sato<sup>2</sup>, Celso Henrique Leite Silva Junior<sup>2,3</sup>, Pedro Henrique Santin Brancalio<sup>4</sup> e Luiz Eduardo Oliveira e Cruz de Aragão<sup>2</sup>

<sup>1</sup>Faculdade de Ciências Agrárias do Vale do Ribeira, Universidade Estadual Paulista "Júlio de Mesquita Filho", Registro, SP, catherine.almeida@unesp.br; <sup>2</sup>Instituto Nacional de Pesquisas Espaciais, São José dos Campos, SP, {lenio.galvao; jean.ometto; luiz.aragao}@inpe.br, alinejacon@hotmail.com, {franrspereira; lucianesato}@gmail.com; <sup>3</sup>University of California Los Angeles, Los Angeles, USA, celso.junior@inpe.br; <sup>4</sup>Escola Superior de Agricultura "Luiz de Queiroz", Universidade de São Paulo, Piracicaba, SP, pedrobrancalion@gmail.com

## RESUMO

A compreensão da taxa de crescimento da biomassa acima do solo (BAS) em florestas sob regeneração natural é essencial para mensurar o sequestro de carbono florestal e auxiliar na mitigação das mudanças climáticas. Neste estudo, estimamos a BAS em 57 amostras de florestas secundárias amazônicas, por meio da combinação de dados aerotransportados LiDAR e hiperespectrais e modelos de aprendizado de máquinas. A idade das florestas secundárias foi determinada pela análise da série temporal de imagens Landsat de 1984 a 2017. As florestas secundárias exibiram uma taxa de recuperação de BAS de 5,7 Mg.ha<sup>-1</sup>.ano<sup>-1</sup>, calculadas por meio de regressão linear ( $R^2 = 0,91$ ). A integração de dados multisensores mostrou grande potencial para apoiar iniciativas de mitigação do clima.

**Palavras-chave** — carbono florestal, Amazônia, imageamento hiperespectral, escaneamento a laser, fusão de dados.

## ABSTRACT

*Understanding the growth rate of aboveground biomass (AGB) in naturally regenerating forests is essential to measure forest carbon sequestration and assist in mitigating climate change. In this study, we estimated the AGB in 57 samples from Amazonian secondary forests, through the combination of LiDAR and hyperspectral airborne data and machine learning models. The age of secondary forests was determined by analyzing the time series of Landsat images from 1984 to 2017. Secondary forests exhibited an AGB recovery rate of 5.7 Mg.ha<sup>-1</sup>.year<sup>-1</sup>, calculated using linear regression ( $R^2 = 0.91$ ). The integration of multisensor data has shown great potential to support climate mitigation initiatives.*

**Key words** — forest carbon, Amazon, hyperspectral imaging, laser scanning, data fusion.

## 1. INTRODUÇÃO

As florestas tropicais amazônicas são cruciais para o balanço global de carbono, armazenando cerca de 86 Pg C na biomassa vegetal acima e abaixo do solo [1]. No entanto, elas também representam uma potencial fonte de carbono quando desmatadas ou degradadas [2]. Sendo assim, evitar o desmatamento e degradação de novas áreas e regenerar a vegetação em áreas já desmatadas geram oportunidades para iniciativas de mitigação das mudanças climáticas. Para atender a esses esforços, é essencial monitorar a biomassa florestal acima do solo (BAS) e seu potencial de recuperação em florestas secundárias [3].

Levantamentos de campo fornecem informações importantes sobre a variabilidade da BAS em florestas secundárias na Amazônia [4]. No entanto, os dados de campo geralmente apresentam amostragem limitada, principalmente em áreas de difícil acesso [5]. O sensoriamento remoto adiciona novas possibilidades para a análise da BAS em escalas espaciais e temporais mais amplas, permitindo a coleta de dados em larga escala. Dados de satélite têm sido amplamente utilizados para gerar mapas de estoque de carbono em florestas tropicais [6]. No entanto, as estimativas de BAS de satélite ainda apresentam grandes incertezas devido a alguns fatores limitantes, como a frequente cobertura de nuvens sobre florestas tropicais, a conhecida saturação do sinal de satélite sobre florestas de alta densidade e a resolução espacial limitada de alguns instrumentos orbitais.

O sensoriamento remoto aéreo oferece uma escala intermediária entre pesquisas de campo e imagens de satélite, permitindo a coleta de dados em alta resolução espacial. Tecnologias avançadas de sensoriamento remoto a bordo de aeronaves, especialmente o sensor LiDAR (*Light Detection and Ranging*), têm sido usadas para fornecer estimativas precisas de BAS em grandes áreas [7]. O LiDAR é reconhecido por seu grande potencial em medir a estrutura florestal em três dimensões e por ser menos afetado pela saturação do sinal, o que permite estimativas precisas de

BAS. Além disso, a combinação de dados de múltiplos sensores, como LiDAR e sensores hiperespectrais, reduz as incertezas na modelagem da BAS, conforme demonstrado por Almeida et al. [8] na Amazônia brasileira. Esses conjuntos de dados e as estimativas de BAS resultantes permitem avaliar a variabilidade da BAS em função da idade das florestas secundárias, possibilitando estimar a taxa de crescimento dessas florestas.

Sendo assim, o objetivo deste estudo é estimar a BAS de florestas secundárias em três áreas da Amazônia brasileira por meio da combinação de dados de sensoriamento remoto LiDAR e hiperespectral aerotransportados e mensurar a taxa de recuperação da BAS ao longo do tempo.

## 2. MATERIAL E MÉTODOS

A área de estudo consiste em três áreas localizadas na Amazônia brasileira: Reserva Adolpho Ducke (DUC) em Manaus/AM, município de Autazes/AM (AUT) e Floresta Nacional do Tapajós em Belterra/PA (TAP). Cada local foi sobrevoado para a coleta de dados aéreos LiDAR e hiperespectrais, obtidos em dois transectos de aproximadamente 12,5 km x 0,3 km por local. Nestes, um total de 57 amostras de 0,25 ha (50 x 50 m) foram alocadas para a estimativa da BAS em área de floresta secundária, sendo 21 amostras em DUC, 22 em AUT e 14 em TAP.

Os dados LiDAR usados são de retorno discreto e foram coletados pelo sistema Trimble HARRIER 68i entre janeiro de 2016 e abril de 2017 [9]. A nuvem de pontos bruta foi pré-processada para obter uma nuvem de pontos normalizada, contendo a altura acima do solo de cada ponto. A nuvem de pontos normalizada foi recortada de acordo com a extensão espacial de cada amostra para calcular 19 métricas LiDAR relacionadas à distribuição de altura (média e percentis) e cobertura do dossel (proporção de retornos e densidade de área foliar).

Os dados hiperespectrais foram adquiridos pelo sensor AISAfenix (Specim, Spectral Imaging, Ltd.) entre setembro e outubro de 2017. O sensor mediu a radiação na faixa espectral de 380–2500 nm, em um total de 361 bandas e uma resolução espacial de 1m. As imagens de radiação foram convertidas em imagens de refletância de superfície corrigidas atmosféricamente com o algoritmo ATCOR-4 (versão 6.3). Em seguida, os dados de refletância foram extraídos de cada uma das 57 amostras para calcular 18 métricas hiperespectrais, dentre bandas de refletância, índices de vegetação e bandas de absorção derivadas da técnica de remoção do contínuo.

Ambas as métricas LiDAR e hiperespectrais das 57 amostras foram usadas para estimar a BAS usando modelos de aprendizado de máquinas desenvolvidos por Almeida et al. [8]. Dos seis diferentes algoritmos de aprendizado de máquina testados por Almeida et al. [8] na Amazônia, selecionamos os três modelos que apresentaram os menores valores de RMSE (raiz do erro médio quadrático) na estimativa da BAS: LMR (Modelo Linear Ridge), RF

(Random Forest) e CB (Cubist). Esses modelos foram calibrados e validados com dados de inventário florestal de 132 parcelas localizadas na Amazônia brasileira. Como os modelos LMR, CB e RF tiveram desempenho aproximadamente semelhante entre si, sem um único melhor modelo, a média da BAS foi calculada a partir das estimativas desses três modelos. Detalhes sobre a etapa de pré-processamento, determinação das métricas LiDAR e hiperespectrais e estratégia de treinamento/validação dos modelos de aprendizado de máquina podem ser encontrados em Almeida et al. [8].

Para obter informações sobre o histórico de uso e cobertura da terra dos locais estudados, possibilitando discriminar as florestas secundárias de outros tipos de florestas e determinar a idade das mesmas, inspecionamos as imagens Landsat de 1984 a 2017 e a série temporal resultante de NDVI (Índice de Vegetação da Diferença Normalizada) e NBR (Índice da Taxa de Queima Normalizada). Dessa forma, foi possível rastrear as mudanças na cobertura florestal causadas pelo desmatamento, seguidas por posterior regeneração natural. Com base nestas séries temporais Landsat, obtivemos a idade das florestas secundárias, caracterizada como o tempo desde o último desmatamento a partir de 2017 (ano de referência).

Para calcular a taxa de crescimento da BAS em florestas secundárias, utilizou-se um modelo de regressão linear simples, considerando a BAS como variável dependente em função da idade da floresta. O intercepto para todos os modelos de regressão foi definido como zero, pois considerou-se que a BAS na idade zero será nula, caracterizada pela perda total da vegetação por desmatamento. Para validar os modelos, examinamos a distribuição dos resíduos em relação aos valores ajustados e a normalidade dos resíduos, usando gráficos QQ (quantil-quantil) e o teste de Shapiro-Wilk. Todas as análises estatísticas consideraram o nível de significância de 0,05 e foram realizadas no ambiente R.

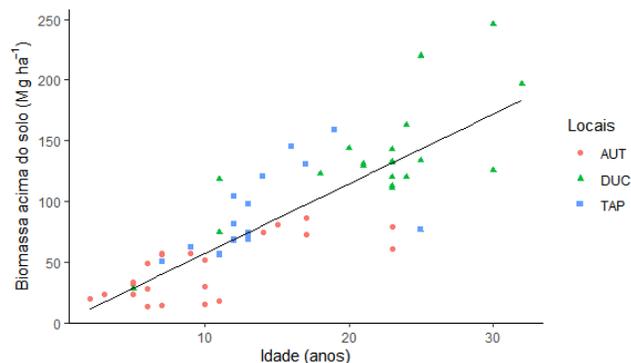
## 3. RESULTADOS

A BAS estimada pelos dados LiDAR e hiperespectrais variou de 12,99 Mg.ha<sup>-1</sup> a 246,23 Mg.ha<sup>-1</sup> para as 57 amostras de floresta secundária avaliadas, com biomassa média de 88,58 Mg.ha<sup>-1</sup>. Ao considerar cada local separadamente, a menor biomassa foi observada em AUT, com média de 44,36 Mg.ha<sup>-1</sup>, variando entre um mínimo de 12,99 e máximo de 86,67 Mg.ha<sup>-1</sup>. A maior biomassa foi verificada em DUC, com média de 132,37 Mg.ha<sup>-1</sup>, mínimo de 28,35 Mg.ha<sup>-1</sup> e máximo de 246,23 Mg.ha<sup>-1</sup>. Já a área TAP, apresentou valores de BAS entre 50,46 e 158,58 Mg.ha<sup>-1</sup>, com média de 92,38 Mg.ha<sup>-1</sup>.

A idade das florestas secundárias estudadas variou entre 2 e 32 anos, sendo que as florestas mais jovens foram observadas no local AUT (entre 2 e 23 anos, com média de aproximadamente 10 anos) e as mais antigas foram verificadas em DUC (entre 5 e 32 anos, com média de 22

anos). A área TAP apresentou idade média de aproximadamente 14 anos, variando entre 7 e 25 anos.

A BAS de todas as amostras avaliadas apresentou relação linear significativa com a idade das florestas ( $p$ -valor  $< 2.2e^{-16}$ ). A idade das florestas secundárias foi responsável pela variação de 91% da biomassa ( $R^2 = 0,91$ ). A taxa de crescimento da biomassa foi de  $5,73 \text{ Mg}\cdot\text{ha}^{-1}\cdot\text{ano}^{-1}$ , considerando-se todas as áreas avaliadas (Figura 1). Considerando-se cada área separadamente, a taxa de crescimento foi de  $4,08 \text{ Mg}\cdot\text{ha}^{-1}\cdot\text{ano}^{-1}$  para AUT,  $5,97 \text{ Mg}\cdot\text{ha}^{-1}\cdot\text{ano}^{-1}$  para DUC e  $6,46 \text{ Mg}\cdot\text{ha}^{-1}\cdot\text{ano}^{-1}$  para TAP.



**Figura 1. Variação da biomassa acima do solo em função da idade da floresta secundária, para os três locais estudados. A linha preta representa a equação linear ajustada para cálculo da taxa de crescimento da biomassa.**

#### 4. DISCUSSÃO

A taxa de recuperação da BAS nas florestas secundárias avaliadas neste estudo ( $5,73 \text{ Mg}\cdot\text{ha}^{-1}\cdot\text{ano}^{-1}$ ) foi similar à encontrada por Poorter et al. [4], de  $6,1 \text{ Mg}\cdot\text{ha}^{-1}\cdot\text{ano}^{-1}$ , baseada em dados de campo compilados de estudos de cronosequência em florestas neotropicais de crescimento secundário. No entanto, Poorter et al. [4] verificaram que o potencial de crescimento da BAS é afetado pela disponibilidade hídrica do local (maior precipitação anual e menor déficit hídrico sazonal). Nossos resultados também foram consistentes aos apresentados por Heinrich et al. [3], em um estudo baseado em dados de satélite, que verificaram uma taxa de sequestro da BAS de  $6,0 \text{ Mg}\cdot\text{ha}^{-1}\cdot\text{ano}^{-1}$  em florestas secundárias jovens ( $< 20$  anos) na região oeste da Amazônia brasileira, onde se encontra nossa área de estudo. Essa região é caracterizada por ter pouco ou nenhum déficit hídrico. Quando foram avaliadas áreas com maior escassez de água (região leste), os autores verificaram uma taxa de crescimento da BAS de  $2,6 \text{ Mg}\cdot\text{ha}^{-1}\cdot\text{ano}^{-1}$ . Sendo assim, áreas com maior escassez hídrica podem apresentar taxas de crescimento mais lentas do que as verificadas nestes estudo. Por exemplo, Lennox et al. [10], ao avaliar uma sucessão secundária de 20 anos na Amazônia oriental, verificou uma taxa de recuperação da BAS de  $4,5 \text{ Mg}\cdot\text{ha}^{-1}\cdot\text{ano}^{-1}$ .

A integração de dados LiDAR e hiperespectrais mostrou-se eficaz para estimar a BAS em florestas secundárias e avaliar sua taxa de recuperação ao longo dos anos de sucessão. Tais estimativas são essenciais para melhorar as previsões dos impactos de distúrbios antrópicos nos fluxos de carbono em paisagens amazônicas altamente biodiversas e complexas.

#### 5. CONCLUSÕES

Dados aéreos LiDAR e hiperespectrais foram usados, juntamente com modelos de aprendizado de máquina (LMR, CB e RF), para estimar a biomassa acima do solo de florestas secundárias na Amazônia brasileira. Além disso, foram avaliadas séries temporais Landsat para obter a idade das florestas secundárias. Concluímos que a BAS apresentou um padrão de variação diretamente relacionado com a idade da floresta, com taxa de crescimento de  $5,7 \text{ Mg}\cdot\text{ha}^{-1}\cdot\text{ano}^{-1}$ . Esse resultado foi consistente com outros estudos de campo e baseados em satélite, destacando o potencial de dados multisensor e abordagens de aprendizado de máquina para capturar variações na BAS em florestas complexas e paisagens dinâmicas modificadas pelo homem na Amazônia brasileira.

#### 6. AGRADECIMENTOS

O presente trabalho foi realizado com apoio da CAPES (Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil) - [Código de Financiamento 001], CNPq (Conselho Nacional de Desenvolvimento Científico e Tecnológico) [bolsas números 140502/2016-5 e 301486/2017-4] e FAPESP (Fundação de Amparo à Pesquisa do Estado de São Paulo) [bolsa número 2020/06734-0]. A coleta de dados aéreos LiDAR e hiperespectrais foi financiada pelo projeto Monitoramento Ambiental por Satélite no Bioma Amazônia (MSA-BNDES) - Atividade 7 "Melhoria de métodos de estimativa de biomassa e modelos de estimativa de emissões para mudança de uso da terra", financiado pelo Fundo Amazônia (processo nº 14209291).

#### 7. REFERÊNCIAS

- [1] S. Saatchi, R. A. Houghton, R. C. Dos Santos Alvalá, J. V. Soares, and Y. Yu, Distribution of aboveground live biomass in the Amazon basin, *Glob. Chang. Biol.*, vol. 13, no. 4, pp. 816–837, 2007, doi: 10.1111/j.1365-2486.2007.01323.x.
- [2] T. O. Assis et al., CO2 emissions from forest degradation in Brazilian Amazon, *Environ. Res. Lett.*, vol. 15, no. 10, 2020, doi: 10.1088/1748-9326/ab9cfc.
- [3] V. H. A. Heinrich et al., Large carbon sink potential of secondary forests in the Brazilian Amazon to mitigate climate change, *Nat. Commun.*, vol. 12, no. 1, pp. 1–11, 2021, doi: 10.1038/s41467-021-22050-1.

- [4] L. Poorter et al., Biomass resilience of Neotropical secondary forests, *Nature*, vol. 530, no. 7589, pp. 211–214, 2016, doi: 10.1038/nature16512.
- [5] D. C. Marvin et al., Amazonian landscapes and the bias in field studies of forest structure and biomass, *Proc. Natl. Acad. Sci. U. S. A.*, vol. 111, no. 48, pp. E5224–E5232, 2014, doi: 10.1073/pnas.1412999111.
- [6] S. J. Goetz et al., Mapping and monitoring carbon stocks with satellite observations: A comparison of methods, *Carbon Balance Manag.*, vol. 4, pp. 1–7, 2009, doi: 10.1186/1750-0680-4-2.
- [7] S. G. Zolkos, S. J. Goetz, and R. Dubayah, A meta-analysis of terrestrial aboveground biomass estimation using lidar remote sensing, *Remote Sens. Environ.*, vol. 128, pp. 289–298, 2013, doi: 10.1016/j.rse.2012.10.017.
- [8] C. T. Almeida et al., Combining LiDAR and hyperspectral data for aboveground biomass modeling in the Brazilian Amazon using different regression algorithms, *Remote Sens. Environ.*, vol. 232, no. 111323, 2019, doi: 10.1016/j.rse.2019.111323.
- [9] J. P. Ometto, B. G. Gorgens, M. Assis, R. Z. Cantinho, F. R. de S. Pereira, and L. Y. Sato, Summary of the Airborne LiDAR transects collected by EBA in the Brazilian Amazon (Version 20210219) [Data set]. Zenodo. <https://doi.org/10.5281/zenodo.4552699>. Zenodo, 2021, [Online]. Available: <https://doi.org/10.5281/zenodo.4552699>.
- [10] G. D. Lennox et al., Second rate or a second chance? Assessing biomass and biodiversity recovery in regenerating Amazonian forests, *Glob. Chang. Biol.*, vol. 24, no. 12, pp. 5680–5694, 2018, doi: 10.1111/gcb.14443.