



POTENCIAL DE DADOS LIDAR FULL-WAVEFORM NA DISCRIMINAÇÃO DE ESTÁGIOS SUCESSIONAIS NA AMAZÔNIA BRASILEIRA

Aline D. Jacon ¹; Lênio Soares Galvão ¹; Rorai Pereira Martins-Neto ²; Pablo Crespo-Peremarch ³; Laura Barbosa Vedovato ⁴; Vinícius Peripato ¹; Isadora Haddad ¹; Catherine Torres de Almeida ⁵; Luiz E. O. C. Aragão ¹; Liana O. Anderson ⁶; Jean P. Ometto ⁷; Ricardo Dalagnol ⁸

¹ Instituto Nacional de Pesquisas Espaciais (INPE), Divisão de Observação da Terra e Geoinformática, São José dos Campos, SP, Brasil.
alinejacon@inpe.br <https://orcid.org/0000-0003-2585-5198>
lenio.galvao@inpe.br <https://orcid.org/0000-0002-8313-0497>
vinicius.peripato@gmail.com <https://orcid.org/0000-0002-3137-211X>
isadora.ruiz@inpe.br <https://orcid.org/0000-0002-1464-366X>
luiz.aragao@inpe.br <https://orcid.org/0000-0002-4134-6708>

² Czech University of Life Sciences Prague, Faculty of Forestry and Wood Sciences, Prague, Czech Republic.
pereira_martins_neto@fld.czu.cz <https://orcid.org/0000-0001-5318-2627>

³ Universitat Politècnica de València, Department of Cartographic Engineering, Geodesy and Photogrammetry, València, Spain.
pabcrepe@cfg.upv.es <https://orcid.org/0000-0003-2241-4493>

⁴ Instituto de Pesquisas Tecnológicas (IPT), São Paulo, SP, Brasil.
lauravedovato2@gmail.com <https://orcid.org/0000-0001-7795-9269>

⁵ Universidade Estadual Paulista Júlio de Mesquita Filho (UNESP), Faculdade de Ciências Agrárias do Vale do Ribeira, Registro, SP, Brasil.
cathe.torres@gmail.com <https://orcid.org/0000-0002-8140-2903>

⁶ Centro Nacional de Monitoramento e Alertas de Desastres Naturais (CEMADEN), São José dos Campos, SP, Brasil.
liana.anderson@cemaden.gov.br <https://orcid.org/0000-0001-9545-5136>

⁷ Instituto Nacional de Pesquisas Espaciais (INPE), Coordenação Geral de Ciências da Terra, São José dos Campos, SP, Brasil.
jean.ometto@inpe.br <https://orcid.org/0000-0002-4221-1039>

⁸ University of California, Center for Tropical Research, Institute of the Environment and Sustainability Los Angeles, CA, USA.
ricds@hotmail.com <https://orcid.org/0000-0002-7151-8697>

RESUMEN. El sensor LiDAR Full-waveform (FWF) ofrece una ventaja prometedora sobre otras tecnologías para representar la estructura vertical del dosel de sucesiones secundarias en la región amazónica. En este estudio, se investigaron los cambios en la estructura vertical de las sucesiones secundarias amazónicas a lo largo del gradiente de vegetación, desde las etapas iniciales hasta las avanzadas de regeneración. El área de estudio estuvo cubierta por 164 parcelas de muestreo distribuidas a lo largo de 12 transectos LiDAR. Las parcelas se agruparon en tres estadios sucesionales (inicial – ES1; intermedio – ES2; avanzado – ES3) y Bosque Maduro (FM). Se extrajeron



un total de 14 métricas FWF LiDAR utilizando el software Waveform LiDAR for Forestry eXtraction (WoLFeX), las cuales se emplearon para discriminar etapas sucesivas utilizando el clasificador Random Forest. El resultado de la validación cruzada para el modelo RF mostró una precisión global y un valor de F1 iguales a 0,80. Una comparación entre clases reveló la importancia de diferentes métricas de FWF para discriminar sucesiones secundarias en la región amazónica, especialmente métricas vinculadas a la altura del dosel, el sotobosque y la descomposición gaussiana.

Palabras-clave: Bosque tropical; sucesión secundaria; métricas LiDAR FWF; WoLFeX; Random Forest.

RESUMO. O sensor LiDAR de forma de onda completa (do inglês *Full-waveform* - FWF) oferece uma vantagem promissora sobre outras tecnologias para representar a estrutura vertical do dossel de sucessões secundárias na região amazônica. Neste estudo, investigamos modificações na estrutura vertical das sucessões secundárias amazônicas ao longo do gradiente de vegetação, desde os estágios iniciais até os avançados de regeneração. A área de estudo foi coberta por 164 parcelas amostrais distribuídas ao longo de 12 transectos LiDAR. As parcelas foram agrupadas em três estágios sucessionais (inicial – ES1; intermediário – ES2; avançado – ES3) e Floresta Madura (FM). Um total de 14 métricas FWF LiDAR foram extraídas usando o software *Waveform LiDAR for Forestry eXtraction* (WoLFeX) e utilizadas para discriminar os estágios sucessionais a partir do classificador Random Forest. O resultado da validação cruzada para o modelo RF apresentou uma Precisão Geral e F1-score médio ponderado de 0,80. Uma comparação entre classes revelou a importância de diferentes métricas FWF para discriminar sucessões secundárias na região amazônica, em especial as métricas ligadas à altura do dossel, sub-bosque e à decomposição gaussiana.

Palavras-chave: Floresta tropical; sucessão secundária; métricas LiDAR FWF; WoLFeX; Random Forest.

ABSTRACT. Full-waveform LiDAR (FWF) offers a promising advantage over other technologies for representing the vertical canopy structure of secondary successions in the Amazon region. In this study, we investigated changes in the vertical structure of Amazonian secondary successions along the vegetation gradient, from early to advanced stages of regeneration. The study area was covered by 164 sample plots distributed along 12 LiDAR transects. The plots were grouped into three successional stages (early – ES1; intermediate – ES2; advanced – ES3) and Mature Forest (FM). A total of 14 FWF LiDAR metrics were extracted using Waveform LiDAR for Forestry eXtraction (WoLFeX) software and used to discriminate the successional stages using the Random Forest classifier. The cross-validation result for the RF model showed an Overall Accuracy and a weighted average F1-score of 0.80. A comparison between classes revealed the importance of different FWF metrics to discriminate secondary successions in the Amazon region, especially metrics linked to canopy height, understory and Gaussian decomposition.

Keywords: Tropical forest; secondary succession; FWF LiDAR metrics; WoLFeX; Random Forest.

1. INTRODUÇÃO

As florestas secundárias são componentes cada vez mais importantes das paisagens modificadas pelo homem (Poorter *et al.*, 2021), pelo potencial sequestro de carbono desempenhado por esses ecossistemas, além de serem uma alternativa economicamente viável para fins de restauração passiva (Strassburg *et al.*, 2019; Heinrich *et al.*, 2021). Essas florestas são estabelecidas através do processo de sucessão secundária, onde ocorre a recolonização espontânea e gradual da vegetação após a remoção completa, ou quase completa, da cobertura florestal existente para uso antrópico, geralmente para agricultura ou pastagem (Chazdon, 2014). O restabelecimento da vegetação em áreas abandonadas é essencial para fornecer habitat para a biodiversidade e meios de subsistência sustentáveis para as pessoas (Brancalion *et al.*, 2019; Rozendaal *et al.*, 2019), tendo grande potencial para mitigar as alterações climáticas, entre outros serviços ecossistêmicos (Chazdon *et al.*, 2016).

À medida que a sucessão avança, normalmente ocorrem modificações importantes na estrutura do dossel florestal, como o aumento da complexidade de características biofísicas da vegetação



ao longo do perfil vertical. Devido a esse aumento na heterogeneidade e complexidade das florestas secundárias, a tecnologia LiDAR aerotransportado possibilita uma quantificação mais precisa de atributos estruturais importantes, como altura do dossel, densidade da área foliar, área basal e biomassa acima do solo (Almeida *et al.*, 2019; Ometto *et al.*, 2023). Um tipo de dado que tem sido pouco explorado como potencial fonte de informação é o dado LiDAR aerotransportado de Forma de Onda Completa (Full-waveform - FWF).

Dados FWF possuem a potencial vantagem de melhorar a representação da estrutura da floresta, uma vez que a forma de onda contém as propriedades de todos os elementos que interceptam o caminho do feixe emitido (Pirotti, 2011). Com mais informações de diferentes camadas verticais, há maior chance de representar a vegetação do sub-bosque em florestas com múltiplos estratos (Crespo-Peremarch *et al.*, 2020). No entanto, até onde sabemos, não há investigações na literatura abordando o uso desse tipo de dado, adquiridos por levantamentos aéreos de *small-footprint*, para caracterizar florestas secundárias de diferentes estágios sucessionais na Amazônia brasileira.

Neste contexto, este estudo teve como objetivo explorar o potencial das métricas extraídas a partir de dados LiDAR aerotransportado FWF, para caracterizar as modificações estruturais e discriminar diferentes estágios sucessionais, assim como áreas de Floresta Madura, na Amazônia brasileira, através da aplicação de método de classificação supervisionada *Random Forest*.

2. MATERIAL E MÉTODOS

2.1. Área de estudo e definição dos estágios sucessionais.

O estudo foi conduzido na Floresta Amazônica brasileira, onde 164 parcelas amostrais circulares, cada uma com diâmetro de 50 m, foram extraídas de 12 transectos LiDAR aerotransportados. As parcelas estão localizadas na porção leste da Amazônia, em uma faixa considerada de moderado a alto déficit hídrico (*Maximum Cumulative Water Deficit* —MCWD entre -446,8 a -244,8 mm·ano⁻¹) (Figura 1-A). Para atribuir a idade de regeneração da vegetação a cada parcela amostral, utilizou-se o produto de idade de floresta secundária gerado por Silva Junior *et al.* (2020), variando de 1 a 33 anos. Assumimos três estágios sucessionais, baseado na disponibilidade de amostras por idade: Estágio inicial (1 a 10 anos - ES1); intermediário (11 a 20 anos - ES2); e avançado (21 a 33 anos - ES3) (Figura 1-B-C). Também foram amostradas parcelas de Floresta Madura (FM) a partir dos dados de uso e cobertura da terra do MapBiomas (MapBiomas Project, 2021).

Para reduzir a influência das bordas nas parcelas amostrais, um *buffer* negativo de 60 m foi aplicado ao redor das áreas florestais, e apenas áreas maiores que 1 hectare foram incluídas na análise (Vedovato, 2022). Foi estabelecida uma distância mínima de 300 m entre as parcelas circulares para evitar autocorrelação ou dependência espacial dos dados.

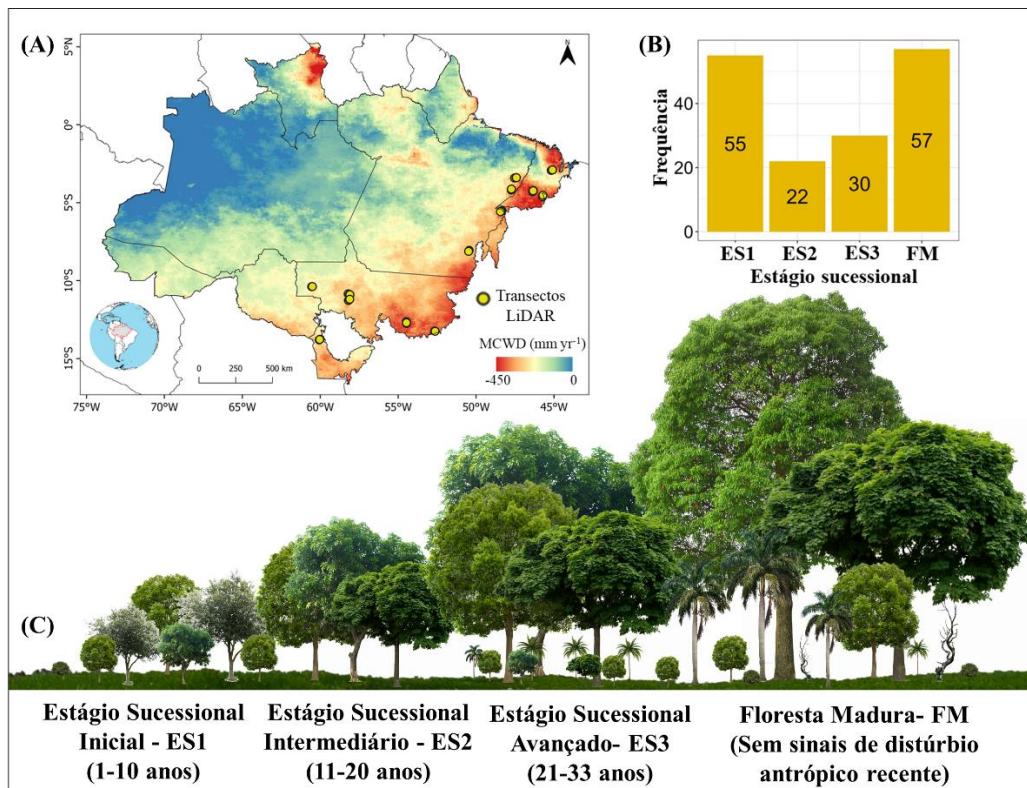


Figura 1. (A) Localização dos transectos LiDAR aerotransportados utilizados no estudo; (B) Número de parcelas amostrais representando cada estágio sucesional (ES1 – Estágio Inicial; ES2 – Estágio Intermediário; ES3 – Estágio Avançado) e Floresta Madura (FM); (C) Representação esquemática das diferenças esperadas na estrutura da vegetação entre estágios sucessionais e floresta madura na região amazônica.

2.2. Processamento de dados LiDAR FWF e métricas derivadas.

Os 12 transectos LiDAR usados aqui fazem parte do projeto Estimativa de Biomassa na Amazônia (EBA) (Ometto *et al.*, 2023). Os dados LiDAR em forma de onda completa foram adquiridos entre os anos de 2016 e 2018 pelo sensor Trimble HARRIER 68i a bordo de um avião, cobrindo transectos no solo com aproximadamente 600 hectares (12 km × 0,5 km). O sensor opera no comprimento de onda do infravermelho próximo, produzindo uma pequena área de 30 cm. A altura média de vôo foi de 600 m acima do nível do solo, com um ângulo máximo de varredura de ± 22,5 graus fora do nadir. A densidade média de pulso foi de 4,8 pulsos·m⁻².

O processamento e extração das métricas FWF foram realizados utilizando o software WoLFeX (Crespo-Peremarch; Ruiz, 2020). Um total de 14 métricas foram extraídas dentro de quatro categorias relacionadas à altura (WD), picos (NP, START PEAK, PEAK END), sub-bosque (HFEV, HFEVT, FVU, NFVU) e decomposição gaussiana (N GS, N GS STARTPEAK, N GS ENDPEAK, BC, BCD, CD), a partir de voxels com dimensões de 1m x 1m x 0,30 m (x, y, z). Os valores médios de cada métrica foram contabilizados e associados à cada parcela. Uma descrição mais detalhada pode ser encontrada em Crespo-Peremarch e Ruiz (2020). Para as métricas do sub-bosque, foi utilizado um limiar mínimo de 1 m e máximo de 5 m para representar possíveis divisões entre sub-bosque e copa. Um modelo digital de terreno (DTM) foi gerado para normalização de altura (Dalagnol *et al.*, 2021).



2.3. Análise de dados.

Para a classificação dos estágios sucessionais (ES1, ES2 e ES3) e FM, utilizamos o algoritmo de aprendizado de máquina amplamente reconhecido *Random Forest* (RF) (Breiman, 2001). Diferentes combinações dos parâmetros de RF (“*Ntree*” e “*mtry*”) foram testadas na classificação e os selecionados foram aqueles que produziram a maior precisão geral de classificação. Para validar os resultados, foi realizada uma abordagem de validação cruzada (5-fold/10 times) (De Almeida, 2020). Para avaliar o desempenho da classificação calculamos, a partir da matriz de confusão, o F1-score por classe, assim como o F1-score geral ponderado e a Precisão Geral (do inglês *Overall Accuracy* - OA) (Brownlee, 2020). A classificação RF foi realizada em linguagem de programação R usando o pacote *caret* (Kuhn, 2008). Também calculamos os valores de importância das cinco métricas mais relevantes na classificação para cada classe. Este resultado foi fornecido pela função *varImp* no pacote *caret* do R (Kuhn, 2008). Algumas dessas métricas foram analisadas estatisticamente utilizando testes não paramétricos de Kruskal-Wallis e U de Mann-Whitney, para testar as diferenças entre as classes (SS1, SS2, SS3 e FM). Todas as análises estatísticas foram realizadas no ambiente R versão 4.2.2 (R Core Team, 2022).

3. RESULTADOS E DISCUSSÃO

O resultado da validação cruzada para o modelo de classificação RF, com quatro classes (ES1, ES2, ES3 e FM) utilizando 14 métricas FWF, apresentou uma Precisão Geral e F1-score médio ponderado de 0,80. As classes com diferenças extremas no desenvolvimento estrutural do dossel como ES1 e FM exibiram os melhores resultados de classificação com F1-score (Tabela 1), de 0,81 e 0,96 respectivamente. A classe ES2, referente às áreas de estágio intermediário de sucessão, apresentou desempenho inferior em relação às outras classes com F1-score de 0,58.

Tabela 1. Matriz de confusão da validação cruzada do modelo Random Forest para quatro classes de floresta. Os acertos de cada classe estão em negrito na diagonal.

		Predito				
		ES1	ES2	ES3	FM	F1-score
Referência	ES1	46	2	7	0	0.81
	ES2	8	11	3	0	0.58
	ES3	4	3	20	3	0.65
	FM	0	0	2	55	0.96

As cinco métricas consideradas mais importantes para a discriminação de cada classe estão ilustradas na Figura 2. A métrica WD (*Waveform Distance*), relacionada à altura do dossel, obteve alta importância na discriminação de três das quatro classes analisadas (Figura 2-A; B; D). Outras métricas também se destacaram com altos valores de importância relativa específica para cada classe como NFVU (*Number of Filled voxels at the understory – 1 a 5m*) (Figura 2-C), relacionada a ocupação do sub-bosque, BC (*Bottom of canopy*), CD (*Canopy distance*) e N GS ENDPEAK (*Number of Gaussian curves between the height of the boundary and the ground*) (Figura 2-B) da categoria de decomposição gaussiana. Uma comparação entre classes revelou a importância das métricas FWF de diferentes categorias (altura, picos, sub-bosque e

de decomposição gaussiana) para discriminar sucessões secundárias na região amazônica, em especial as métricas ligadas à altura do dossel, sub-bosque e à decomposição gaussiana.

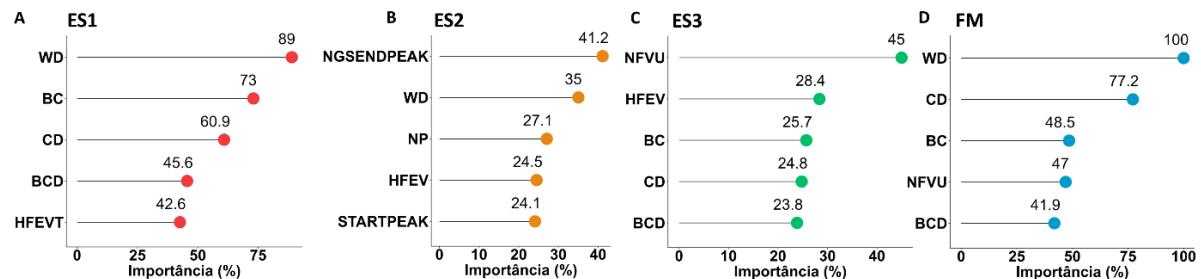


Figura 2. Importância relativa das cinco principais métricas no modelo RF para cada uma das classes: (A) Estágio inicial - ES1; (B) Estágio intermediário - ES2; (C) Estágio avançado - ES3; (D) Floresta madura - FM. WD (*Waveform distance*); BC (*Bottom of canopy*); CD (*Canopy distance*); BCD (*Bottom of canopy distance*); HFEVT (*Height of the first empty voxel from a max threshold*); N GS ENDPEAK (*Number of Gaussian curves between the beginning of the waveform and the height of the boundary*); NP (*Number of peaks in the waveform*); HFEV (*Height of the first empty voxel from the ground upwards*); STARTPEAK (*Distance between the beginning of the waveform and the height of maximum energy*); NFVU (*Number of filled voxels at the understory*).

Para a métrica NFVU, que considera a proporção de voxels que contém alguma informação no sub-bosque (entre 1 e 5 m), há uma tendência de redução dos valores de ES1 para ES3 (Figura 3-A), no entanto essa tendência se inverte de ES3 para FM, onde há um aumento da métrica. Esse comportamento pode estar relacionado ao surgimento de clareiras que expõe mais extratos verticais dentro das parcelas, aumentando assim a quantidade de voxels interceptados no sub-bosque em FM.

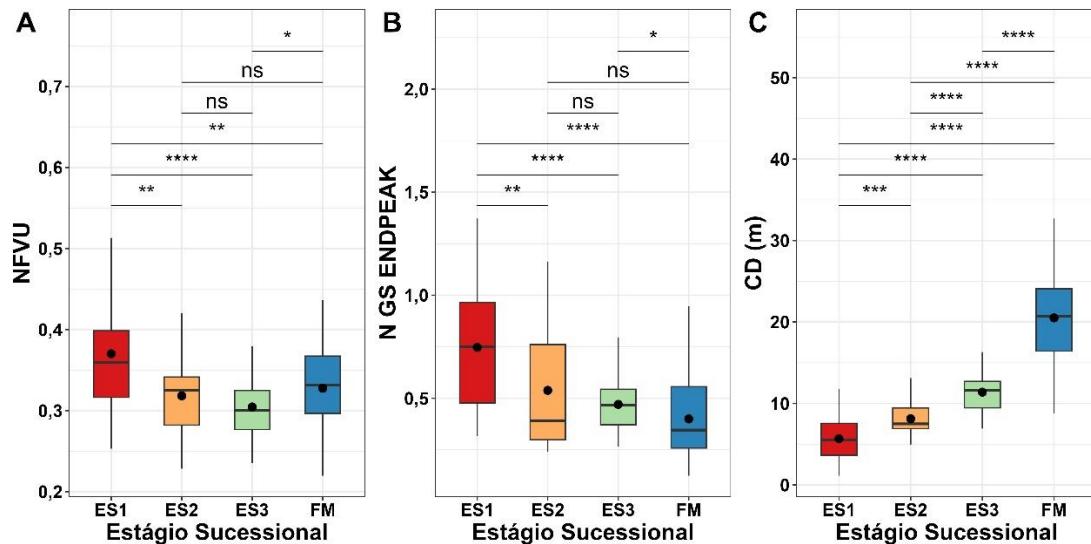


Figura 3. Boxplots de três métricas FWF consideradas como umas das mais importantes para o modelo RF de quatro classes: (A) NFVU; (B) N GS ENDPEAK; (C) CD. Nível de significância * $p < 0,05$, ** $p < 0,01$, *** $p < 0,001$, **** $p < 0,0001$; “ns” não significativo.

A possível oclusão do sinal, causada pelo espalhamento da energia pelas camadas superiores conforme a floresta cresce em altura (WD), pode estar relacionada aos baixos valores encontrados para NFVU (Figura 4 A-B). A métrica N GS ENDPEAK (Figura 3-B), referente

ao número de curvas gaussianas que estão num limite próximo ao solo, também reflete a oclusão do sinal próximo ao solo, mas possui uma tendência decrescente dos valores de ES1 a FM. Já CD (Figura 3-C), que está relacionada a distância do início da forma da onda até o limite entre o solo e o dossel e que também se aproxima dos valores de altura do topo do dossel para nossos dados, apresentou grande variação entre classes e valores crescentes de ES1 para FM.

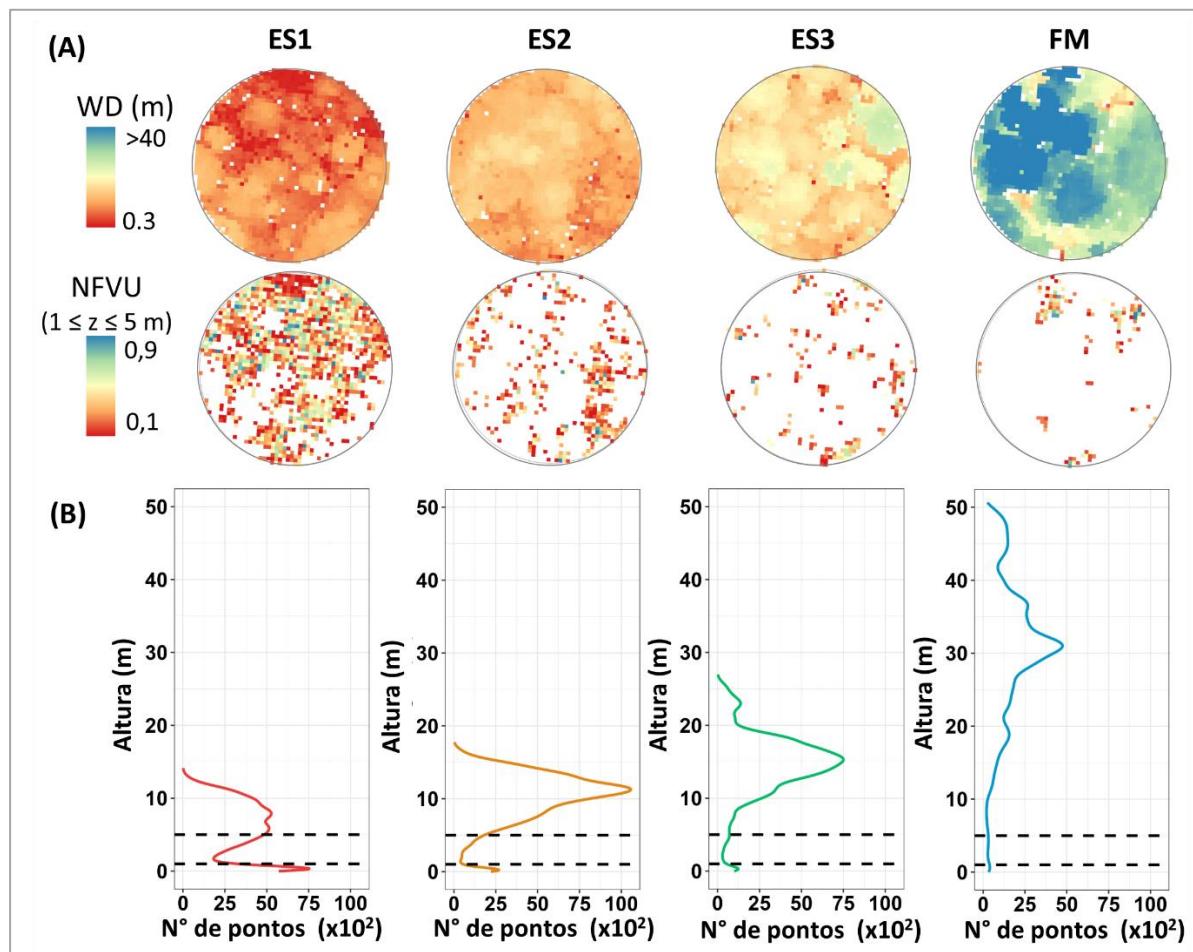


Figura 4. (A) Exemplo das variações nas métricas WD (Waveform distance) e NFVU (Number of filled voxels at the understory) em parcelas amostrais circulares e seus respectivos (B) perfis verticais do número de pontos (número de pontos ou retornos somados a cada 1 m até a altura máxima da parcela) para representar a possível oclusão do sinal no estrato inferior da floresta com o avanço da sucessão (de ES1 para FM). As linhas tracejadas demarcam os limites do sub-bosque (1 e 5 m).

Estudos anteriores (Gu; Cao; Sanchez-Azofeifa, 2018; Duan *et al.*, 2023), utilizando dados LiDAR FWF aerotransportados principalmente em Florestas Tropicais Secas, demonstraram que as estruturas de transição florestal variam com os principais estágios sucessionais ao longo do gradiente sucesional e destacam os desafios e a importância de discriminar as transições entre os estágios, em especial para o intermediário/avançado, e que métricas FWF podem ter grande potencial nessa aplicação.

Embora esse estudo tenha considerado parcelas amostrais localizadas apenas em regiões de moderado a alto déficit hídrico, e de certa forma tenha controlado esse fator climático de alta influência na regeneração da vegetação, outros fatores que afetam a magnitude e a



sustentabilidade do processo de regeneração como o histórico de uso da terra, a cobertura e fragmentação florestal, e a composição e fertilidade do solo, devem ser considerados em trabalhos futuros (Crouzeilles *et al.*, 2020; Heinrich *et al.*, 2021). Esses fatores podem afetar a estrutura vertical das florestas e, portanto, alterar o comportamento das métricas ao longo dos estágios sucessionais.

4. CONCLUSÕES

Este estudo investigou a viabilidade do emprego de dados LiDAR FWF aerotransportados na região Amazônica para caracterizar a dinâmica das modificações na estrutura do dossel ao longo do gradiente de vegetação, desde estágios iniciais até avançados de sucessões secundárias. Examinamos 14 métricas LiDAR FWF derivadas de 164 parcelas amostrais em três estágios sucessionais (ES1, ES2 e ES3), bem como em floresta madura (FM). A métrica WD, relacionada à altura média do dossel, juntamente com as métricas NFVU, relacionada a ocupação do sub-bosque e com BC, CD e N GS ENDPEAK de decomposição gaussiana, mostraram-se altamente influentes na discriminação dos estágios sucessionais alcançando um F1-score ponderado e precisão geral de 0,80.

AGRADECIMENTOS

Agradecemos à equipe do projeto EBA por fornecer os dados LiDAR de forma de onda completa necessários para esta investigação e à Fototerra pelas informações adicionais sobre a campanha de voo. Este trabalho foi apoiado pelo Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) (bolsa número 141035/2021-8) e pela Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código Financeiro 001.

REFERÊNCIAS

- ALMEIDA, C. T. D. *et al.* Combining LiDAR and hyperspectral data for aboveground biomass modeling in the Brazilian Amazon using different regression algorithms. **Remote Sensing of Environment**, [S. l.], v. 232, p. 111323, out. 2019.
- BRANCALION, P. H. S. *et al.* Global restoration opportunities in tropical rainforest landscapes. **Science Advances**, [S. l.], v. 5, n. 7, p. eaav3223, 5 jul. 2019.
- BREIMAN, L. Random Forests. **Machine Learning**, [S. l.], v. 45, n. 1, p. 5–32, 2001.
- BROWNLEE, J. **Imbalanced classification with Python: better metrics, balance skewed classes, cost-sensitive learning**. New York: Machine Learning Mastery, 2020.
- CHAZDON, R. L. *et al.* Carbon sequestration potential of second-growth forest regeneration in the Latin American tropics. **Science Advances**, [S. l.], v. 2, n. 5, p. e1501639, 6 maio 2016.
- CHAZDON, R. L. **Second Growth: The Promise of Tropical Forest Regeneration in an Age of Deforestation**. [S. l.]: University of Chicago Press, 2014. Disponível em: <https://www.bibliovault.org/BV.landing.epl?ISBN=9780226118109>. Acesso em: 11 mar. 2024.



CRESPO-PEREMARCH, P. *et al.* A comparative assessment of the vertical distribution of forest components using full-waveform airborne, discrete airborne and discrete terrestrial laser scanning data. **Forest Ecology and Management**, [S. l.], v. 473, p. 118268, out. 2020.

CRESPO-PEREMARCH, P.; RUIZ, L. A. A Full-Waveform Airborne Laser Scanning Metric Extraction Tool for Forest Structure Modelling. Do Scan Angle and Radiometric Correction Matter? **Remote Sensing**, [S. l.], v. 12, n. 2, p. 292, 15 jan. 2020.

CROUZEILLES, R. *et al.* Achieving Cost-effective Landscape-scale Forest Restoration through Targeted Natural Regeneration. **Conserv. Lett.**, [S.l.], v.13, n. 13, e12709, maio 2020.

DALAGNOL, R. *et al.* Large-scale variations in the dynamics of Amazon forest canopy gaps from airborne lidar data and opportunities for tree mortality estimates. **Scientific Reports**, [S. l.], v. 11, n. 1, p. 1388, 14 jan. 2021.

DE ALMEIDA, C. T. **Integration of lidar and hyperspectral data for forest disturbance characterization and aboveground biomass estimation in the brazilian amazon.** 2020. Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2020.

DUAN, M. *et al.* Characterizing Transitions between Successional Stages in a Tropical Dry Forest Using LiDAR Techniques. **Remote Sensing**, [S. l.], v. 15, n. 2, p. 479, 13 jan. 2023.

GU, Z.; CAO, S.; SANCHEZ-AZOFELA, G. A. Using LiDAR waveform metrics to describe and identify successional stages of tropical dry forests. **International Journal of Applied Earth Observation and Geoinformation**, [S. l.], v. 73, p. 482–492, dez. 2018.

HEINRICH, V. H. A. *et al.* Large carbon sink potential of secondary forests in the Brazilian Amazon to mitigate climate change. **Nature Communications**, [S. l.], v. 12, n. 1, p. 1785, 19 mar. 2021.

KUHN, M. Building Predictive Models in *R* Using the **caret** Package. **Journal of Statistical Software**, [S. l.], v. 28, n. 5, 2008. Disponível em: <http://www.jstatsoft.org/v28/i05/>. Acesso em: 11 mar. 2024.

MAPBIOMAS PROJECT. **Collection 6 of the Annual Land Use Land Cover Maps of Brazil.** <https://mapbiomas.org>. [S. l.: s. n.], 2021. Disponível em: <https://mapbiomas.org>. Acesso em: 6 out. 2021.

OMETTO, J. P. *et al.* A biomass map of the Brazilian Amazon from multisource remote sensing. **Scientific Data**, [S. l.], v. 10, n. 1, p. 668, 30 set. 2023.

PIROTTI, F. Analysis of full-waveform LiDAR data for forestry applications: a review of investigations and methods. **iForest - Biogeosciences and Forestry**, [S. l.], v. 4, n. 3, p. 100–106, 1 jun. 2011.

POORTER, L. *et al.* Multidimensional tropical forest recovery. **Science**, [S. l.], v. 374, n. 6573, p. 1370–1376, 10 dez. 2021.

R CORE TEAM, R. F. for S. C. **R: A Language and Environment for Statistical Computing.** [S. l.: s. n.], 2022. Disponível em: <https://www.r-project.org/>.



ROZENDAAL, D. M. A. *et al.* Biodiversity recovery of Neotropical secondary forests. **Science Advances**, [S. l.], v. 5, n. 3, p. eaau3114, mar. 2019.

SILVA JUNIOR, C. H. L. *et al.* Benchmark maps of 33 years of secondary forest age for Brazil. **Scientific Data**, [S. l.], v. 7, n. 1, p. 269, 14 ago. 2020.

STRASSBURG, B. B. N. *et al.* Strategic approaches to restoring ecosystems can triple conservation gains and halve costs. **Nature Ecology & Evolution**, [S. l.], v. 3, n. 1, p. 62–70, jan. 2019.

VEDOVATO, L. B. **From Past to Present: Impacts of Fire on Amazonian Forests**. 2022. University of Exeter, Exeter, UK, 2022.