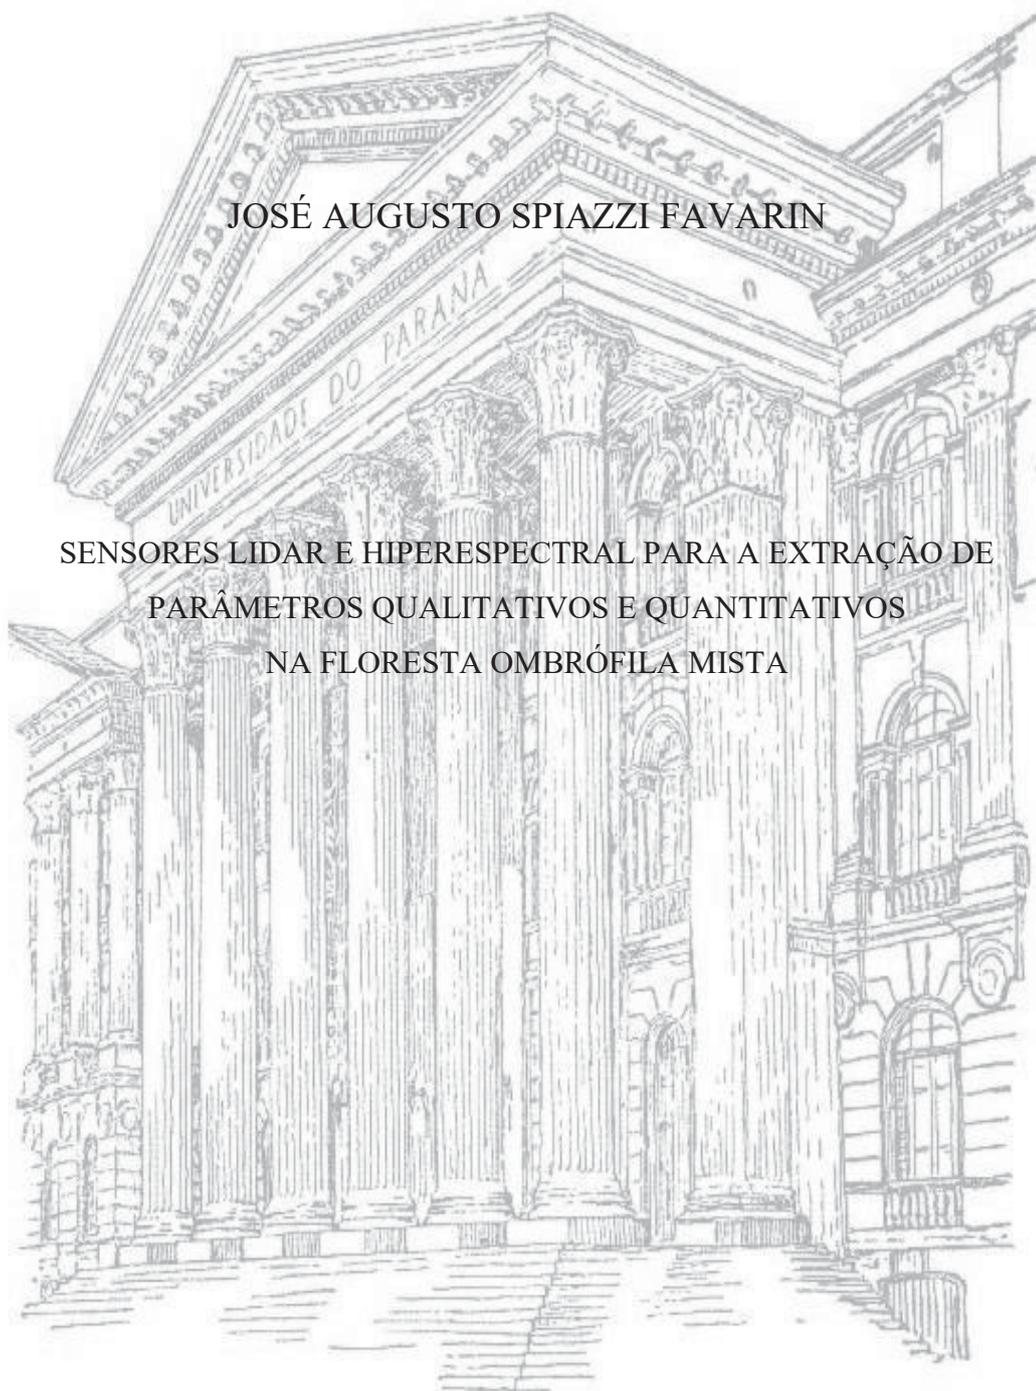


UNIVERSIDADE FEDERAL DO PARANÁ

JOSÉ AUGUSTO SPIAZZI FAVARIN

SENSORES LIDAR E HIPERESPECTRAL PARA A EXTRAÇÃO DE
PARÂMETROS QUALITATIVOS E QUANTITATIVOS
NA FLORESTA OMBRÓFILA MISTA



CURITIBA

2023

JOSÉ AUGUSTO SPIAZZI FAVARIN.

SENSORES LIDAR E HIPERESPECTRAL PARA A EXTRAÇÃO DE
PARÂMETROS QUALITATIVOS E QUANTITATIVOS
NA FLORESTA OMBRÓFILA MISTA

Tese apresentada ao Programa de Pós-Graduação em Engenharia Florestal, Setor de Ciências Agrárias, Universidade Federal do Paraná, como requisito parcial à obtenção do título de Doutor em Engenharia Florestal, Área de Concentração: Manejo Florestal

Orientadora: Prof.^a Dr.^a Ana Paula Dalla Corte
Coorientador: Prof. Dr. Matheus Pinheiro Ferreira
Coorientador: Prof. Dr. Eben North Broadbent

CURITIBA

2023

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

Favarin, José Augusto Spiazzi

Sensores LIDAR e hiperespectral para a extração de parâmetros qualitativos e quantitativos na floresta ombrófila mista / José Augusto Spiazzi Favarin. - Curitiba, 2023.
1 recurso on-line : PDF.

Orientadora: Profa. Dra. Ana Paula Dalla Corte
Coorientadores: Prof. Dr. Matheus Pinheiro Ferreira
Prof. Dr. Eben North Broadbent

Tese (Doutorado) - Universidade Federal do Paraná, Setor de Ciências Agrárias. Programa de Pós-Graduação em Engenharia Florestal. Defesa: Curitiba, 24/11/2023.

1. Florestas - Sensoriamento remoto. 2. Biomassa florestal - Medição.
3. Araucaria Angustifolia. 4. Mata Atlântica. 5. Florestas tropicais. 6 Sensoriamento remoto.
I. Dalla Corte, Ana Paula. II. Ferreira, Matheus Pinheiro. III. Broadbent, Eben North. IV.
Universidade Federal do Paraná, Setor de Ciências Agrárias.
V. Título.

CDD - 634.9
CDU - 634.0.58
528.8



MINISTÉRIO DA EDUCAÇÃO
SETOR DE CIÊNCIAS AGRÁRIAS
UNIVERSIDADE FEDERAL DO PARANÁ
PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO ENGENHARIA
FLORESTAL - 40001016015P0

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 **JOSÉ AUGUSTO SPIAZZI FAVARIN** intitulada: **Sensores LiDAR e Hiperespectral para a extração de parâmetros qualitativos e quantitativos na Floresta Ombrófila Mista**, 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, 24 de Novembro de 2023.

Assinatura Eletrônica
27/11/2023 09:55:20.0
ANA PAULA DALLA CORTE
Presidente da Banca Examinadora

Assinatura Eletrônica
27/11/2023 18:33:51.0
CARLOS ROBERTO SANQUETTA
Avaliador Interno (UNIVERSIDADE FEDERAL DO PARANÁ)

Assinatura Eletrônica
28/11/2023 08:29:05.0
RUDINEY SOARES PEREIRA
Avaliador Externo (UNIVERSIDADE FEDERAL DE SANTA MARIA)

Assinatura Eletrônica
01/12/2023 07:56:40.0
ELISIANE ALBA
Avaliador Externo (UNIVERSIDADE FEDERAL RURAL DE
PERNAMBUCO)

Assinatura Eletrônica
27/11/2023 10:06:18.0
VAGNER ALEX PESCK
Avaliador Externo (UNIVERSIDADE ESTADUAL DO CENTRO-OESTE)

*Dedico esse trabalho ao meu tio, Luiz Henrique, o Dindo, o Chico.
Um dos milhares de vítimas da pandemia e do descaso com a Ciência.*

AGRADECIMENTOS

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior pela concessão de bolsa para que eu pudesse me dedicar à pesquisa.

À Universidade Federal do Paraná, pela oportunidade e estrutura oferecida.

Ao Programa de Pós-Graduação em Engenharia Florestal por possibilitar que eu pudesse me qualificar acadêmica e profissionalmente.

À Prof.^a Ana Paula Dalla Corte por aceitar me orientar no doutorado, pelas ideias e provocações para o desenvolvimento desta tese e pela confiança depositada para a condução e suporte nas atividades do laboratório.

Aos professores Matheus Pinheiro Ferreira e Eben North Broadbent por aceitarem a participar do comitê de orientação, compartilhando conhecimentos que ajudaram a desenvolver esta tese.

Aos colegas Franciele Alba e Franciel Rex que me receberam na casa deles para eu me instalar em Curitiba e dividi-la comigo.

Às colegas Aline Debastiane e Bruna Cabral que me ajudaram quando precisei mudar de casa em meio a uma pandemia e pela parceria em tempos de poucos contatos, inclusive quando eu mesmo peguei Covid.

À colega Manu Guaraná, que sem sua disposição pessoal (e de seu carro), esse trabalho não teria se realizado. Ao Marks, Orso, Kyvia, Letícia, Tarsila, Thiago ‘Capeta’, Thiago, que também estiveram entre os que participaram dos meus campos, aventuras cervejeiras e shows de Rock por Curitiba, inclusive tomando chuva de granizo na cabeça. Através deles estendo o agradecimento aos demais colegas que em outros momentos também estiveram comigo durante essa jornada.

À Maria Emília pelo suporte e parceria no dia a dia do laboratório e aos demais professores do PPGEF pelo aprendizado e conversas nas disciplinas, cafés e confraternizações.

Por fim, às pessoas sem as quais essa trajetória não teria se concretizado, minha mãe Maria Cristina e minha irmã Simone. Sempre me apoiaram em minhas decisões e me incentivaram a persistir na carreira acadêmica. Também, à Gabriela. Prenda que conheci nesta cidade e que esteve comigo durante um dos momentos mais difíceis que já passei. Pelos momentos de alegria e pela compreensão nos momentos em que não me fiz presente. Sou muito feliz por tê-la como companheira. E não poderia faltar, à Janis Joplin, ‘filha’ felina que está sempre junto.

*... toda vez que fazemos autocrítica,
toda vez que testamos nossas ideias no mundo exterior,
estamos fazendo ciência.
Quando somos indulgentes conosco mesmos e pouco críticos,
quando confundimos esperanças e fatos,
Escorregamos para a pseudociência e a superstição.*

Carl Sagan, em “O mundo assombrado pelos demônios” (1995).

RESUMO

A Mata Atlântica apresenta uma rica biodiversidade, que sofre com a expansão populacional desde a chegada dos colonizadores europeus. Atualmente, apenas uma pequena parte da sua cobertura original está disponível. Na região Sul do Brasil se destaca a fitofisionomia da Floresta Ombrófila Mista e tem como espécie característica a *Araucaria angustifolia*. O objetivo geral desta tese foi desenvolver a caracterização do comportamento espectral da espécie *Araucaria angustifolia* em dados coletados por sensor hiperespectral e, ainda, testar o potencial da integração de dados LiDAR de alta densidade com dados hiperespectrais para predições de biomassa acima do solo em ambientes florestais da Floresta Ombrófila Mista. Também foi objetivo realizar uma revisão bibliométrica a respeito da biomassa da *Araucaria* a fim de identificar lacunas nas pesquisas com essa espécie, e utilizar dados do sensor LiDAR para a predição de índices de vegetação. A área de estudo está localizada em um fragmento de Floresta Ombrófila Mista no município de São João do Triunfo-PR. Possui 3 parcelas de 1ha e 1 de 0,5ha, sendo divididas em subparcelas de 10x10m. Foram realizados campos para a obtenção de dados de inventário florestal e dados dos sensores hiperespectrais e LiDAR. A caracterização da floresta foi realizada por meio de parâmetros fitossociológicos e índices de diversidade. A análise bibliométrica apresentou apenas dois trabalhos utilizando o sensoriamento remoto para a predição da biomassa. As espécies mais importantes na área de estudo foram a *Araucaria angustifolia* e a *Nectandra grandiflora*, com Valor de Importância percentual de 28,5% e 11%, respectivamente. A densidade total de árvores foi de 716,86 indivíduos.ha⁻¹, e a área basal encontrada foi de 39,48 m².ha⁻¹. A caracterização espectral mostrou que as regiões do azul, verde e borda do vermelho tiveram o mesmo comprimento de onda (400 nm, 558 nm e 744 nm, respectivamente) tanto para as reflectâncias obtidas com todos os píxeis quanto os *sunlit*. Já a região do Vermelho apresentou comprimento de onda de 672 nm (todos os píxeis) e 677 nm (*sunlit*), enquanto o NIR apresentou 869 nm quando utilizado todos os píxeis e 811 para os *sunlit*. Também foi constatado que não houve diferença no comportamento espectral por classe de diâmetro. O modelo selecionado para a predição da biomassa nas árvores da área de estudo apresentou um R² de 0,9572. A modelagem com os dados LiDAR teve o modelo selecionado com R² de 0,6614, enquanto a modelagem com os dados hiperespectrais apresentou R² de 0,3402 no modelo selecionado. Quando realizada a integração dos dados, o modelo com os dados LiDAR passou a ter um R² de 0,6889. Entre os 20 índices de vegetação utilizados nesses estudos, o que apresentou melhor ajuste a partir de dados LiDAR foi o PSRI (R²=0,549). Assim, concluiu-se que foi possível fazer a caracterização da Araucária com dados hiperespectrais e que não houve diferença no comportamento espectral por classes de diâmetro. A modelagem com a integração dos dados de ambos os sensores confirmou a hipótese de que haveria um aumento no R². Constatou-se ser possível realizar a modelagem de índices de vegetação a partir de métricas obtidas de nuvem de pontos Lidar.

Palavras-chave: sensoriamento remoto, índice de vegetação, mata atlântica, araucária, biomassa.

ABSTRACT

The Atlantic Forest has a rich biodiversity, which has suffered from population expansion since the arrival of European colonizers. Currently, only a small portion of its original coverage is available. In the southern region of Brazil, the phytophysiology of the Mixed Ombrophilous Forest stands out and its characteristic species is *Araucaria angustifolia*. The general objective of this thesis was to develop a characterization of the spectral behavior of the species *Araucaria angustifolia* in data collected by a hyperspectral sensor and also to test the potential for integrating high-density LiDAR data with hyperspectral data for predictions of above-ground biomass in forest environments. of the Mixed Ombrophylous Forest. The objective was also to carry out a bibliometric review regarding the biomass of *Araucária* in order to identify gaps in research on this species and use data from the LiDAR sensor to predict vegetation indices. The study area is located in a fragment of Mixed Ombrophylous Forest in the municipality of São João do Triunfo–PR. It has 3 plots of 1ha and 1 of 0.5ha, divided into subplots of 10x10m. Fields were carried out to obtain forest inventory data and hyperspectral and LiDAR data. The characterization of the forest was carried out using phytosociological parameters and diversity indices. The bibliometric analysis presented only two works using remote sensing to predict biomass. The most important species in the study area were *Araucaria angustifolia* and *Nectandra grandiflora*, with a percentage Importance Value of 28.5% and 11%, respectively. The total tree density was 716.86 individuals.ha⁻¹, and the basal area found was 39.48 m².ha⁻¹. The spectral characterization showed that the blue, green, and red edge regions had the same wavelength (400 nm, 558 nm, and 744 nm, respectively) for both the reflectances obtained with all pixels and those illuminated by the sun. The Red region presented wavelengths of 672 nm (all pixels) and 677 nm (sunlit), while the NIR presented 869 nm when using all pixels and 811 for sunlit. It was also found that there was no difference in spectral behavior by diameter class. The model selected to predict biomass in trees in the study area presented an R² of 0.9572. Modeling with LiDAR data had the model selected with an R² of 0.6614 while modeling with hyperspectral data presented an R² of 0.3402 in the selected model. When data integration was carried out, the model with LiDAR data now had an R² of 0.6889. Among the 20 vegetation indices used in these studies, the one that presented the best fit from LiDAR data was the PSRI (R²=0.549). Thus, it was concluded that it was possible to characterize *Araucaria* with hyperspectral data and that there was no difference in spectral behavior by diameter classes. Modeling with the integration of data from both sensors confirmed the hypothesis that there would be an increase in R². It was possible to model vegetation indices based on statistics obtained from Lidar point clouds.

Keywords: remote sensing, vegetation index, atlantic forest, araucaria, biomass.

LISTA DE ILUSTRAÇÕES

FIGURA 1 - Perfil Esquemático da Floresta Ombrófila Mista (Mata-de-Araucária).....	27
FIGURA 2 - Espectro Eletromagnético com destaque para a Região do Visível (400 a 700 nm).....	30
FIGURA 3 - Comportamento Espectral da vegetação verde sadia (Live Grass) e vegetação seca (Dry Grass).	31
FIGURA 4 – Cubo de Dados Hiperespectrais do AVIRIS com 224 Bandas Espectrais comparado às 9 Bandas Espectrais do Landsat 8.	34
FIGURA 5 - Curvas Espectrais de diferentes espécies, onde se observa o padrão do Comportamento Espectral da vegetação verde sadia e se diferenciando conforme a espécie.....	35
FIGURA 6 - Componentes e operação do sistema LiDAR.....	39
FIGURA 7 – Localização da área de estudo (Estação Experimental de São João do Triunfo – UFPR) no município de São João do Triunfo–PR.....	44
FIGURA 8 - RPA DJI Matrice 600 com sensores LiDAR e Hiperespectral.	46
FIGURA 9 – Localização das parcelas na área de estudo.....	47
FIGURA 10 – Sobreposição da parcela ARAUCÁRIA no transecto hiperespectral 14.....	50
FIGURA 11 – Comportamento Espectral da Araucária: curva sem filtragem (a) e curva com filtragem (b).	51
FIGURA 12 – a) Recorte da nuvem de pontos do LiDAR para a copa de uma Araucária com os pontos da própria árvore e do sub-bosque sob ela (As); b) nuvem com os pontos do sub-bosque removidos, restando apenas os pontos da Araucária (Aa).	55
FIGURA 13 – Fluxograma da aquisição dos dados à modelagem da biomassa acima do solo.	57
FIGURA 14 – Distribuição dos manuscritos publicados, ao longo do tempo, relacionados com o estoque de carbono e/ou biomassa em <i>Araucaria</i> sp. e indexados nas bases de dados <i>Scopus</i> , <i>Web of Science</i> e/ou <i>Science Direct</i> , até o ano de 2021.....	60
FIGURA 15 – Instituição de afiliação dos autores com publicações, relacionadas com o estoque de carbono e/ou biomassa em <i>Araucaria</i> sp. e indexados nas bases de dados <i>Scopus</i> , <i>Web of Science</i> e/ou <i>Science Direct</i> , até o ano de 2021.....	62
FIGURA 16 – Agências de fomento à pesquisa, relacionadas com o estoque de carbono e/ou biomassa em <i>Araucaria</i> sp. e indexados nas bases de dados <i>Scopus</i> , <i>Web of Science</i> e/ou <i>Science Direct</i> , até o ano de 2021.....	63
FIGURA 17 – Autores com pelo menos três publicações, relacionadas com o estoque de carbono e/ou biomassa em <i>Araucaria</i> sp. e indexados nas bases de dados <i>Scopus</i> , <i>Web of Science</i> e/ou <i>Science Direct</i> , até o ano de 2021.	67
FIGURA 18 – Teia de integração, de cocitação, dos autores com publicações, relacionadas com o estoque de carbono e/ou biomassa em <i>Araucaria</i> sp. e indexados nas bases de dados <i>Scopus</i> , <i>Web of Science</i> e/ou <i>Science Direct</i> , até o ano de 2021.....	68
FIGURA 19 – Comportamento espectral. a) Reflectâncias médias de todos os píxeis amostrados para a araucária e o dossel da FOM; b) Reflectâncias médias dos píxeis sunlit para a araucária e o dossel da FOM.	76

FIGURA 20 – Avaliação do comportamento espectral da espécie Araucária em função das classes de DAP. a) Reflectâncias médias da Araucária de todos os píxeis amostrados por classe de DAP; b) reflectâncias médias da espécie Araucária apenas dos píxeis iluminados (*sunlit*) por classe de DAP. 78

FIGURA 21 – Reflectâncias médias de todos os píxeis amostrados e apenas dos píxeis iluminados (*sunlit*) da Araucária por classes de diâmetros. a) Classe 1, 18,8 – 28,8 cm; b) Classe 2, 28,9 – 38,9 cm; c) Classe 3, 39,0 – 49,0 cm; d) Classe 4, 49,1 – 59,1 cm; e) Classe 5, 59,2 – 69,2 cm; f) Classe 6, 69,3 – 79,3 cm; g) Classe 7, 79,4 – 89,4 cm; h) Classe 8, 89,5 – 109,2 cm..... 79

LISTA DE TABELAS

TABELA 1 – Índices de vegetação utilizados em trabalhos no Brasil a partir de dados de sensores hiperespectrais. (continua)	37
TABELA 2 – Resumo estatístico dos dados de Watzlawick (2002) usados para a predição da biomassa acima do solo para a espécie <i>Araucaria angustifolia</i>	48
TABELA 3 – Resumo estatístico das áreas de copas delimitadas sobre o ortomosaico.	50
TABELA 4 – Índices de vegetação.	53
TABELA 5 - Algoritmos e hiperparâmetros utilizados nas modelagens de biomassa acima do solo e dos índices de vegetação.	56
TABELA 6 – Distribuição dos trabalhos por país.....	63
TABELA 7 – Distribuição dos trabalhos por espécies, relacionadas com o estoque de carbono e/ou biomassa em <i>Araucaria</i> sp. e indexados nas bases de dados <i>Scopus</i> , <i>Web of Science</i> e/ou <i>Science Direct</i> , até o ano de 2021.....	64
TABELA 8 – Distribuição dos trabalhos conforme os objetivos propostos, relacionadas com o estoque de carbono e/ou biomassa em <i>Araucaria</i> sp. e indexados nas bases de dados <i>Scopus</i> , <i>Web of Science</i> e/ou <i>Science Direct</i> , até o ano de 2021.....	65
TABELA 9 – Distribuição por material, relacionados com o estoque de carbono e/ou biomassa em <i>Araucaria</i> sp. e indexados nas bases de dados <i>Scopus</i> , <i>Web of Science</i> e/ou <i>Science Direct</i> , até o ano de 2021.....	66
TABELA 10 – Composição florística da área de estudo. (continua)	69
TABELA 11 – Parâmetros fitossociológicos da área de estudo. (continua)	72
TABELA 12 – Píxeis e píxeis <i>sunlit</i> amostrados para a espécie <i>Araucaria angustifolia</i>	75
TABELA 13 – Píxeis e píxeis <i>sunlit</i> amostrados para o dossel da Floresta Ombrófila Mista (exceto araucária).....	75
TABELA 14 – Comprimentos de onda da espécie Araucária.....	76
TABELA 15 – Comprimentos de onda da espécie Araucária para as classes de DAP.....	80
TABELA 16 – ANOVA para as classes de diâmetro da espécie <i>Araucaria angustifolia</i>	80
TABELA 17 – Resumo estatístico das variáveis preditoras DAP e H das árvores selecionadas para esse estudo.	81
TABELA 18 - Indicadores estatísticos da modelagem da biomassa acima do solo para <i>A. angustifolia</i>	82
TABELA 19 – Métricas de ajuste dos modelos de biomassa com dados LiDAR.	84
TABELA 20 – Indicadores de ajuste dos modelos de biomassa acima do solo através de dados hiperespectrais (continua).....	86
TABELA 21 – Comparativo entre a modelagem da biomassa com apenas nuvens de pontos LiDAR e as nuvens integradas com dados hiperespectrais utilizando todos os pixels.....	88
TABELA 22 – Métricas de ajuste dos modelos de biomassa com a integração dos dados LiDAR com os dados hiperespectrais utilizando todos os pixels.....	90

TABELA 23 - Comparativo entre a modelagem da biomassa com apenas nuvens de pontos LiDAR e as nuvens integradas com dados hiperespectrais utilizando apenas os pixels iluminados (<i>sunlit</i>).	91
TABELA 24 - Métricas de ajuste dos modelos de biomassa com a integração dos dados LiDAR com os dados hiperespectrais utilizando apenas os pixels iluminados (<i>sunlit</i>).	92
TABELA 25 – Resumo das modelagens com apenas os modelos selecionados.....	93
TABELA 26 – Métricas de ajuste do modelo com melhor desempenho de cada índice de vegetação a partir de dados do sensor LiDAR.....	95
TABELA 27 – Métricas LiDAR com importância maior ou igual a 90 %.	97

LISTA DE ABREVIATURAS E SIGLAS

Aa	Nuvem com somente os pontos da árvore de Araucária
AB	Área basal (m ²)
ACI	<i>Anthocyanin Content Index</i>
AGB	Biomassa Acima do Solo
ALS	<i>Airborne Laser Scanner</i>
ANAC	Agência Nacional de Aviação Civil
ANN	<i>Artificial Neural Network</i>
ANOVA	Análise de variância
APG IV	<i>Angiosperm Phylogeny Group IV</i>
ARI	<i>Anthocyanin Reflectance Index 1</i>
As	Nuvem com pontos da árvore de Araucária e o sub-bosque sob ela
AVIRIS	<i>Airborne visible/infrared imaging spectrometer</i>
B	Região do azul do espectro eletromagnético
CAP	Circunferência à altura do peito
CAPES	Coordenação de Aperfeiçoamento de Pessoal de Nível Superior
CARI	<i>Chlorophyll absorption reflectance index</i>
Cig	<i>Chlorophyll Index green</i>
Cire	<i>Chlorophyll Index red-edge</i>
CNN	<i>Convolution Neural Network</i>
CNPq	Conselho Nacional de Desenvolvimento Científico e Tecnológico
CONICET	<i>Consejo Nacional de Investigaciones Científicas y Técnicas</i>
COP	Conferência das Partes
CRI 1	<i>Carotenoid Reflectance Index 1</i>
CRI 2	<i>Carotenoid Reflectance Index 2</i>
DA	Densidade absoluta (indivíduos.ha ⁻¹)
DAP	Diâmetro a Altura do Peito
DoA	Dominância absoluta (m ² .ha ⁻¹)
DoR	Dominância relativa (%)
DR	Densidade relativa (%),
EEM	Espectro eletromagnético
ENET	<i>Elastic net</i>
EVI	<i>Enhanced vegetation index</i>

FA	Frequência absoluta (indivíduos.parcela ⁻¹)
Fcal	Estatística F calculada
FOM	Floresta Ombrófila Mista
FOV	<i>Field of View</i>
FR	Frequência relativa (%),
Ftab	Estatística F tabelada
G	Região do verde do EEM
GEDI	<i>Global Ecosystem Dynamics Investigation</i>
GLAS	<i>Geoscience Laser Altimeter System</i>
GNSS	<i>Global Navigation Satlite System</i>
IAF	Índice de área foliar
IBGE	Instituto Brasileiro de Geografia e Estatística
IDE	<i>Integrated Development Environment</i>
IMU	Unidade de medição inercial
IPCC	Painel Intergovernamental para as Mudanças Climáticas
IV	Índice de vegetação
k-NN	<i>k-nearest neighbour</i>
LiDAR	<i>Light Detection and Ranging</i>
Ln	Logaritmo neperiano
LVIS	<i>Land Vegetation and Ice Sensor</i>
MAE	<i>Mean Absolut Error</i>
MARI	<i>Modified Anthocyanin Reflectance Index</i>
MCARI	<i>Modified CARI</i>
MCTIC	Ministério da Ciência, Tecnologia e Inovação
ML	<i>Machine learning</i>
MSN	<i>Most similar neighbour's inference</i>
N	Número de indivíduos medidos
NA	Sem informação
NDII	<i>Normalized difference infrared index</i>
NDLI	<i>Normalized difference lignin index</i>
NDNI	<i>Normalized difference nitrogen index</i>
NDVI	<i>Normalized Difference Vegetation Index</i>
NDWI	<i>Normalized difference water index</i>
NI	Não identificado

NIR	Região do infravermelho próximo do EEM
ONU	Organização das Nações Unidas
PELD	Programa de Pesquisas Ecológicas de Longa Duração
PI	Bandas com as reflectâncias de todos os píxeis
PLAa	Integração das bandas com as reflectâncias de todos os píxeis e a nuvem com somente os pontos da árvore de Araucária
pLAs	Integração das bandas com as reflectâncias de todos os píxeis e a nuvem com pontos da árvore de Araucária e o sub-bosque sob ela
PRI	<i>Photochemical Reflectance Index</i>
PSND	<i>Pigment sensitive normalized difference</i>
PSRI	<i>Plant senescence reflectance index</i>
R	Região do vermelho do EEM
R ²	Coefficiente de Determinação
RE	Região da borda do vermelho do EEM
REM	Radiação eletromagnética
RENDVI	<i>Red Edge Normalized Difference Vegetation Index</i>
REP	<i>Red edge position</i>
RF	<i>Random Forest</i>
RGB	<i>Red, Green, Blue</i>
RMSE%	<i>Root Mean Square Error</i>
RPA	<i>Remotely Piloted Aircraft</i>
RPAS	<i>Remotely Piloted Aircraft System</i>
RPS	<i>Remotely Piloted Station</i>
RVSI	<i>Red-Edge Vegetation Stress Index</i>
Sd	Desvio padrão
SIPI	<i>Structurally insensitive pigment index</i>
sL	Bandas com as reflectâncias dos píxeis iluminados (sunlit).
sLAa	Integração das bandas com as reflectâncias dos píxeis iluminados (sunlit) e a nuvem com somente os pontos da árvore de Araucária
sLAs	Integração das bandas com as reflectâncias dos píxeis iluminados (sunlit) e a nuvem com pontos da árvore de Araucária e o sub-bosque sob ela
SPEC Lab	Laboratório de Ecologia Espacial e Conservação
Sqrt	Raiz quadrada
SR	<i>Simple ratio</i>

SVM	<i>Support Vector Machine</i>
SVR	<i>Support Vector Regression</i>
TLS	<i>Terrestrial Laser Scanner</i>
TM	<i>Thematic Mapper</i>
UAV	<i>Unmanned Aerial Vehicle</i>
UFL	Universidade da Flórida
UFPR	Universidade Federal do Paraná
UTM	Universal Transversa de Mercator
VANT	Veículo Aéreo Não Tripulado
VARI	<i>Visible atmospherically resistant index</i>
VIG	<i>Visible green index</i>
VIp	Valor de importância percentual (%).
VNIR	Visível, Infravermelho próximo
VREI1	<i>Vogelmann Red Edge Index 1</i>
WI	<i>Water Index</i>
X	Variável preditora
Y	Variável resposta

SUMÁRIO

1	INTRODUÇÃO	21
1.1	JUSTIFICATIVA	23
1.2	OBJETIVOS	25
1.2.1	Objetivo Geral	25
1.2.2	Objetivos Específicos	25
1.3	HIPÓTESES	25
2	REVISÃO BIBLIOGRÁFICA	27
2.1	FLORESTA OMBRÓFILA MISTA	27
2.2	ARAUCÁRIA	28
2.3	BIOMASSA FLORESTAL	28
2.4	SENSORIAMENTO REMOTO.....	30
2.4.1	Aeronave Remotamente Pilotada	32
2.4.2	Sensor Hiperespectral	32
2.4.3	Caracterização espectral	35
2.4.4	Índices de Vegetação	36
2.4.5	Sensor Lidar.....	38
2.5	MODELAGEM DE BIOMASSA COM DADOS DE SENSORIAMENTO REMOTO	40
2.5.1	Modelagem com dados de sensores passivos	40
2.5.2	Modelagem com dados de sensores ativos	40
2.5.3	Modelagem com a integração de sensores passivos e ativos.....	41
2.6	APRENDIZADO DE MÁQUINA	42
2.6.1	Random Forest.....	42
2.6.2	Support Vector Regression.....	42
2.6.3	Elastic Net.....	43
3	MATERIAIS E MÉTODOS	43
3.1	ÁREA DE ESTUDO	43
3.2	ANÁLISE BIBLIOMÉTRICA	45
3.3	COLETA DE DADOS	46
3.3.1	Dados de Sensoriamento Remoto	46
3.3.2	Inventário Florestal	46
3.3.2.1	Diversidade Florística e Estrutura Horizontal	48
3.3.3	Biomassa Florestal.....	48
3.4	PROCESSAMENTO E ANÁLISE DOS DADOS.....	49
3.4.1	Caracterização florestal	49

3.4.2	Geoprocessamento	49
3.4.3	Dados hiperespectrais	50
3.4.3.1	Caracterização espectral	52
3.4.3.2	Índices de Vegetação	52
3.4.4	Dados LiDAR	54
3.4.5	Algoritmos para modelagem e avaliação dos modelos.....	55
3.4.6	Modelagem da Biomassa.....	56
3.4.6.1	Modelagem da Biomassa com dados do sensor LiDAR	58
3.4.6.2	Modelagem da Biomassa com dados Hiperespectrais.....	58
3.4.6.3	Modelagem da Biomassa com a integração dos dados LiDAR e Hiperespectrais	58
3.4.7	Modelagem dos índices de Vegetação com as métricas da nuvem de pontos do LiDAR	59
4	RESULTADOS	60
4.1	ANÁLISE BIBLIOMÉTRICA.....	60
4.2	INVENTÁRIO FLORESTAL E FITOSSOCIOLOGIA	68
4.2.1	Diversidade florística.....	68
4.2.2	Estrutura horizontal da vegetação da área de estudo.	71
4.3	CARACTERIZAÇÃO ESPECTRAL	75
4.3.1	Comportamento espectral da Araucária.....	75
4.3.2	Comportamento espectral da espécie Araucária em função das classes de DAP..	77
4.3.3	Avaliação do comportamento espectral por classe de DAP para a espécie Araucária.....	80
4.4	MODELAGEM DA BIOMASSA AÉREA INDIVIDUAL PARA <i>A. ANGUSTIFOLIA</i>	81
4.4.1	Modelos testados para predição da biomassa aérea individual para <i>A. angustifolia</i>	81
4.4.2	Modelagem da AGB a partir dos dados do sensor LiDAR	83
4.4.3	Modelagem da AGB a partir dos dados hiperespectrais.....	85
4.4.4	Integração dos dados LiDAR e hiperespectrais para predizer a AGB.....	87
4.4.5	Síntese das modelagens da biomassa.....	93
4.5	MODELAGEM DOS ÍNDICES DE VEGETAÇÃO COM DADOS LIDAR.....	94
5	CONCLUSÃO	99
6	RECOMENDAÇÕES	100
	REFERÊNCIAS	101
	APÊNDICE 1 – CORRELOGRAMA COM MÉTODO DE PEARSON ENTRE A AGB E AS MÉTRICAS OBTIDAS A PARTIR NUVEM DE PONTOS LIDAR CONTENDO OS PONTOS DA ARAUCÁRIA E O SUB-BOSQUE (AS).	122

APÊNDICE 2 – CORRELOGRAMA COM MÉTODO DE PEARSON ENTRE A AGB E AS MÉTRICAS OBTIDAS A PARTIR DA NUVEM DE PONTOS LIDAR CONTENDO APENAS OS PONTOS DA ARAUCÁRIA (AA).....	123
APÊNDICE 3 – CORRELOGRAMA COM MÉTODO DE PEARSON ENTRE A AGB E AS BANDAS ESPECTRAIS DO SENSOR HIPERESPECTRAL COM AS REFLECTÂNCIAS OBTIDAS DE TODOS OS PIXELS.	124
APÊNDICE 4 – CORRELOGRAMA COM MÉTODO DE PEARSON ENTRE A AGB E AS BANDAS ESPECTRAIS DO SENSOR HIPERESPECTRAL COM AS REFLECTÂNCIAS OBTIDAS APENAS DOS PIXELS ILUMINADOS (SUNLIT).....	127
ANEXO 1 – DADOS DE BIOMASSA ACIMA DO SOLO PARA A ESPÉCIE <i>ARAUCARIA ANGUSTIFOLIA</i>, ADAPTADO DE WATZLAWICK (2002).	130

1 INTRODUÇÃO

As florestas tropicais sofrem grande pressão da expansão do agronegócio e dos centros urbanos. A Mata Atlântica, que hoje possui apenas 12,4% da cobertura original (Fundação SOS Mata Atlântica e INPE, 2021), é um dos principais biomas do Brasil, possuindo uma grande diversidade de plantas e animais.

Em sua porção meridional, nos estados do Paraná, Santa Catarina e Rio Grande do Sul, destaca-se a fitofisionomia da Floresta Ombrófila Mista (FOM), a qual é composta por uma imensa variedade de espécies arbóreas, incluindo espécies raras e endêmicas, concentrando-se em regiões tropicais e temperadas, constituindo parte da Mata Atlântica na América do Sul (BARBOSA et al., 2022; OLIVEIRA-FILHO et al., 2015), a mais característica delas é a espécie *Araucaria angustifolia* (Bertol.) Kuntze.

De acordo com Carvalho (2003), a espécie *Araucaria angustifolia* possui diferentes denominações populares conforme a região de ocorrência, como Araucária, Pinheiro-do-Paraná, Pinheiro-do-Brasil, Pino Paraná (na Argentina) e Parana Pine (denominação comercial em outros países). Esta espécie sofreu com o seu corte indiscriminado no início do século XX. Possuindo madeira de qualidade, despertou, portanto, o interesse em sua exploração comercial. Atualmente tem como principal interesse comercial as suas sementes, o pinhão (ATANAZIO et al., 2022).

As florestas aparecem como grandes responsáveis pelo armazenamento do carbono nos ecossistemas de todo o mundo, uma vez que o processo de formação de biomassa tem capacidade de estocar o carbono atmosférico, sendo as florestas tropicais e subtropicais as responsáveis por grande parte deste armazenamento (TSEGAY e MENG, 2021; CANADELL e RAUPACH, 2008). A quantificação da biomassa pode ser feita através do método direto, ou seja, destrutivo a campo ou por método indireto, o qual consiste em realizar uma relação de variáveis como o diâmetro a altura do peito (DAP), volume da madeira, altura comercial, altura total e o diâmetro da copa, os quais são relacionados com a biomassa (TEIXEIRA, 2003). Além da altura e o DAP, Silveira et al. (2008) e Chave et al. (2005) incluem a densidade da madeira como variável para a estimativa da biomassa.

O monitoramento das florestas por meio do sensoriamento remoto orbital já é conhecido e consolidado. À medida que novos instrumentos e sensores vão sendo desenvolvidos, faz-se necessário estudar suas aplicações sobre as florestas. É uma área de estudo na Engenharia Florestal muito dinâmica por estar diretamente conectado aos avanços de tecnologias. Há,

assim, uma necessidade de acompanhar o lançamento de novas tecnologias e explorar de diferentes formas as já existentes e aprimorar métodos de aplicação.

O sensoriamento remoto suborbital, através das aeronaves remotamente pilotadas (RPA, do inglês *Remotely Piloted Aircraft*), oferece uma nova geração de sensores que podem, por elas, serem aerotransportados. A possibilidade de se ter um sensor LiDAR (*Light Detection and Ranging*, em tradução livre Detecção e Alcance de Luz) na mesma plataforma que um sensor hiperespectral, potencializa a capacidade de analisar a floresta. Isso proporciona informações morfológicas (altura, forma da copa), fisiológicas (taxa fotossintética), bioquímica (conteúdo de clorofila e água) ou fenológicas (folhas e floração) (SHI et al., 2018).

Sensores hiperespectrais medem a radiação solar refletida pelo dossel em centenas de bandas estreitas e, assim, permitem identificar variações sutis na resposta espectral das árvores, determinando sua detecção remota (FERREIRA, 2017). Estudos como os de Ferreira et al. (2016) e Nevalainen et al. (2017) apresentaram bons resultados na diferenciação de espécies com o uso de dados hiperespectrais. A espectroscopia de campo integrada com dados hiperespectrais permite o monitoramento da floresta e do ambiente, proporcionando características espectrais intrínsecas que ajudam a mapear a vegetação ao nível de espécie (PRASSAD et al., 2015). Assim, dados de bandas estreitas oferecem uma gama de análises sobre a vegetação com o uso de comprimentos de onda específicos, e têm o potencial para que se desenvolvam índices de vegetação específicos para cada espécie.

Os índices de vegetação são resultantes de cálculos radiométricos, os quais indicam a abundância relativa e a atividade da vegetação verde, incluindo índice de área foliar (IAF), porcentagem de cobertura verde, teor de clorofila, biomassa verde e radiação fotossinteticamente ativa (JENSEN, 2011). Como os pigmentos são importantes para a função dos organismos vegetais, sua biossíntese e catabolismo são fortemente regulados, tornando-os marcadores informativos da condição fisiológica da planta e, em última análise, da sua produtividade (GITELSON e SOLOVCHENKO, 2019). Os índices de vegetação (IV) de bandas estreitas possibilitam o emprego de comprimentos de onda específicos, os quais podem estar associados aos pigmentos presentes nas folhas, como clorofila, carotenoides e antocianina. Isso permite que sejam identificados os estágios fenológicos da vegetação, por exemplo. Alguns dos índices de vegetação hiperespectrais mais promissores destinam-se a quantificar as principais respostas fisiológicas da planta como o PRI (*Photochemical Reflectance Index*) e o RVSI (*Red-Edge Vegetation Stress Index*), os quais são altamente sensíveis às mudanças sazonais no estresse ambiental (ROBERTS et al., 2019).

Outro sensor que se popularizou no monitoramento de florestas é o LiDAR. Por ser um sensor ativo, pode ser empregado em situações de baixa iluminação solar, dias nublados, por exemplo, e mesmo assim obter informações sobre a floresta. Este sensor pode caracterizar, com grande precisão, a diversidade estrutural e funcional de florestas, tornando as estimativas de biomassa acima do solo mais confiáveis (ALMEIDA et al., 2019), demonstrando grande aplicação em gerenciamento de precisão de florestas tropicais (FIGUEIREDO et al., 2016). Dessa forma, é possível realizar medidas verticais diretas da vegetação associando tais resultados com a biomassa acima do solo (SATO et al., 2016). Dados LiDAR possibilitam obter métricas sobre a floresta, como a altura das árvores, forma da copa e volume da copa. Outras métricas podem ser derivadas a partir de modelos como o DAP, o volume do tronco e a biomassa.

A fusão de dados hiperespectrais com os dados coletados de sensor LiDAR confere uma poderosa ferramenta para os pesquisadores da área florestal. A combinação entre métricas e variáveis obtidas por ambos os sensores, possibilita um ganho nas predições que já eram realizadas utilizando os dados de cada sensor separadamente e abre para que novas ideias surjam. Um estudo conduzido por Almeida et al. (2021) demonstrou grande potencial para avaliar a estrutura do dossel, biomassa e diversidade de espécies em parcelas de restauração florestal, combinando dados LiDAR e hiperespectrais. Degerickx et al. (2018) integraram dados LiDAR e hiperespectrais visando obter um indicador de saúde das árvores no meio urbano. Para isso, as árvores foram segmentadas com os dados LiDAR e o conteúdo de clorofila e índice de área foliar com dados hiperespectrais e LiDAR.

Por ser o primeiro trabalho a utilizar métricas derivadas de dados LiDAR para realizar a predição de Índices de Vegetação, não foram encontradas, até a conclusão desta tese, referências de trabalhos que já o fizeram. Dessa forma, este trabalho contribuirá para que novas pesquisas sejam realizadas nesse sentido.

1.1 JUSTIFICATIVA

A espécie *Araucaria angustifolia* tem grande interesse, seja do ponto de vista ecológico ou econômico, embora esse último esteja limitado por regulamentações. Ecologicamente, é de grande importância, pois suas sementes servem de alimento para espécies de animais terrestres e aves, inclusive na alimentação humana, com alto teor nutritivo. É a principal espécie da FOM, e por isso também é chamada de Floresta de Araucária. Economicamente, a Araucária contribui

com a renda de produtores rurais através da comercialização do pinhão. Alimento típico da região Sul do Brasil, que é consumido principalmente nos meses de frio no ano.

Devido a essa importância, faz-se necessário calcular a contribuição dessa espécie no estoque de biomassa. Quantificar o estoque de biomassa permite fazer previsões do teor de carbono em uma floresta, contribuindo para os estudos e entendimento das alterações do clima.

Através do sensoriamento remoto é possível obter previsões de biomassa com o uso de diferentes sensores. O uso de dados de sensor LiDAR e Hiperespectral, além de proporcionar um mapeamento mais acurado da floresta, pode proporcionar previsões precisas de índices de vegetação modelados a partir de dados LiDAR, o que ocasionaria uma redução de custo, já que seria necessário apenas o sensor LiDAR.

Para fins de pesquisa, estes sensores, juntamente com as RPAs, têm se tornado uma importante ferramenta para os cientistas desenvolverem estudos sobre as florestas. Com as aplicações desses sensores distintos, seja na geração de índices de vegetação ou obtenção de métricas, pode-se estabelecer correlações com a biomassa e desenvolver modelos para a sua previsão. Da mesma forma, modelos que utilizem ambos, ou seja, a integração dos dados hiperespectrais com as métricas LiDAR. Portanto, esse projeto se justifica por ser o primeiro a propor uma caracterização espectral da Araucária a partir de dados hiperespectrais e a integração desses com métricas obtidas a partir de dados LiDAR, ambos obtidos por RPAs, para a estimativa da biomassa acima do solo e a modelagem de índices de vegetação a partir de dados LiDAR.

1.2 OBJETIVOS

1.2.1 Objetivo Geral

O objetivo geral desta tese foi desenvolver a caracterização do comportamento espectral da espécie *Araucaria angustifolia* em dados coletados por sensor hiperespectral e, testar o potencial da integração de dados LiDAR de alta densidade com dados hiperespectrais para predições de biomassa acima do solo em ambientes florestais da Floresta Ombrófila Mista.

1.2.2 Objetivos Específicos

- Identificar, por meio de revisão bibliométrica, os trabalhos relacionados à pesquisa de biomassa da espécie *Araucaria angustifolia* e apontar possíveis lacunas nestas pesquisas;
- Desenvolver um modelo para predição de biomassa acima do solo da espécie *Araucaria angustifolia*, tendo como base as variáveis coletadas pelo método destrutivo;
- Desenvolver modelos de predição de biomassa acima do solo para a espécie *Araucaria angustifolia* a partir de índices de vegetação de dados hiperespectrais, bem como a partir de dados LiDAR;
- Testar a integração de dados LiDAR de alta densidade e dados hiperespectrais para prever a biomassa acima do solo para a espécie *Araucaria angustifolia*;
- Testar se os índices de vegetação possuem correlações com as métricas obtidas a partir dos dados LiDAR;
- Testar algoritmos de aprendizado de máquina (*Random Forest*, *Elastic Net* e *Support Vector Regression*) para a predição da biomassa acima do solo e dos índices de vegetação.

1.3 HIPÓTESES

Dados hiperespectrais de bandas estreitas permitem a caracterização espectral da *Araucaria angustifolia*, devendo o porte dos indivíduos, representados pelas classes diamétricas, interferir significativamente na resposta espectral da espécie.

A integração de dados LiDAR de alta densidade e os dados hiperespectrais proporcionam uma predição da biomassa acima do solo da espécie *Araucaria angustifolia* com

um coeficiente de determinação (R^2) superior ao quando os dados de ambos os sensores forem tratados separadamente.

Os índices de vegetação, os quais são calculados a partir de dados hiperespectrais, podem apresentar fortes correlações com as métricas extraídas das nuvens de pontos LiDAR de alta densidade, podendo ser explicados pelos mesmos.

2 REVISÃO BIBLIOGRÁFICA

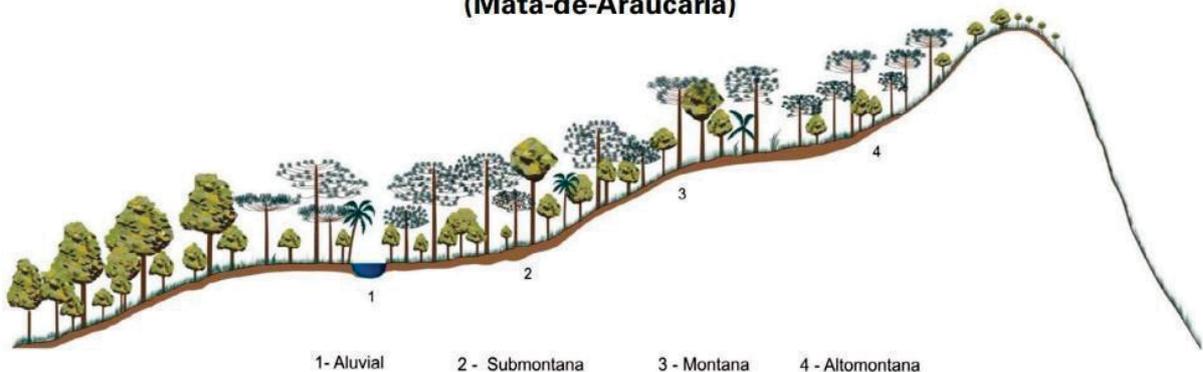
2.1 FLORESTA OMBRÓFILA MISTA

De acordo com Sanquetta e Mattei (2006), a Floresta Ombrófila Mista (FOM) recebe esse nome por ser característica de ambientes úmidos (ombrófila) e geologicamente mista, ou seja, possui elementos da flora oriundos da Oceania (*Araucaria*) e parte das espécies folhosas oriundas da África. Tem a espécie *Araucaria angustifolia* como a espécie mais característica e, por isso, também é chamada de Mata de Araucária ou Floresta de Araucária. Espécies como *Ocotea porosa* (imbuia) e *Ilex paraguariensis* (erva-mate) também são características da FOM, além de espécies das famílias Lauraceae (gêneros *Nectandra* e *Ocotea*), Fabaceae (gêneros *Dalbergia* e *Machaerium*), Meliaceae (*Cedrela fissilis*), Myrtaceae e também as espécies *Podocarpus lambertii* (pinheiro-bravo) e *Syagrus romanzoffiana* (jerivá) (MAACK, 1968).

As florestas com araucárias são formadas por múltiplas associações e agrupamentos que se encontram nos mais variados estágios de sucessão, bem como por diversos estratos de vegetação, que variam sensivelmente conforme as diferentes condições edáficas e microclimáticas (LONGHI, 1997). Por apresentar variações, o IBGE (2012) classifica a FOM em formações: Aluvial, a qual está presente nos terraços antigos ao longo dos rios, Submontana, que ocorre em altitudes entre 50 m e 400 m, Montana, que varia de 400 m até aproximadamente 1.000 m e Altomontana, que supera os 1.000 m de altitude, conforme o perfil apresentado na Figura 1.

FIGURA 1 - Perfil Esquemático da Floresta Ombrófila Mista (Mata-de-Araucária).

Figura 11 - Perfil esquemático da Floresta Ombrófila Mista (Mata-de-Araucária)



FONTE: Adaptado de Veloso et al. (1991)

2.2 ARAUCÁRIA

O gênero *Araucaria* Juss. pertence à família Araucariaceae Henkel & W.Hochst (IGANCI e DORNELLES, 2020), e conforme Garcia (2002), possui árvores normalmente dioicas com casca esfoliante ou íntegra e folhas espiraladas sésseis com o ápice frequentemente pungente, escamiformes a triangular-lanceoladas, monomórficas ou heteromórficas. O gênero *Araucaria* possui cerca de 18 espécies, sendo 13 endêmicas da Nova Caledônia, uma da Ilha de Norfolk e o restante da Nova Guiné, Queensland e América do Sul (LAUBENFELS, 1988).

A espécie *Araucaria angustifolia* ocupa uma ampla área no Brasil (regiões sul e sudeste) e na Argentina (região leste) e produz uma semente conhecida por pinhão (ALVES et al., 2019), e é a única representante da família Araucariaceae na flora autóctone do Brasil (MARCHIORI, 1996). Segundo Carvalho (2003), as árvores medem de 10 a 35 metros de altura e diâmetro à altura do peito (DAP) entre 50 e 120 cm, no entanto, excepcionalmente podem atingir 50 m de altura e ultrapassar os 250 cm de DAP na idade adulta. O tronco extremamente cilíndrico proporciona um alto grau de aproveitamento da madeira, utilizada para a fabricação de móveis finos, fins decorativos, ressonância de interiores e produção de celulose, chapas de fibras ou compensados (SANQUETTA e MATTEI, 2006).

Para Reitz et al. (1988) a madeira da Araucária foi o recurso madeireiro mais amplamente exportado da América Latina por mais de um século. Atualmente a espécie apresenta um grande potencial não madeireiro, como o uso da semente, a qual é um alimento nutritivo e energético, e seus ramos aciculados secos (RODRIGUES et al., 2021). Diante da intensa exploração madeireira, a espécie está em risco de extinção, sendo classificada na Lista da Flora Brasileira Ameaçada como “em perigo” (BRASIL, 2021) e “criticamente em perigo” pela União Internacional de Conservação da Natureza (IUCN, 2018). Portanto, atualmente a Araucária é protegida pela Lei da Mata Atlântica número 11.428 de 2006 (BRASIL, 2006). Devido às restrições legais, as pesquisas acabam sofrendo limitações, especialmente as que envolvem regimes de manejo de florestas nativas de Araucária (ORELLANA et al., 2017), as quais podem contribuir com o desenvolvimento de métodos para as estimativas de biomassa e, conseqüentemente, carbono.

2.3 BIOMASSA FLORESTAL

Biomassa florestal é definida, segundo IPCC (2003), como toda a matéria orgânica existente acima e abaixo do solo, viva ou morta, considerando como biomassa aérea toda a

biomassa viva acima do solo, ou seja, tronco, galhos, casca, sementes e folhas, e, de acordo com Ravindranath e Ostwald (2008), pode ser convertida em energia, com o seu valor expresso em peso por unidade de área. Enquanto isso, Martinelli (1994) conceitua como a quantidade, em massa, de material vegetal em uma floresta, sendo a biomassa viva acima do solo, árvores e arbustos. De acordo com Sanquetta (2002), o termo biomassa florestal pode significar toda a biomassa existente na floresta ou apenas a fração arbórea da mesma, também, pode-se utilizar o termo fitomassa florestal ou fitomassa arbórea.

A quantificação da biomassa pode ser realizada através do método direto, ou seja, destrutivo a campo. Conforme Salati (1994), esse método é interessante e aplicável apenas em pequenas áreas, além disso, serve como forma de calibração dos modelos que contemplam métodos indiretos de estimativas de biomassa. O método indireto, o qual consiste em realizar uma relação de variáveis como o DAP, volume da madeira, altura comercial, altura total e o diâmetro da copa, os quais são relacionados com a biomassa (TEIXEIRA, 2003). Além da altura e do DAP, Silveira et al. (2008) e Chave et al. (2005) incluem a densidade da madeira como variável para a estimativa da biomassa.

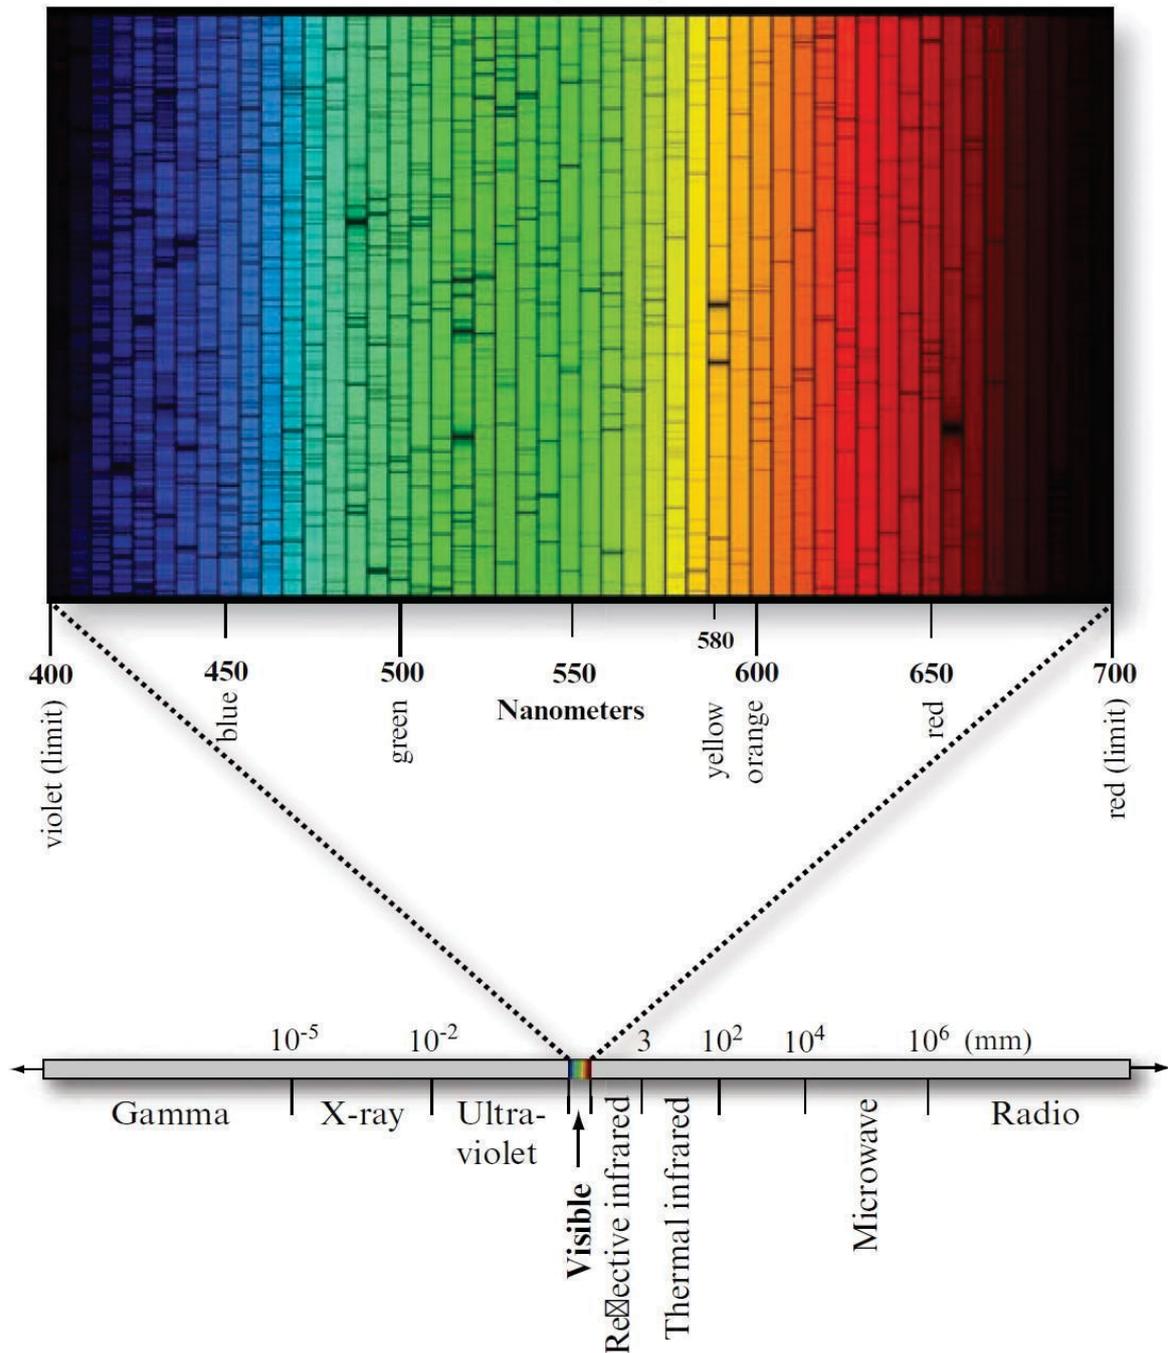
Métodos indiretos fornecem dados essenciais que permitem a extrapolação de estoques de biomassa e carbono para os ecossistemas avaliados (SOMOGYI et al., 2006). De acordo com Sanquetta (2002), quanto maior for a precisão da estimativa da biomassa, maior será a consistência da quantificação de carbono estocado ou liberado na atmosfera pelas florestas, melhorando, de acordo com Lu et al. (2012), o entendimento dos impactos do desmatamento no aquecimento global. Conforme Watzlawick et al. (2009), a biomassa pode ser quantificada utilizando técnicas de sensoriamento remoto para realizar as estimativas que, com os desenvolvimentos relacionados aos avanços no processamento de imagens, tem se obtido uma melhor caracterização da estrutura das florestas e, conseqüentemente, de sua biomassa e carbono.

Entender a distribuição e a dinâmica ao longo do tempo da biomassa arbórea é a chave para o entendimento e monitoramento de ecossistemas florestais. O estoque de carbono florestal representa um importante componente da biomassa total e pode ser agrupado nos seguintes subcomponentes: abaixo do solo e acima do solo (tronco, folhas e galhos) (PIROTTI et al., 2020). Além de estimar o estoque de carbono, segundo Salunkhe et al. (2018), quantificar a biomassa permite estimar o potencial de emissão ou remoção de dióxido de carbono (CO₂) atmosférico; por isso, é importante realizar inventários de diferentes métodos para subsidiar a elaboração de medidas mitigadoras do aquecimento global.

2.4 SENSORIAMENTO REMOTO

O sensoriamento remoto consiste em instrumentos tais como câmeras, escâneres, lasers, dispositivos lineares e/ou matriciais localizados em plataformas como aeronaves ou satélites, os quais registram informações de objetos sem contato físico, nas regiões do ultravioleta, visível, infravermelho e micro-ondas do espectro eletromagnético (JENSEN, 2015) (Figura 2).

FIGURA 2 - Espectro Eletromagnético com destaque para a Região do Visível (400 a 700 nm).

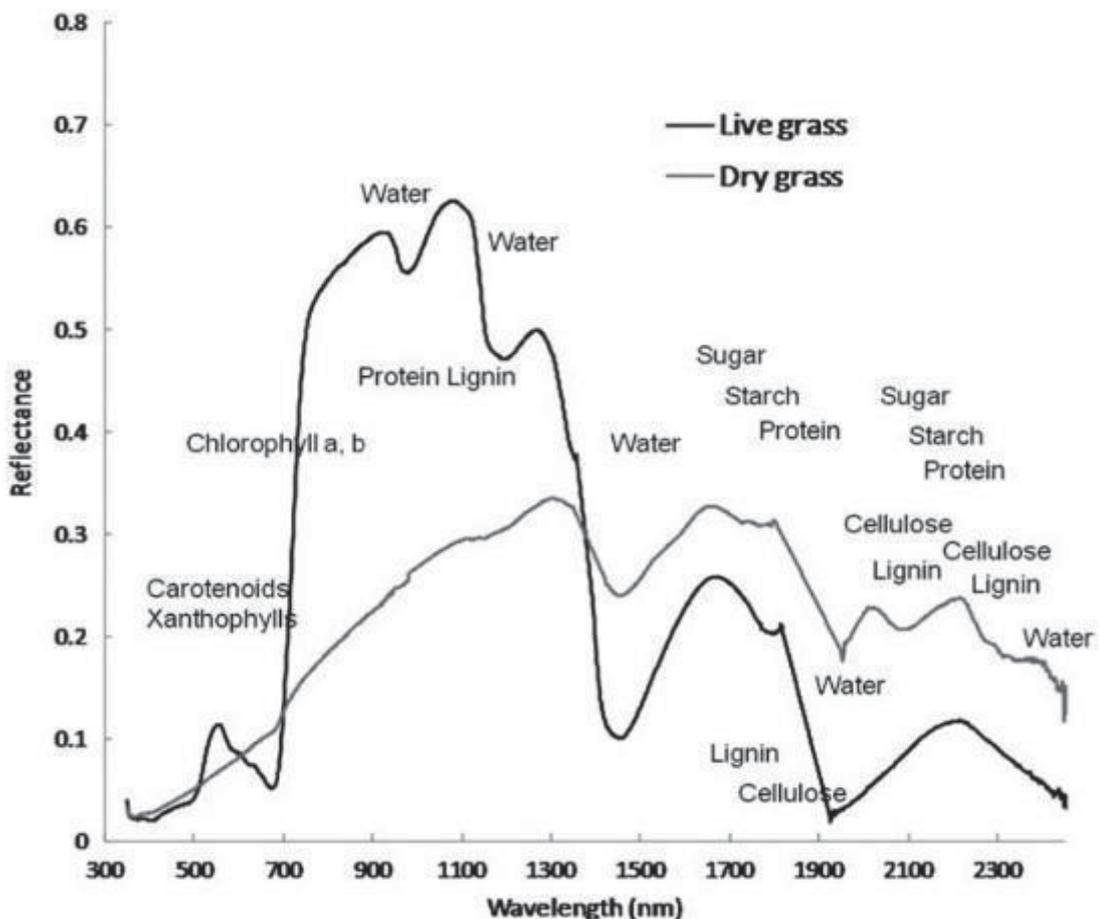


FONTE: Adaptado de Jensen (2015).

Baseia-se na interação da radiação eletromagnética com os objetos da superfície terrestre como a vegetação, a água e o solo, assim, estes objetos refletem, absorvem e transmitem radiação eletromagnética em porções que variam com o comprimento de onda, de acordo com suas características bio-físicas-químicas (FLORENZANO, 2011).

Conforme Rosette et al. (2012), o sensoriamento remoto ótico proporciona uma representação bidimensional da vegetação presente na superfície e sua reflectância pode ser relacionada indiretamente com parâmetros biofísicos, como os índices de vegetação e índice de área foliar. De acordo com Ponzoni e Shimabukuro (2009), a reflectância é dada pela razão entre a quantidade de energia refletida e a energia que incide na superfície das folhas ou do dossel, enquanto a transmitância é a razão entre o fluxo transmitido através do dossel e das camadas que constituem a folha pelo fluxo incidente. Uma folha verde sadia possui picos de reflexão nos comprimentos de onda nas faixas do visível (0,4 a 0,72 μm), infravermelho próximo (0,72 a 1,1 μm) e infravermelho médio (1,1 a 3,2 μm) (PONZONI et al., 2007) (Figura 3).

FIGURA 3 - Comportamento Espectral da vegetação verde sadia (Live Grass) e vegetação seca (Dry Grass).



FONTE: Adaptado de Hill (2004).

Devido a essas interações da radiação eletromagnética com a vegetação, o sensoriamento remoto se desenvolveu como uma técnica de grande importância para os estudos em florestas, possuindo diversas aplicações. Entre elas, estão a exploração seletiva de madeira (ASNER et al., 2005), incêndios florestais (KAZMIERCZAK, 2015), monitoramento florestal (JUCKER et al., 2016) e identificação de desmatamento (MILODOWSKI, et al., 2017).

2.4.1 Aeronave Remotamente Pilotada

Segundo Brasil (2015a), a RPA é uma aeronave não tripulada pilotada a partir de uma estação de pilotagem remota (RPS – *Remotely Piloted Station*) sendo um componente do sistema de aeronave remotamente pilotada (RPAS – *Remotely Piloted Aircraft System*) contendo os equipamentos necessários à pilotagem da RPA, dessa forma, a RPS se comporta ou funciona como o cockpit de uma aeronave tripulada e deve, portanto, oferecer ao piloto remoto capacidade equivalente para pilotar e gerenciar o voo.

O termo VANT (Veículo Aéreo Não Tripulado) também pode ser encontrado na literatura, como em Brasil (2015b), onde a Agência Nacional de Aviação Civil (ANAC) define VANT como sendo toda aeronave não tripulada com finalidade diversa à recreação e categoriza como subgrupo as Aeronaves Remotamente Pilotadas (RPA). Medeiros (2007) define VANT como pequenas aeronaves que, sem qualquer tipo de contato físico direto, conseguem executar diversas tarefas, tais como monitoramento, reconhecimento tático, vigilância e mapeamento; de forma genérica, são aeronaves normalmente projetadas para operar em situações perigosas e repetitivas em regiões consideradas hostis ou de difícil acesso (PEGORARO e PHILIPS, 2011). Neste estudo, será utilizado o termo RPA, pois, conforme Brasil (2015a), o termo VANT está obsoleto na comunidade aeronáutica internacional e as principais organizações relacionadas à aviação não empregam o termo “veículo”, mas sim, aeronave.

2.4.2 Sensor Hiperespectral

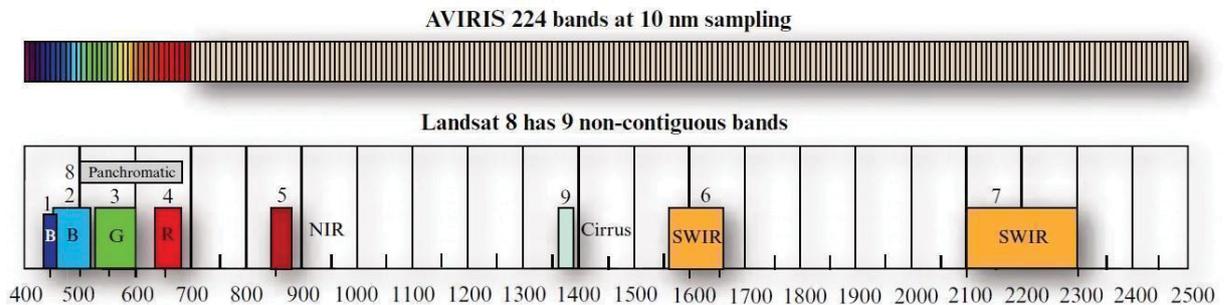
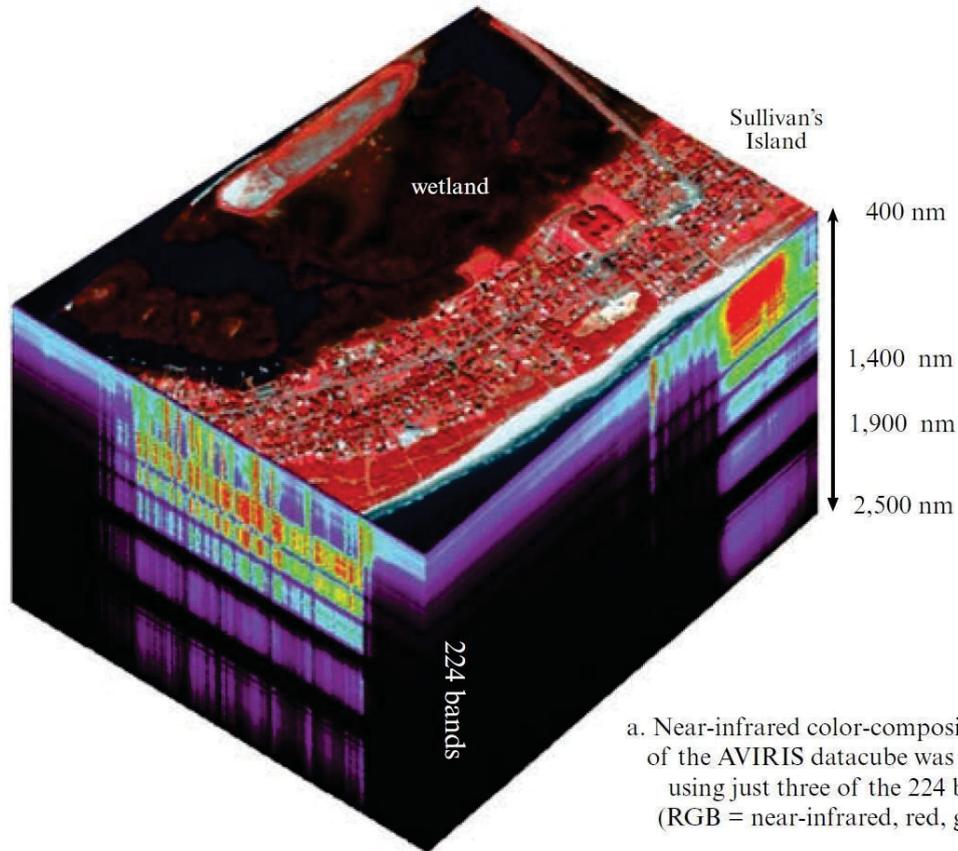
Sensores hiperespectrais medem a radiação solar refletida pelo dossel em centenas de bandas estreitas e, assim, permitem identificar variações sutis na resposta espectral das árvores, determinando sua detecção remota (FERREIRA, 2017). Atributos hiperespectrais visam caracterizar e representar a estrutura e fisiologia da vegetação, assim como a bioquímica e estrutura do dossel (GALVÃO et al., 2013), relações e predições de biomassa acima do solo

em diferentes tipos de vegetação (LATIFI et al., 2015; LAURIN et al., 2014; LEI et al., 2012; PONZONI et al., 2010).

De forma geral, o termo sensoriamento remoto hiperespectral se refere à utilização de sensores de alta resolução espectral para a obtenção de informação detalhada sobre os alvos (objetos, fenômenos) sem que haja contato direto entre eles, isto é, remotamente. E o produto gerado pode ser um espectro, se for utilizado um sensor hiperespectral não imageador, como um espectralradiômetro, ou uma imagem hiperespectral, da qual se podem extrair espectros, se for utilizado um sensor hiperespectral imageador (FORMAGGIO e SANCHES, 2017).

A resolução espectral de uma imagem é medida pela quantidade de bandas espectrais nela contida. Esse número está diretamente ligado à capacidade do sensor em descrever o comportamento espectral dos alvos da imagem. Quanto mais bandas houver, mais detalhada será a resposta espectral de cada píxel. Uma vez que cada banda registra a quantidade de radiação em um intervalo de comprimentos de onda, uma imagem com muitas bandas espectrais permite uma análise detalhada da composição química dos alvos na superfície (ZANOTTA et al., 2019). A Figura 4 exemplifica a resolução espectral comparando um sensor que obtém dados a partir de 224 bandas (AVIRIS) e outro a partir de apenas 9 bandas espectrais (Landsat 8).

FIGURA 4 – Cubo de Dados Hiperespectrais do AVIRIS com 224 Bandas Espectrais comparado às 9 Bandas Espectrais do Landsat 8.



b. Comparison of 224 AVIRIS spectral bands at 10 nm sampling with the sensitivity of the nine Landsat 8 non-contiguous bands in the region from 400 to 2,500 nm.

FONTE: Adaptado de Jensen (2015).

Trabalhos envolvendo esses sensores aplicados à vegetação já foram desenvolvidos, como em Tahmasbian et al. (2017), onde os autores fizeram a predição de Carbono e Nitrogênio da serrapilheira de uma floresta na Austrália. Muitos trabalhos são voltados à quantificação de pigmentos, como a Clorofila *a*, Clorofila *b* e Carotenoides, observável em Blackburn (1998a), Sonobe et al. (2020), Amirruddin et al. (2020).

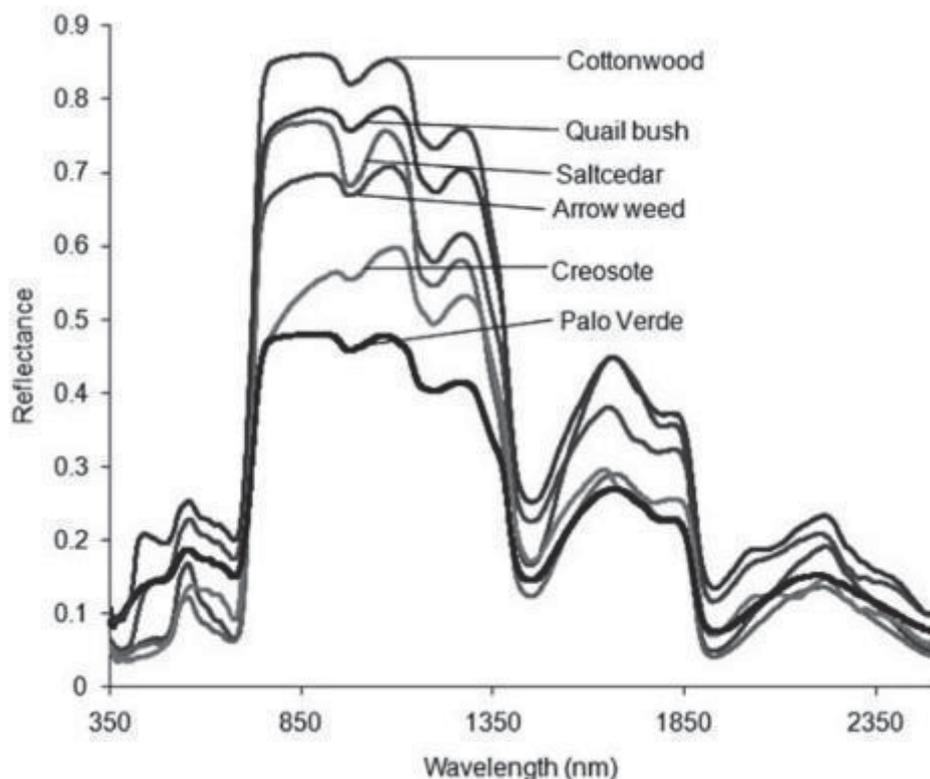
No Brasil, temos pesquisas na Mata Atlântica que envolveram a discriminação de espécies florestais (FERREIRA et al., 2013; FERREIRA et al., 2016) e a classificação de

espécies arbóreas da fitofisionomia da Floresta Ombrófila Mista (SOTHE et al., 2019). No Cerrado foi realizada a distinção de fisionomias de Savana no Brasil Central durante a estação seca e chuvosa (JACON et al., 2017; TONIOL et al., 2017) e estimativas de biomassa acima do solo (JACON et al., 2021). Também já foi estudado os ciclos fenológicos na Floresta Amazônica (DE MOURA et al., 2017).

2.4.3 Caracterização espectral

A radiação eletromagnética (REM) interage de diferentes formas com distintos materiais. Conforme a estrutura e a composição desses materiais, haverá regiões do EEM onde a radiação eletromagnética será mais absorvida ou refletida (Figura 5). Imagens hiperespectrais empregam dezenas a centenas de bandas contíguas a fim de reconstruir acuradamente a assinatura espectral de alvos de interesse (GOETZ et al., 2009). Assinaturas espectrais derivam dos valores de reflectância hiperespectral que representam características únicas de plantas e feições (SINGH et al., 2020).

FIGURA 5 - Curvas Espectrais de diferentes espécies, onde se observa o padrão do Comportamento Espectral da vegetação verde sadia e se diferenciando conforme a espécie.



FONTE: Adaptado de Nagler et al. (2019).

Conforme Hasmadi et al. (2010), a coleção de reflectâncias espectrais compreende uma biblioteca espectral e pode ser usada como guia para a classificação de imagens espectrais ou definir alvos em análise de imagens. Assim como muitos materiais possuem feições de absorção espectral distintas na região do espectro eletromagnético do visível ao infravermelho de ondas curtas, informações multi ou hiperespectrais ao longo desses comprimentos de onda são aplicáveis a uma variedade de problemas de pesquisa em meio ambiente (CLARK, 1999).

A comparação de dados hiperespectrais com dados de bibliotecas espectrais pode ajudar em uma identificação rápida do material em questão (KAMARUZAMAN e MALEK, 2009). Bao et al. (2019) construíram uma biblioteca espectral para 67 espécies arbóreas na região subtropical do leste da Ásia. Juola et al. (2022) coletaram a biblioteca espectral da casca de espécies de árvores na Finlândia utilizando uma câmera hiperespectral. Conforme estudo realizado por Haneda et al. (2023), as curvas espectrais permitiram entender o comportamento espectral de diferentes classes de coberturas de árvores a partir dos níveis de reflectância ao longo dos comprimentos de onda, mostrando quais classes têm comportamento similar e influência na classificação.

2.4.4 Índices de Vegetação

Os índices de vegetação fundamentam-se no comportamento antagônico da reflectância da vegetação nas regiões espectrais do visível e do infravermelho próximo (PONZONI et al., 2012). Isto é, enquanto no visível há uma menor reflectância devido à absorção da REM pelos pigmentos presentes nas folhas, no infravermelho há uma maior reflectância devido à interação da REM com as estruturas internas das folhas.

Os IVs de bandas largas não são adequados para o sensoriamento remoto de propriedades bioquímicas da vegetação, ao contrário dos IVs de bandas estreitas, que tem demonstrado tal capacidade (FORMAGGIO e SANCHEZ, 2017). De acordo com Roberts et al. (2019), muitos índices de vegetação estruturais foram desenvolvidos para sistemas de bandas largas, porém há índices de bandas estreitas equivalentes, além disso, há índices de vegetação bioquímicos e fisiológicos que são estritamente hiperespectrais com largura de banda menores ou iguais a 10 nm.

Thenkabail et al. (2014) propuseram seis categorias distintas de índices de vegetação hiperespectrais baseados na sua utilização em estudos de diversas características da vegetação, são elas: 1) quantificação biofísica (biomassa, índice de área foliar, altura da planta e produtividade de grãos; 2) quantificação bioquímica (pigmentos como carotenoides,

antocianinas e clorofila, assim como o nitrogênio); 3) estresse da vegetação (estresse e seca); 4) características hídricas (conteúdo de água e umidade); 5) eficiência no uso da luz; 6) lignina e celulose (lignina, celulose e resíduos).

Na Tabela 1 estão alguns exemplos de índices de vegetação obtidos a partir de dados hiperespectrais utilizados em estudos no Brasil. Não foi objetivo fazer um levantamento sobre os índices de vegetação mais utilizados, mas apresentar alguns índices utilizados em trabalhos utilizados como referência nesta tese.

TABELA 1 – Índices de vegetação utilizados em trabalhos no Brasil a partir de dados de sensores hiperespectrais.

(continua)

Sigla	Nome	Autor	Trabalho
ARI	<i>Anthocyanin Reflectance Index 1</i>	Gitelson et al. (2001)	Souza et al. (2010); Ferreira et al. (2016); Laurin et al. (2016); Jacon et al. (2017); Jacon et al. (2021); Anand et al. (2022). Ferreira et al. (2016).
CARI	<i>Chlorophyll absorption reflectance index</i>	Kim (1994)	Ferreira et al. (2016).
CRI 1	<i>Carotenoid Reflectance Index 1</i>	Gitelson et al. (2002a)	Souza et al. (2010); Ferreira et al. (2016); Laurin et al. (2016); Jacon et al. (2017); Jacon et al. (2021); Anand et al. (2022). Ferreira et al. (2016);
CRI 2	<i>Carotenoid Reflectance Index 2</i>	Gitelson et al. (2002)a	Ferreira et al. (2016).
EVI	<i>Enhanced vegetation index</i>	Huete et al. (2002)	Ferreira et al. (2016).
MCARI	<i>Modified CARI</i>	Daughtry et al. (2000)	Ferreira et al. (2016).
NDII	<i>Normalized difference infrared index</i>	Hunt and Rock (1989)	Ferreira et al. (2016).
NDLI	<i>Normalized difference lignin index</i>	Serrano et al. (2002)	Ferreira et al. (2016).
NDNI	<i>Normalized difference nitrogen index</i>	Serrano et al. (2002)	Ferreira et al. (2016).
NDVI	<i>Normalized Difference Vegetation Index</i>	Rouse et al. (1974)	Souza et al. (2010); Ferreira et al. (2016); Laurin et al. (2016); Moura et al. (2017); Jacon et al. (2017); Sothe et al. (2020); Jacon et al. (2021); Anand et al. (2022). Ferreira et al. (2016).
NDWI	<i>Normalized difference water index</i>	Gao (1996)	Ferreira et al. (2016).
PRI	<i>Photochemical Reflectance Index</i>	Gamon et al. (1997)	Souza et al. (2010); Ferreira et al. (2016); Jacon et al. (2017); Sothe et al. (2020); Jacon et al. (2021); Anand et al. (2022).

TABELA 1 – Índices de vegetação utilizados em trabalhos no Brasil a partir de dados de sensores hiperespectrais.

(conclusão)

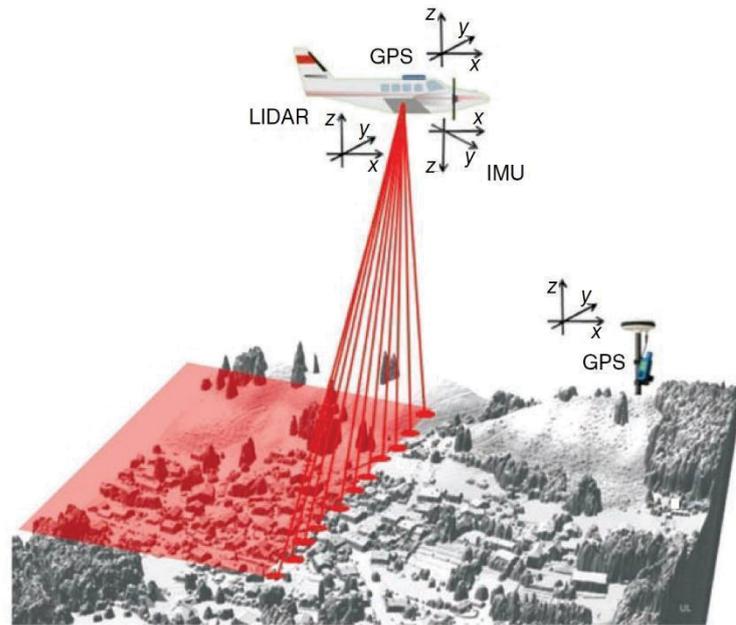
Sigla	Nome	Autor	Trabalho
PSND	<i>Pigment sensitive normalized difference</i>	Blackburn (1998b)	Ferreira et al. (2016).
PSRI	<i>Plant senescence reflectance index</i>	Merzlyak et al. (1999)	Ferreira et al. (2016).
RENDVI	<i>Red Edge Normalized Difference Vegetation Index</i>	Gitelson et al. (1996)	Souza et al. (2010); Ferreira et al. (2016); Laurin et al. (2016); Jacon et al. (2017); Jacon et al. (2021); Anand et al. (2022).
REP	<i>Red edge position</i>	Horler et al. (1983)	Ferreira et al. (2016).
SIPI	<i>Structurally insensitive pigment index</i>	Peñuelas et al. (1995)	Ferreira et al. (2016).
SR	<i>Simple ratio red/green</i>	Gamon and Surfus (1999)	Ferreira et al. (2016).
VARI	<i>Visible atmospherically resistant index</i>	Gitelson et al. (2002b)	Ferreira et al. (2016).
VIG	<i>Visible green index</i>	Gitelson et al. (2002b)	Ferreira et al. (2016).
VREI1 ou VOG	<i>Vogelmann Red Edge Index 1</i>	Vogelmann et al. (1993)	Souza et al. (2010); Laurin et al. (2016); Jacon et al. (2017); Jacon et al. (2021); Anand et al. (2022).

FONTE: O autor (2023).

2.4.5 Sensor Lidar

O sistema LiDAR é um dispositivo de sensoriamento remoto ativo que mede o tempo de viagem necessária para um pulso de energia laser enviado do sistema sensor aerotransportado até o alcance do solo e refletir de volta ao sensor (POPESCU, 2007). A precisão da posição dos pontos que retornam ao sensor é devida à integração da tecnologia de posicionamento global por satélite (GNSS – *Global Navigation Satllite System*) com o sistema de navegação inercial que posicionam o sensor acuradamente, assim como, também, os dados obtidos (MALTAMO et al., 2014). Dessa forma, os pulsos emitidos pelo sensor LiDAR penetram no dossel florestal e oferecem informações tridimensionais sobre a estrutura do dossel e a topografia abaixo dele, o que não é possível de se obter usando outras técnicas de sensoriamento remoto (HEISKANEN et al., 2015). Após o pulso ser emitido pelo sensor, ele interage com os objetos na superfície, retorna ao sensor sendo registrado. Esse retorno pode ser discreto (HUDAK et al., 2012; COSTA et al., 2021) ou registrado de forma contínua, *full waveform* (ANDERSON et al., 2008; Li et al., 2014).

FIGURA 6 - Componentes e operação do sistema LiDAR.



FONTE: Adaptado de Vosselman e Maas (2010).

Diferentes espécies florestais possuem configurações distintas da copa, tamanho e disposição das folhas. Conforme Shi et al. (2018), o retorno do pulso LiDAR registrado no sensor depende do percurso, da direção e da orientação do pulso emitido, o que pode ser usado para a diferenciação das espécies. Para Smrecek et al. (2018), o LiDAR aerotransportado tem sido cada vez mais utilizado para a detecção e mensuração de árvores na floresta, porém as estimativas das características dependem da resolução espacial dos dados derivados.

Conforme Zhao et al. (2009), é possível extrair um número infinito de possíveis métricas derivadas de dados LiDAR, as quais dependerão das características dos dados, número de retornos gravados por pulso e se há ou não informações auxiliares como a intensidade e o ângulo de escaneamento. Para estudos florestais, em particular, o LiDAR pode caracterizar efetivamente tanto o terreno quanto a estrutura da vegetação (LEITOLD et al, 2015). Com os parâmetros oriundos do processamento dos dados LiDAR, é possível desenvolver aplicações voltadas para a vegetação como a biomassa (LEITOLD et al., 2015; SATO et al., 2016; CHEN et al., 2016).

A densidade de pontos da nuvem obtida pelo sensor LiDAR depende de fatores como a velocidade de deslocamento da plataforma, frequência de pulsos emitidos e altitude da plataforma. O sensor LiDAR quando transportado em RPA proporciona uma nuvem com alta densidade de pontos. Isso pode ser verificado em Cunha Neto et al. (2021), que a partir de uma nuvem com densidade de 2.500 pontos.m⁻², derivaram a altura total da espécie *Araucaria*

angustifolia. Dalla Corte et al. (2019), além da medida da altura, também obtiveram o diâmetro à altura do peito derivado de nuvem de alta densidade de pontos. Aplicações para a medição de atributos de inventário florestal com a detecção de árvores individuais a partir de nuvem de alta densidade pode ser conferido em Dalla Corte et al. (2022).

2.5 MODELAGEM DE BIOMASSA COM DADOS DE SENSORIAMENTO REMOTO

2.5.1 Modelagem com dados de sensores passivos

Sensores remotos passivos são aqueles que necessitam de uma fonte externa de REM, como o Sol, para fazerem o registro de feições na superfície da Terra. Assim, possuem a limitação de condições climáticas, como a cobertura de nuvens, para realizarem seus registros, que podem ser feitos a partir de satélites, aviões ou RPAs. Tais registros, em forma de imagens, possibilitam extrair atributos da superfície terrestre, como a biomassa acima do solo.

Conforme Souza e Ponzoni (1998), os trabalhos que visam quantificar a biomassa florestal se destacam entre os que aplicam técnicas de sensoriamento remoto para estudos na área florestal. Santos (1988) realizou um dos primeiros estudos da biomassa acima do solo da vegetação no Cerrado utilizando o sensor TM do satélite Landsat-5. Também com o sensor TM, mas com o Landsat-7, Correa et al. (2001) realizaram o mapeamento da fitomassa da Caatinga utilizando o índice de área foliar e o índice de vegetação da diferença normalizada (NDVI). Watzlawick et al. (2003) utilizaram imagens do satélite Ikonos para predições de biomassa e carbono em plantações de *Araucaria angustifolia* e *Pinus taeda*, bem como em Floresta com Araucária.

Métodos baseados em sensoriamento remoto na predição de AGB em ecossistemas florestais ganharam atenção crescente, e pesquisas substanciais foram conduzidas nas últimas três décadas (LU et al., 2014). Segundo Watzlawick et al. (2009), com os avanços nas técnicas de processamento de imagens, tem-se obtido uma melhor caracterização da estrutura das florestas e, conseqüentemente, de sua biomassa e carbono estocado, ao associar esses atributos aos dados de radiância/reflectância provenientes de imagens de satélite.

2.5.2 Modelagem com dados de sensores ativos

Predições de biomassa florestal a partir de dados LiDAR tem se tornado possíveis devido ao desenvolvimento científico e à busca por inovação realizados por pesquisadores da

área florestal. Dados derivados deste sensor, como as métricas obtidas a partir do processamento da nuvem de pontos e o modelo de altura do dossel, possibilitam fazer correlações com a quantidade de biomassa presente nas árvores e na floresta.

Os métodos utilizados para fazer as estimativas são diversos, assim como a plataforma onde o sensor está instalado. Os dados podem ser adquiridos a partir de sensores em plataformas orbitais como o GLAS – *Geoscience Laser Altimeter System* (POPESCU et al., 2011), LVIS – *Land Vegetation and Ice Sensor* (DRAKE et al., 2002; ANDERSON et al., 2008; MEYER et al., 2013) e mais recentemente o GEDI – *Global Ecosystem Dynamics Investigation* (MUSTHAFA e SINGH, 2022; DUNCANSON et al., 2022). Ao nível suborbital, pode-se dividir em sensores transportados por aviões, também chamados de ALS – *Airborne Laser Scanner* (MARCHESAN et al., 2020; REX et al., 2020; SCHUH et al., 2020), e transportados por aeronaves remotamente pilotadas, nesse caso RPA-lidar ou UAV-lidar (d’OLIVEIRA et al., 2020). Outra forma de obtenção dos dados para a predição da biomassa é a partir de um sensor terrestre (TLS – *Terrestrial Laser Scanner*), o qual é instalado em um tripé nivelado, semelhante a uma estação total (LI et al., 2021). Os trabalhos que estão sendo desenvolvidos também possuem escalas diferentes, predizendo a biomassa por árvore individual (FERNANDEZ-LANDA et al., 2017) ou ao nível de área e parcela (HERNANDO et al., 2019; COSTA et al., 2021).

2.5.3 Modelagem com a integração de sensores passivos e ativos

O emprego de aeronaves remotamente pilotadas (RPA) com grande capacidade de carga permite que sejam embarcados diferentes sensores. A possibilidade de se ter um sensor LiDAR na mesma plataforma que um sensor hiperespectral obtendo dados em um mesmo voo, potencializa a capacidade de analisar a floresta. Enquanto o LiDAR proporciona a altura da vegetação, os dados hiperespectrais proporcionam informações sobre parâmetros biofísicos e bioquímicos, os quais, quando combinados, oferecem um mapeamento da floresta mais acurado e uma melhor discriminação de espécies florestais (ZHANG et al., 2016; TRIER et al., 2018). De uma perspectiva ecológica e biológica, a classificação de espécies florestais requer feições específicas dessas espécies, que podem ser morfológicas (altura, forma da copa), fisiológicas (taxa fotossintética), bioquímica (conteúdo de clorofila e água) ou fenológicas (folhas e floração) (SHI et al., 2018).

2.6 APRENDIZADO DE MÁQUINA

Aprendizado de máquina ou *machine learning* (ML) é uma efetiva aproximação empírica para regressão e/ou classificação (supervisionada ou não supervisionada) de sistemas não lineares, os quais podem envolver poucos até milhares de variáveis (LARY et al., 2016). O campo que o aprendizado de máquina disponibiliza é um conjunto de algoritmos que transformam dados em conhecimento, cujo objetivo é nos ajudar a entender o grande volume de dados disponível no mundo (LANTZ, 2015). Segundo Szwarcfiter e Markenzon (1994), algoritmos são definidos como o processo sistemático para a resolução de um problema, ou seja, uma sequência ordenada de passos que deve ser seguida para a realização de uma tarefa (SALIBA, 1993; BERG e FIGUEIRÓ, 1998).

Por estarem ligados à ciência de dados, há uma rápida evolução dos algoritmos empregados. Entre os mais utilizados na predição da biomassa acima do solo estão o *Random Forest* (BACCINI e ASNER, 2013; MARCHESAN et al., 2020; REX et al., 2020), ANN – *artificial neural network* (ZHU e LIU, 2015; SCHUH et al., 2020), k-NN – *k-nearest neighbour* (HERNANDO et al., 2019; REX et al., 2020), CNN – *convolution neural network* (AO et al., 2021), MSN – *most similar neighbour's inference* (BREIDENBACH et al., 2010), SVM – *support vector machine* (REX et al., 2020; SCHUH et al., 2020).

2.6.1 Random Forest

Random Forest ou florestas aleatórias é um algoritmo baseado no princípio de árvores de decisão (BREIMAN, 2001), a qual é uma técnica determinística que seleciona um conjunto aleatório de variáveis e uma amostra aleatória de treinamento (SHAO e ZHANG, 2016). De acordo com Montañó (2016), o algoritmo utiliza processos diferentes para a classificação, cujo resultado é alcançado pela votação de cada árvore da floresta, e para a regressão, onde a saída da floresta é a média entre os resultados das árvores. Ainda, não é limitado pela distribuição de covariáveis e sensível a outliers e ruídos (PRASAD et al., 2006). Conforme Pal (2005), é uma alternativa não-linear e não-paramétrica com capacidades preditivas promissoras para conjuntos de dados de grandes dimensões, assim, tornando-se popular no sensoriamento remoto.

2.6.2 Support Vector Regression

O *Support Vector Regression* é, em muitos princípios, similar ao *Support Vector Machine*, onde se considera uma margem de tolerância para problemas de regressão (KEYVANPOUR e SHIRZAD, 2022). Segundo Babbar et al. (2022), o SVM tem uso mais amplo para agrupamento e ordenação de problemas, enquanto para a regressão não é muito documentado. O SVR é um algoritmo que proporciona flexibilidade e permite que se escolha a tolerância para os erros mediante uma margem de erro satisfatória e um ajuste aceitável que exceda a taxa aceitável de erro (HELMAN et al, 2019). Conforme Ji et al. (2022), o SVR tem uma grande vantagem em lidar com problemas não lineares a partir da introdução de uma função kernel a fim de projetar os dados originais em um espaço linearmente separável de alta dimensão, portanto, é selecionado para construir modelos de regressão para variáveis não estacionárias.

2.6.3 Elastic Net

A regressão *Elastic net* (ENET) é uma técnica estatística híbrida usada para regularizar e selecionar variáveis preditoras necessárias que possuem um forte efeito sobre a variável resposta e lidar com problemas de multicolinearidade, quando existente, entre as variáveis preditoras (AL-JAWARNEH et al., 2021). Dessa forma, obtém-se um modelo simples com as variáveis preditoras mais significantes apesar da alta multicolinearidade entre os preditores (AL-JAWARNEH et al., 2021). Em outras palavras, conforme Liu e Li (2017), o ENET pode remover ou selecionar variáveis preditoras com alta correlação no modelo final e melhorar a acurácia da predição.

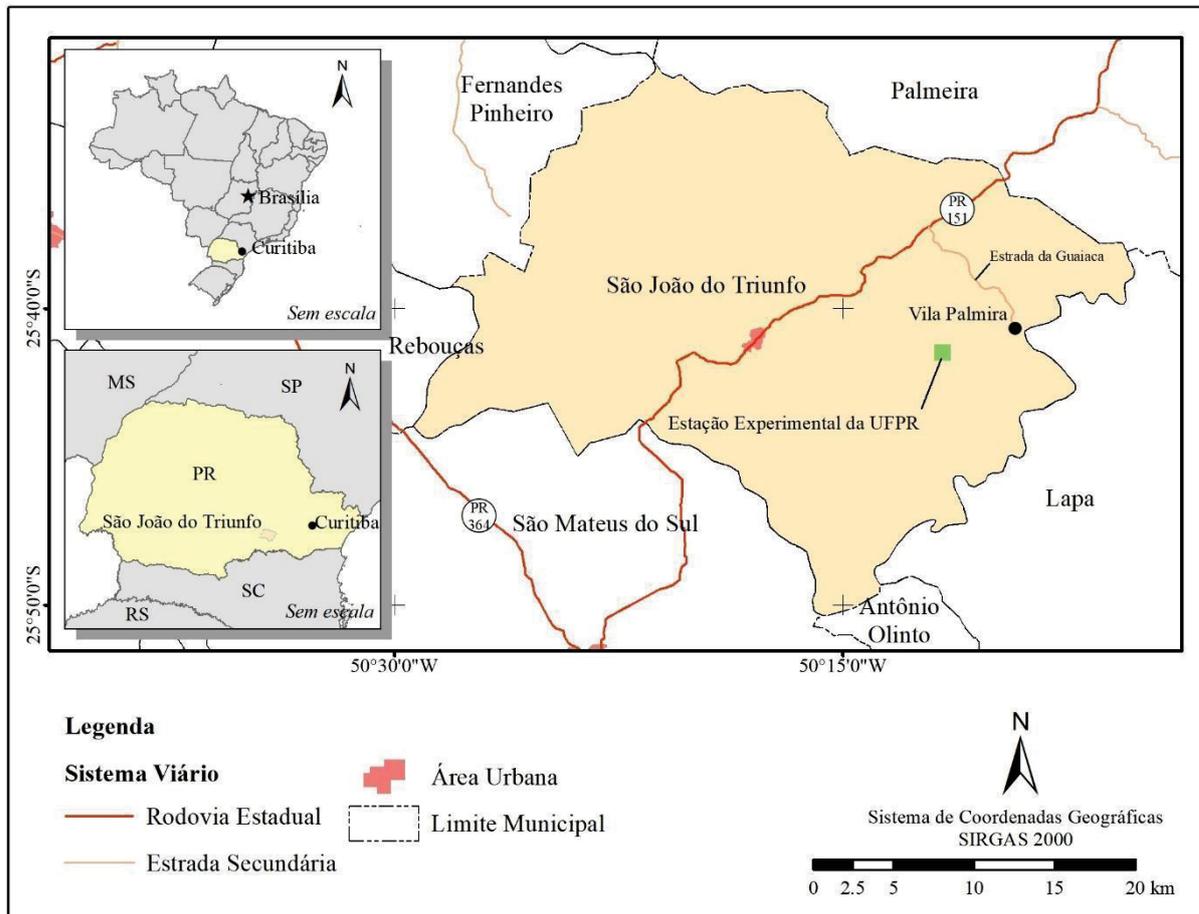
3 MATERIAIS E MÉTODOS

3.1 ÁREA DE ESTUDO

A área de estudo está localizada na Estação Experimental da Universidade Federal do Paraná, município de São João do Triunfo, Estado do Paraná, cerca de 120 km de distância da capital Curitiba (Figura 7). A estação possui uma área de 30,5 ha de Floresta Ombrófila Mista (FOM), dividida em talhões nos quais estão instaladas parcelas permanentes, três de 1 ha e uma de 0,5 ha, nominadas Araucária, Fogo, Imbuia e Rio, as quais são divididas em subparcelas de 10×10 m (100 m²). Estas parcelas possuem monitoramento contínuo anual através do

Programa de Pesquisas Ecológicas de Longa Duração (PELD) Sítio 9 – Floresta com Araucária e suas transições (SANQUETTA et al., 2014).

FIGURA 7 – Localização da área de estudo (Estação Experimental de São João do Triunfo – UFPR) no município de São João do Triunfo–PR.



FONTE: O autor (2023).

A área está a uma altitude de 780 m acima do nível do mar (DURIGAN, 1999). Possui, conforme Iapar (2000), a classificação climática de Köppen Cfb (clima temperado), com temperatura média no mês mais frio abaixo de 18 °C (mesotérmico), com verões frescos, temperatura média no mês mais quente abaixo de 22 °C e sem estação seca definida. Conforme Longhi (1980), o solo é classificado como podzólico vermelho-amarelo distrófico, com uma pequena porção de solo do tipo cambissolo distrófico álico, ambos possuindo baixa saturação de bases (distróficos) e alta concentração de alumínio (álico), dessa forma, são considerados solos com acidez elevada.

A vegetação é classificada, conforme IBGE (2012), como Floresta Ombrófila Mista Montana, a qual está presente em altitudes médias de 400 m até em torno de 1000 m. Segundo Dalla Lana (2013), as famílias Lauraceae e Myrtaceae apresentam maior riqueza e

representatividade, bem como as espécies *Araucaria angustifolia* (Bertol.) Kuntze, *Nectandra grandiflora* Nees & Mart., *Ilex paraguariensis* A.St.-Hil. e *Matayba elaeagnoides* Radlk.

3.2 ANÁLISE BIBLIOMÉTRICA

As bases de dados escolhidas para a obtenção dos bancos de dados foram a *Scopus*, *Web of Science* e *Science Direct*. A busca ocorreu por meio de palavras-chave segundo a metodologia proposta por Silva et al. (2020). As bases de dados escolhidas são reconhecidas globalmente por serem abrangentes e respaldadas cientificamente (FALAGAS et al., 2008; KHUDZARI et al., 2018). Assim, as bases de dados foram consultadas para todo período até 2021 e os bancos de dados foram baixados no mesmo dia (10 de fevereiro de 2022).

A busca foi realizada para títulos, resumos e palavras-chave de manuscritos e os termos utilizados foram: *araucaria*, *biomass*, *carbon stock*, *stored carbon*, *carbon sink*, *Carbon storage*, *fixed carbon*, *carbon sequestration*. Já a sequência de pesquisa foi: *TITLE-ABS-KEY(araucaria and ("biomass" OR "carbon stock" OR "stored carbon" OR "carbon sink" OR "Carbon storage" OR "fixed carbon" OR "carbon sequestration"))*.

Cada base de dados gerou um banco de informações, sendo as duplicatas excluídas na ocasião. Posteriormente, os textos passaram por uma triagem por meio de leitura e compatibilidade com critérios de inclusão pré-estabelecidos a fim de verificar os que de fato estavam relacionados com o tema. Os critérios de inclusão utilizados na ocasião foram: 1) Trabalhos que quantificaram a biomassa de *Araucaria* sp.; 2) Pesquisas relacionadas com estoque de carbono na biomassa da espécie em questão.

Para a revisão bibliométrica foram observados os seguintes dados: 1) Ano de publicação; 2) Tipo de documento; 3) Periódico; 4) Autores; 5) Teia de cocitação dos autores; 6) Instituição de afiliação dos autores; 7) Áreas da ciência; 8) Agências de fomento. Para o estado da arte, os aspectos foram: 1) localização do estudo; 2) tipo de vegetação da área; 3) componente da biomassa avaliado; 4) Tipo de determinação da biomassa; 5) tipo de determinação do teor de carbono; 6) valores de teores de carbono em gramas por quilograma; 7) estoque de carbono em megagrama por hectare. Os resultados foram analisados e os gráficos confeccionados utilizando a linguagem de programação científica R 4.2.0 através do ambiente de desenvolvimento integrado RStudio 2022.07.1. Os pacotes utilizados para as análises foram os que fazem parte da biblioteca do sistema do próprio R, como *Base*, *stats* e *utils*.

3.3 COLETA DE DADOS

3.3.1 Dados de Sensoriamento Remoto

Os dados foram obtidos em 11 de setembro de 2019 com a aeronave remotamente pilotada (RPA) modelo DJI Matrice 600 Pro (Figura 8), a qual conta com uma unidade de medição inercial (IMU) STIM300 e receptor GNSS de dupla frequência L1/L2 pós-processado. A RPA faz parte do *GatorEye Unmanned Flying Laboratory*, localizado junto ao Laboratório de Ecologia Espacial e Conservação (*SPEC Lab*) da Universidade da Flórida (UFL).

As imagens hiperespectrais foram obtidas com o sensor Headwall Photonics Nano VNIR de 640 píxeis x 270 bandas espectrais, entre os comprimentos de onda de 400 e 1.000 nm. Já a nuvem de pontos, com o sensor LiDAR Velodyne VLP-32c atuando no comprimento de onda de 903 nm e 1,2 milhão de pontos por segundo, com campo de visão (FOV) de 360°.

FIGURA 8 - RPA DJI Matrice 600 com sensores LiDAR e Hiperespectral.



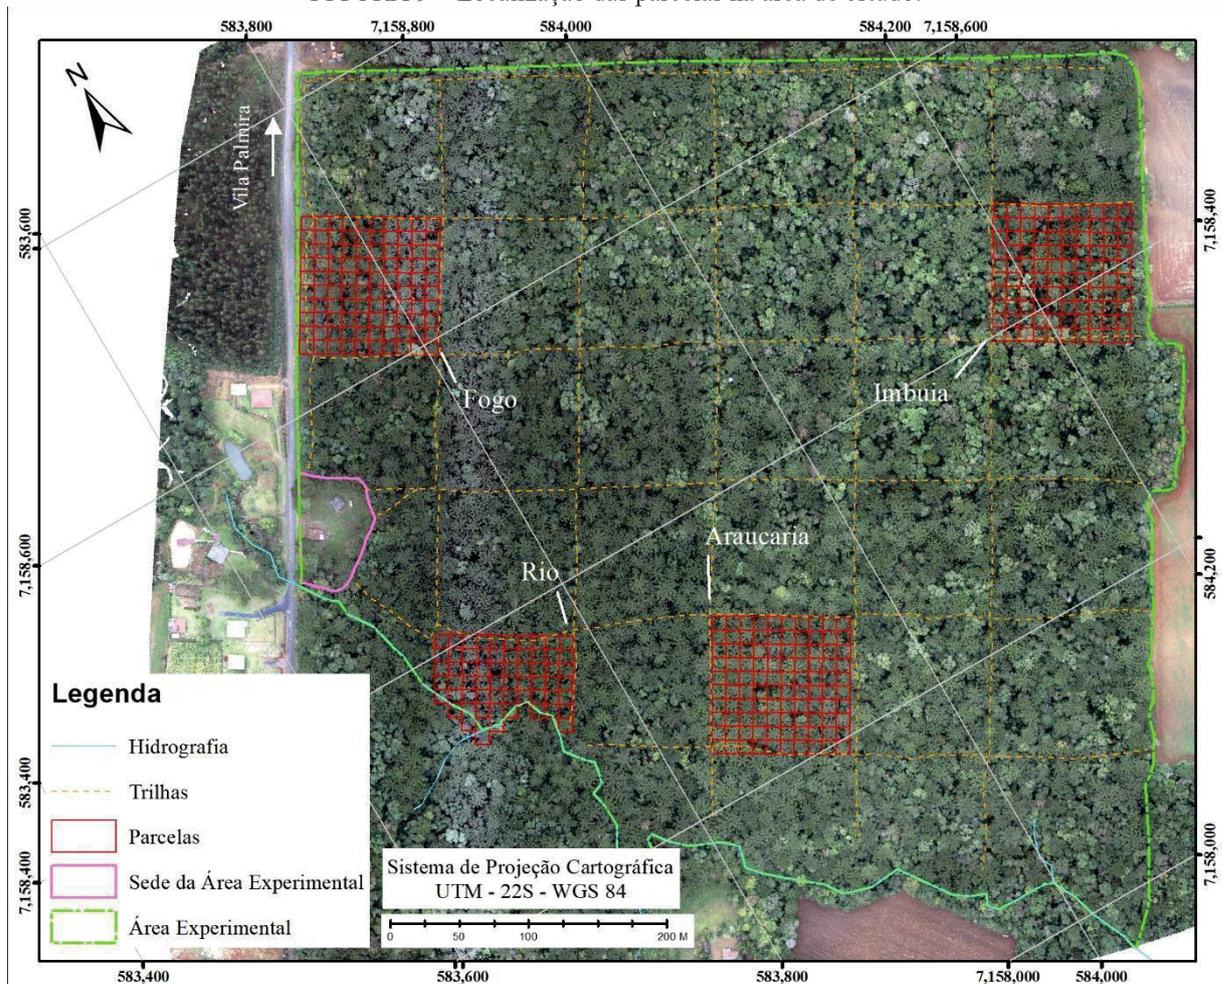
FONTE: O autor (2023).

Os dados brutos foram processados no *SPEC Lab*, resultando, assim, em 16 transectos de imagens hiperespectrais. Além disso, a fim de identificar as copas das árvores de interesse, foram adquiridas imagens com sensor RGB a uma altura de voo de 140 m com a RPA DJI Phantom 4 Pro, no dia 7 de maio de 2021.

3.3.2 Inventário Florestal

Os dados de campo foram obtidos em três campanhas. Nos dias de 9 a 14 de agosto e 10 a 14 de setembro de 2020 foram mensuradas as circunferências à altura do peito (CAP), em centímetros, de todas as árvores presentes nas parcelas. As árvores que mediram um CAP igual ou maior a 31,4 cm, e que não faziam parte das medições anteriores, foram incluídas como novos ingressos, recebendo um número identificador e uma placa em alumínio, passando, assim, a fazer parte do estoque da floresta. A terceira campanha foi realizada nos dias 21 e 22 de maio de 2021, a qual contou com a identificação e posição prévia de 118 araucárias no ortomosaico gerado a partir do sensor RGB. Em cada uma das 118 araucárias foi criada a feição ponto, que assumiu as coordenadas conforme o georreferenciamento do ortomosaico. Dessa forma, foi possível localizar cada árvore nas parcelas e sua respectiva identificação no inventário florestal. Na Figura 9 estão localizadas as 4 parcelas existentes na área de estudo.

FIGURA 9 – Localização das parcelas na área de estudo.



FONTE: O autor (2023).

Como há um monitoramento contínuo na área de estudo, já existe uma base vetorial disponível em formato shapefile com as posições de cada indivíduo que é monitorado. Essa base foi, então, atualizada com os novos ingressos que tiveram suas coordenadas X e Y registradas, tendo como origem o vértice inferior esquerdo ou direito da parcela, dependendo de como esta foi orientada no momento de sua materialização. As distâncias dos indivíduos em relação aos eixos x e y foram tomadas a partir de trena.

3.3.2.1 Diversidade Florística e Estrutura Horizontal

A fim de se obter informações sobre a vegetação local, foram aplicados dois índices: o índice de informação de *Shannon* (H'), o qual se baseia no raciocínio de que a diversidade, ou informação, em um sistema natural pode ser medida similarmente à informação contida em um código ou mensagem e o índice de uniformidade de *Pielou* (J'), o qual expressa a uniformidade na abundância de espécies (MAGURRAN, 2013).

O estudo da estrutura horizontal foi realizado com o emprego de parâmetros fitossociológicos como densidade, dominância e frequência, com seus valores absolutos por unidade de área e relativos. Também foi calculado o índice de valor de importância percentual. Salienta-se que essa etapa do trabalho foi realizada apenas para caracterizar o fragmento florestal em estudo.

3.3.3 Biomassa Florestal

Para a predição da biomassa acima do solo da espécie *Araucaria angustifolia*, foram utilizados os dados de Watzlawick (2002), os quais contêm a medição do diâmetro à altura do peito, altura total e a AGB pesada no campo (fuste, galhos vivos, galhos mortos, acículas) de 44 árvores dessa espécie. O resumo estatístico desses dados pode ser conferido na Tabela 2.

TABELA 2 – Resumo estatístico dos dados de Watzlawick (2002) usados para a predição da biomassa acima do solo para a espécie *Araucaria angustifolia*.

Variável	N	Média	Sd	Mínimo	Máximo
D (cm)	44	29,11	15,16	14,29	105,68
H (m)	44	17,08	3,22	11,10	30,10
AGB (kg)	44	483,52	930,08	56,44	5.904,09

FONTE: Adaptado de Watzlawick (2002).

LEGENDA: N = número de indivíduos, sd = desvio padrão.

3.4 PROCESSAMENTO E ANÁLISE DOS DADOS

Os dados foram processados a partir da Linguagem de Programação Científica R, através do Ambiente de Desenvolvimento Integrado (IDE, do inglês *Integrated Development Environment*) RStudio, com o uso de pacotes e funções específicas para cada tipo de dado. Para os dados LiDAR também foi utilizado o software FUSION/LDV 3.8 (McAUGHEY, 2018) desenvolvido pelo Serviço Florestal dos Estados Unidos.

3.4.1 Caracterização florestal

Os dados de campo foram tabulados em planilhas eletrônicas contendo o nome da parcela, subparcela, número da árvore, CAP (em centímetros), nome científico, família botânica e gênero. Os nomes científicos foram revisados a partir do site Flora do Brasil e Funga do Brasil (FLORA E FUNGA DO BRASIL, 2022) e estão conforme o *Angiosperm Phylogeny Group IV* (APG IV). Posteriormente os valores da CAP foram convertidos para diâmetro à altura do peito (DAP), também em centímetros, em uma nova coluna nas planilhas.

Os parâmetros fitossociológicos foram obtidos a partir da aplicação da função *fitoR* e a diversidade florística da aplicação da função *similaridade*, ambas desenvolvidas por Dallagnol et al. (2017). Para a entrada dos dados foi editada uma planilha contendo apenas as subparcelas, os nomes científicos e o DAP, além da área das subparcelas (100 m²) a ser informada na própria função.

3.4.2 Geoprocessamento

O mosaico ortorretificado foi feito na versão de teste do Pix4D a partir de 169 imagens RGB obtidas sobre a área de estudo. Esse foi utilizado para a identificação das copas das árvores a serem buscadas no campo. Para tanto, o mosaico foi carregado no ArcMap 10.3 com os transectos das imagens hiperespectrais e o arquivo *shapefile* das parcelas. Assim, realizou-se a delimitação das copas das árvores onde houve a coincidência dessas três camadas. Os vetores das copas foram salvos no formato *shapefile* contendo um atributo de identificação das árvores para serem usados nas etapas seguintes de processamento. Na Tabela 3 pode ser visto um resumo estatístico das áreas de copas. Todo o projeto e dados geoespaciais (coordenadas obtidas em campo, imagens, nuvem de pontos e vetores) foram georreferenciados no sistema de projeção cartográfica UTM no fuso 22 Sul e Datum WGS 84. Cabe ressaltar que o ortomosaico

serviu apenas para a localização das araucárias e delimitação de suas respectivas copas, não sendo usado dados de reflectância.

TABELA 3 – Resumo estatístico das áreas de copas delimitadas sobre o ortomosaico.

Parcela	N	Área total (m ²)	Média (m ²)	sd (m ²)	Mínimo (m ²)	Máximo (m ²)
Araucária	39	4.077,4	104,55	54,34	38,3	309,7
Fogo	38	2.862,6	75,33	26,96	37,9	138,3
Imbuia	13	2.466,6	189,74	69,87	64,68	304,78
Rio	28	2.869,4	102,48	39,59	38,18	181,54

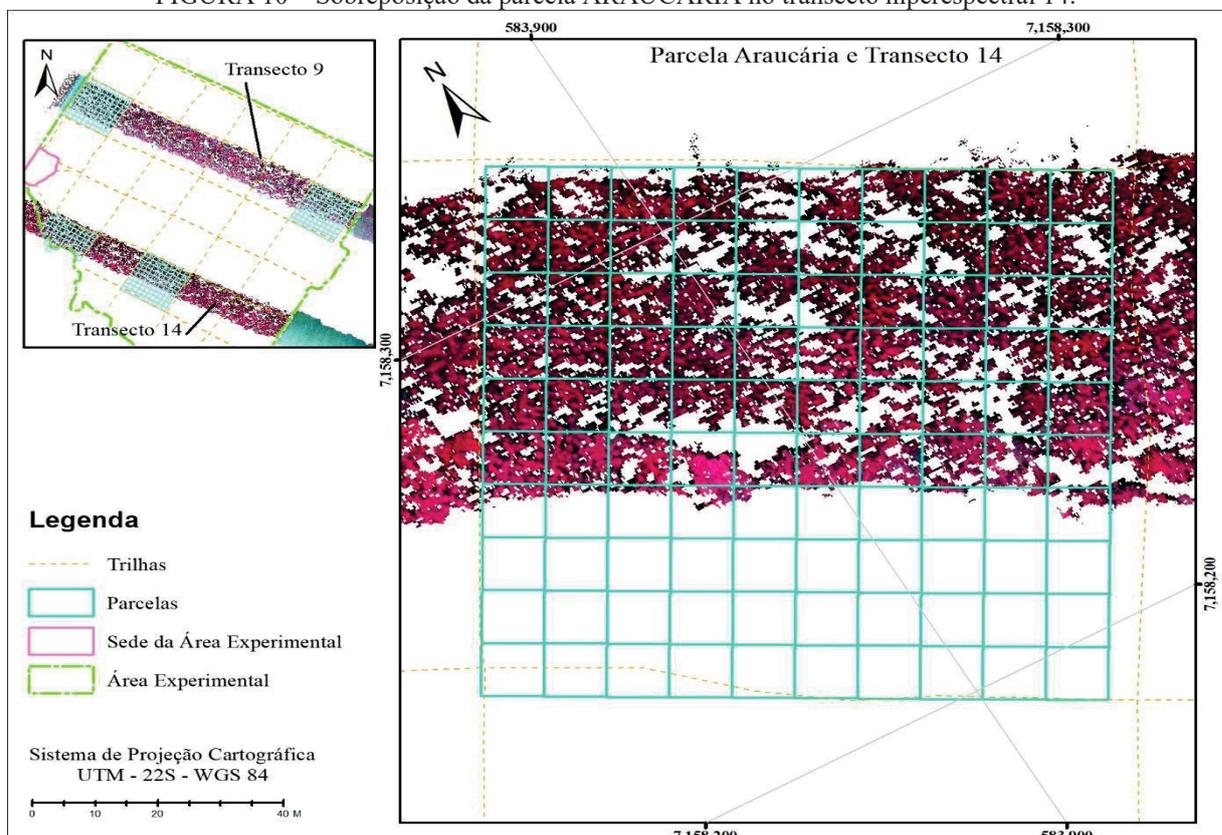
FONTE: O autor (2023).

LEGENDA: N = número de indivíduos, sd = desvio padrão.

3.4.3 Dados hiperespectrais

Para os dados hiperespectrais foram utilizados os pacotes *raster* (HIJMANS et al., 2023), *hdsar*, *rgdal*, *RStoolbox*. Dos 16 transectos sobre a área total de estudo, apenas dois cobriram as parcelas. O transecto 9 cobriu as parcelas Fogo e Imbuia e o transecto 14 cobriu as parcelas Araucária e Rio. Na Figura 10 se observa a área da parcela coberta pelo voo que obteve os dados hiperespectrais.

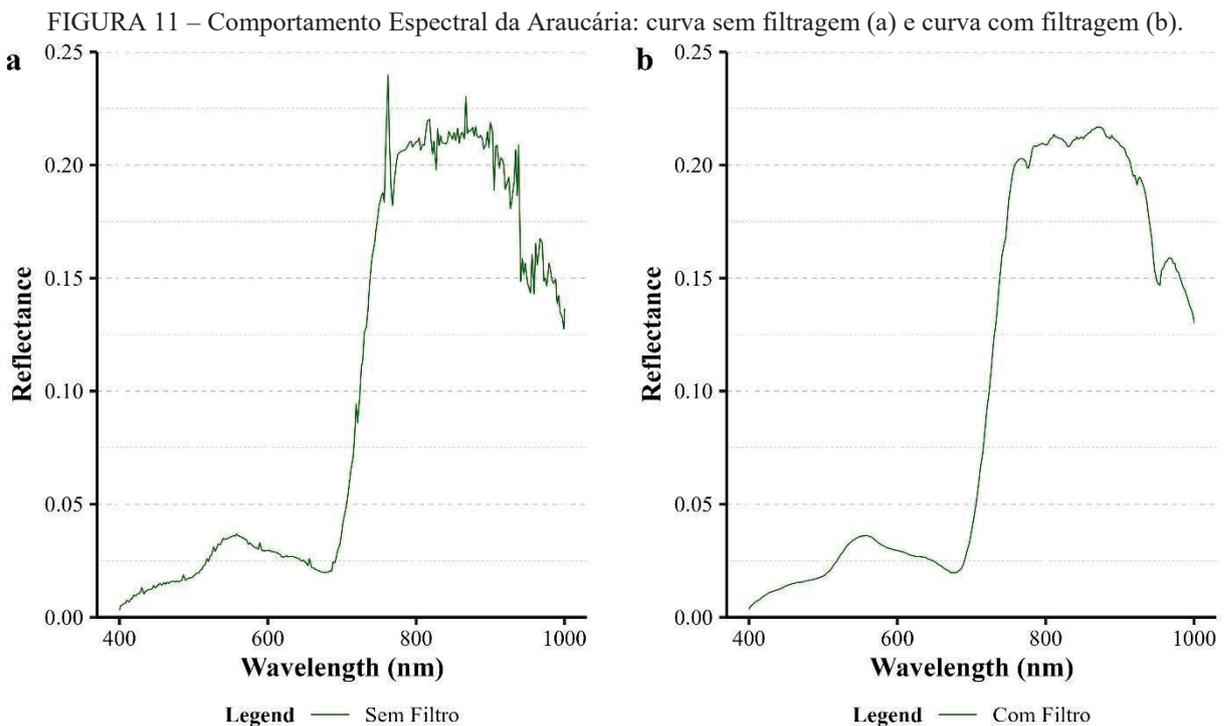
FIGURA 10 – Sobreposição da parcela ARAUCÁRIA no transecto hiperespectral 14.



FONTE: O autor (2023).

Foi realizada uma interseção entre os vetores das copas e os transectos, dessa forma, cada píxel ficou com a identificação correspondente a cada uma das árvores. As parcelas foram processadas separadamente e associadas a objetos no RStudio. Cada objeto se constituiu em 271 atributos, dos quais 270 correspondentes a cada uma das bandas espectrais e um correspondente ao identificador de cada uma das 118 árvores.

Inicialmente, procedeu-se à extração dos valores de reflectância de cada píxel e logo após fez-se a remoção dos píxeis com valores iguais a zero e píxeis sem informação (NA). Então, calculou-se a reflectância média para cada árvore e aplicou-se um filtro nos píxeis com a função *noiseFiltering* com o método “*sgolay*” a fim de suavizar as curvas de reflectância. Assim, criou-se um objeto contendo todas as árvores das quatro parcelas e exportado como planilha eletrônica no formato *.csv*. Na Figura 11 é possível comparar as curvas espectrais sem filtragem e com filtragem de ruídos do comportamento espectral da Araucária.



FONTE: O autor (2023).

Além da obtenção das reflectâncias de todos os píxeis amostrados, também foram obtidas as reflectâncias apenas dos píxeis iluminados (*sunlit*). Os píxeis iluminados foram selecionados de forma empírica, calculando-se uma média de corte para a reflectância de modo que todos os comprimentos de onda foram amostrados. Após, repetiu-se o mesmo processo já descrito anteriormente para todos os píxeis.

3.4.3.1 Caracterização espectral

O comportamento espectral da araucária foi analisado a partir da curva espectral gerada com os valores de reflectância correspondentes a cada comprimento de onda, tanto para todos os píxeis amostrados quanto para os píxeis iluminados. A fim de se comparar o comportamento espectral da araucária com outros alvos na superfície, foram obtidas amostras do dossel da floresta ombrófila mista sem amostrar píxeis de araucária nesse conjunto. Ou seja, apenas as demais árvores presentes na floresta em diferentes regiões da área de estudo.

O comportamento espectral da Araucária também foi analisado por classes de sua distribuição diamétrica. Foram utilizadas oito classes, as quais foram definidas a partir da regra de Sturges. Foi realizada a análise de variância (ANOVA) com significância de 5% a fim de se constatar se o comportamento espectral da araucária se diferencia do comportamento espectral entre as diferentes classes de diâmetros.

3.4.3.2 Índices de Vegetação

Foram selecionados 20 índices de vegetação relacionados a pigmentos (antocianina, carotenoides e clorofila), fisiologia, bioquímica e estrutura da planta (Tabela 4). Os comprimentos de onda utilizados nos cálculos dos índices foram adaptados dos autores conforme a finalidade estabelecida e comprimentos de onda correspondentes a determinadas faixas do espectro eletromagnético: azul (400 a 499 nm), verde (500 a 599 nm), vermelho (600 a 699 nm), borda do vermelho (700 a 750 nm) e infravermelho próximo (751 a 1.000 nm), cujos intervalos de referência foram obtidos conforme Jensen (2011). Dentro dessas faixas do EEM foi selecionado o pico de máxima reflectância para o verde e o NIR e o vale de mínima reflectância para o azul e o vermelho. A borda do vermelho foi obtida a partir da primeira derivada em intervalo utilizando o pacote *hsdar*.

TABELA 4 – Índices de vegetação.

Índice de Vegetação	Sigla	Equação	Referência
Pigmento - Antocianina			
<i>Anthocyanin Content Index</i>	ACI	$\frac{\rho_{531}}{\rho_{941}}$	Van den Berg e Perkins, 2005
<i>Anthocyanin Reflectance Index Modified</i>	ARI	$\frac{1}{\rho_{558}} - \frac{1}{\rho_{744}}$	Gitelson et al., 2001
<i>Anthocyanin Reflectance Index</i>	MARI	$\left(\frac{1}{\rho_{558}} - \frac{1}{\rho_{744}}\right) * \rho_{869}$	Gitelson et al., 2006
Pigmento - Carotenóides			
<i>Carotenoids Reflectance Index 1</i>	CRI - 1	$\frac{1}{\rho_{511}} - \frac{1}{\rho_{558}}$	Gitelson et al., 2002a
<i>Carotenoids Reflectance Index 2</i>	CRI - 2	$\frac{1}{\rho_{511}} - \frac{1}{\rho_{744}}$	Gitelson et al., 2002a
Pigmento - Clorofila			
<i>Chlorophyll Index green</i>	CIg	$\left(\frac{\rho_{869}}{\rho_{558}}\right) - 1$	Gitelson et al., 2006
<i>Chlorophyll Index red-edge</i>	CIre	$\left(\frac{\rho_{869}}{\rho_{744}}\right) - 1$	Gitelson et al., 2006
<i>Modified Chlorophyll Absortion in Reflectance Index</i>	MCARI	$\left((\rho_{744} - \rho_{672}) - 0.2 * (\rho_{744} - \rho_{558})\right) * \frac{\rho_{744}}{\rho_{672}}$	Daugtry et al., 2000
<i>Red-Edge NDVI</i>	RENDVI	$\frac{\rho_{753} - \rho_{701}}{\rho_{753} + \rho_{701}}$	Gitelson et al., 1996
<i>Simple Ratio Pigment Index</i>	SIPI	$\frac{\rho_{869} - \rho_{400}}{\rho_{869} - \rho_{672}}$	Peñuelas et al., 1995
Pigmentos			
<i>Pigment Specific Normalised Difference b</i>	PSNDb	$\frac{\rho_{869} - \rho_{634}}{\rho_{869} + \rho_{634}}$	Blackburn, 1998b
<i>Plant Senescence Reflectance Index</i>	PSRI	$\frac{\rho_{681} - \rho_{498}}{\rho_{753}}$	Merzlyak et al., 1999
Estrutura			
<i>Enhanced Vegetation Index</i>	EVI	$2.5 * \left(\frac{\rho_{869} - \rho_{672}}{(\rho_{869} + (6 * \rho_{672}) - (7.5 * \rho_{400})) + 1}\right)$	Huete et al., 2002
<i>Normalised Difference Vegetation Index</i>	NDVI	$\frac{\rho_{869} - \rho_{672}}{\rho_{869} + \rho_{672}}$	Rouse et al., 1974
<i>Simple Ratio Nir/Red</i>	SR NIR/RED	$\frac{\rho_{869}}{\rho_{672}}$	Jordan, 1969
<i>Visible Atmospherically Resistant Index</i>	VARI	$\frac{\rho_{558} - \rho_{672}}{\rho_{558} + \rho_{672} - \rho_{400}}$	Gitelson et al., 2002b
<i>Visible Index green</i>	VIg	$\frac{\rho_{558} - \rho_{672}}{\rho_{558} + \rho_{672}}$	Gitelson et al., 2002b
Fisiologia			
<i>Photochemical Reflectance Index</i>	PRI	$\frac{\rho_{531} - \rho_{571}}{\rho_{531} + \rho_{571}}$	Gamon, 1997
<i>Red-Edge Vegetation Stress Index</i>	RVSI	$\left(\frac{\rho_{715} + \rho_{753}}{2}\right) - \rho_{744}$	Merton, 1998
<i>Water Index</i>	WI	$\frac{\rho_{900}}{\rho_{970}}$	Peñuelas et al., 1997

FONTE: O autor (2023).

Após a análise da curva do comportamento espectral da araucária, identificaram-se os comprimentos de onda onde houve maior e menor reflectância no intervalo do espectro eletromagnético do sensor. Para os índices, os quais os autores estabeleceram comprimentos de onda específicos para a finalidade daquele índice, os comprimentos de onda foram mantidos.

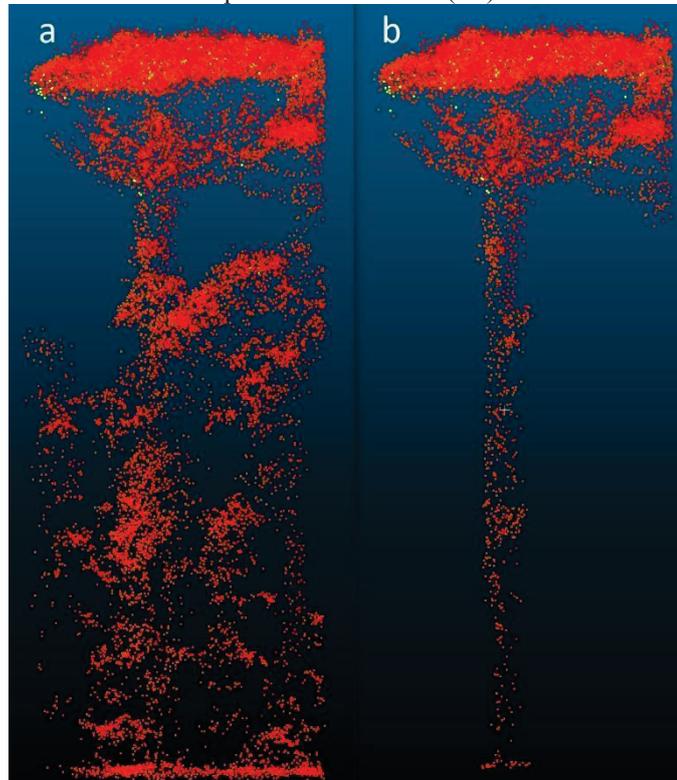
Assim, foram desenvolvidas e implementadas funções baseadas nas equações da Tabela 2 a fim de se calcular os índices de vegetação. Os atributos de entrada nas funções foram as planilhas de reflectâncias para cada uma das árvores e os comprimentos de onda específicos de cada índice. Os índices foram calculados considerando-se tanto todos os píxeis quanto os píxeis iluminados, resultando, então, em dois valores para cada índice.

3.4.4 Dados LiDAR

A nuvem de pontos foi processada utilizando-se alguns passos. O primeiro processamento foi realizado no FUSION/LDV, desenvolvido pelo Departamento de Agricultura dos Estados Unidos (USDA), onde a nuvem foi cortada ao nível das parcelas a fim de diminuir o tamanho ocupado em disco e otimizar o processamento. Após, fez-se a análise das nuvens para verificar a densidade de pontos e então realizar a homogeneização da densidade de pontos para 400 ppm² (pontos por metro quadrado). Com as nuvens das parcelas homogêneas realizou-se o recorte das nuvens com o *shapefile* das copas, assim, cada árvore ficou associada a sua respectiva nuvem e pode-se extrair suas métricas individualmente.

Como as nuvens não continham apenas os pontos referentes às araucárias, mas também de toda a vegetação do sub-bosque, foi realizada a remoção manualmente a partir do *software* Cloud Compare v2.10.2 (Figura 12). Dessa forma, extraíram-se novamente as métricas das nuvens, agora sem o sub-bosque.

FIGURA 12 – a) Recorte da nuvem de pontos do LiDAR para a copa de uma Araucária com os pontos da própria árvore e do sub-bosque sob ela (As); b) nuvem com os pontos do sub-bosque removidos, restando apenas os pontos da Araucária (Aa).



FONTE: O autor (2023).

3.4.5 Algoritmos para modelagem e avaliação dos modelos.

Os pacotes utilizados foram o *caret*, *data.table*, *tidyverse*, *randomForest*, *kernlab*, *elasticnet*. O pacote *caret* possui as funções para serem feitos os ajustes dos modelos, como a função *train*. Dentro dessa função se estabeleceram parâmetros como o método de validação, que neste trabalho foi o *repeated cross validation* (“*repeatedcv*”) com 10 *folds* e 5 repetições. Os algoritmos utilizados para os ajustes também foram definidos na função *train*. Método “*rf*” para *random forest* (RF), “*svrRadial*” para *support vector regression* (SVR), “*enet*” para *elastic net* (ENET). Também foram definidos os hiperparâmetros específicos de cada um dos algoritmos (Tabela 5).

TABELA 5 - Algoritmos e hiperparâmetros utilizados nas modelagens de biomassa acima do solo e dos índices de vegetação.

Algoritmo	Nome	Método	Hiperparâmetros
RF	<i>Random Forest</i>	<i>rf</i>	<i>mtry</i> = c(2, 4, 6, 8, 10, 12) <i>ntree</i> =c(50,100,150,200, 300,400,550,750))
SVR	<i>Support Vector Regression</i>	<i>svrRadial</i>	<i>sigma</i> = c(0.0005,0.0001,0.005,0.001,0.1,0.5) $C = 2^c(5,6,7,8,9,10)$
ENET	<i>Elastic Net</i>	<i>enet</i>	<i>lambda</i> = <i>grid search</i> <i>fraction</i> = <i>grid search</i>

FONTE: O autor (2023).

Para o “*rf*” foi utilizado um código para a customização dos parâmetros, já que a função *train* só permite que seja definido o hiperparâmetro *mtry*, e, assim, pode-se definir, também, o hiperparâmetro *ntree*. Esse código se encontra em Souza (2020). No caso do “*enet*”, os hiperparâmetros foram definidos por meio de busca, *grid search*, onde são testados os hiperparâmetros *lambda* e *fraction*, assim, selecionando quais tiveram o melhor desempenho utilizando o método de validação cruzada “*cv*” com 5 *folds*.

Os dados foram particionados em dois conjuntos, um de treino/validação (80%) e outro de teste (20%). A fim de que fossem utilizados os mesmos conjuntos de dados particionados nos ajustes, adotou-se uma semente (*seed* 550), o que também garante a repetibilidade dos conjuntos de dados utilizados.

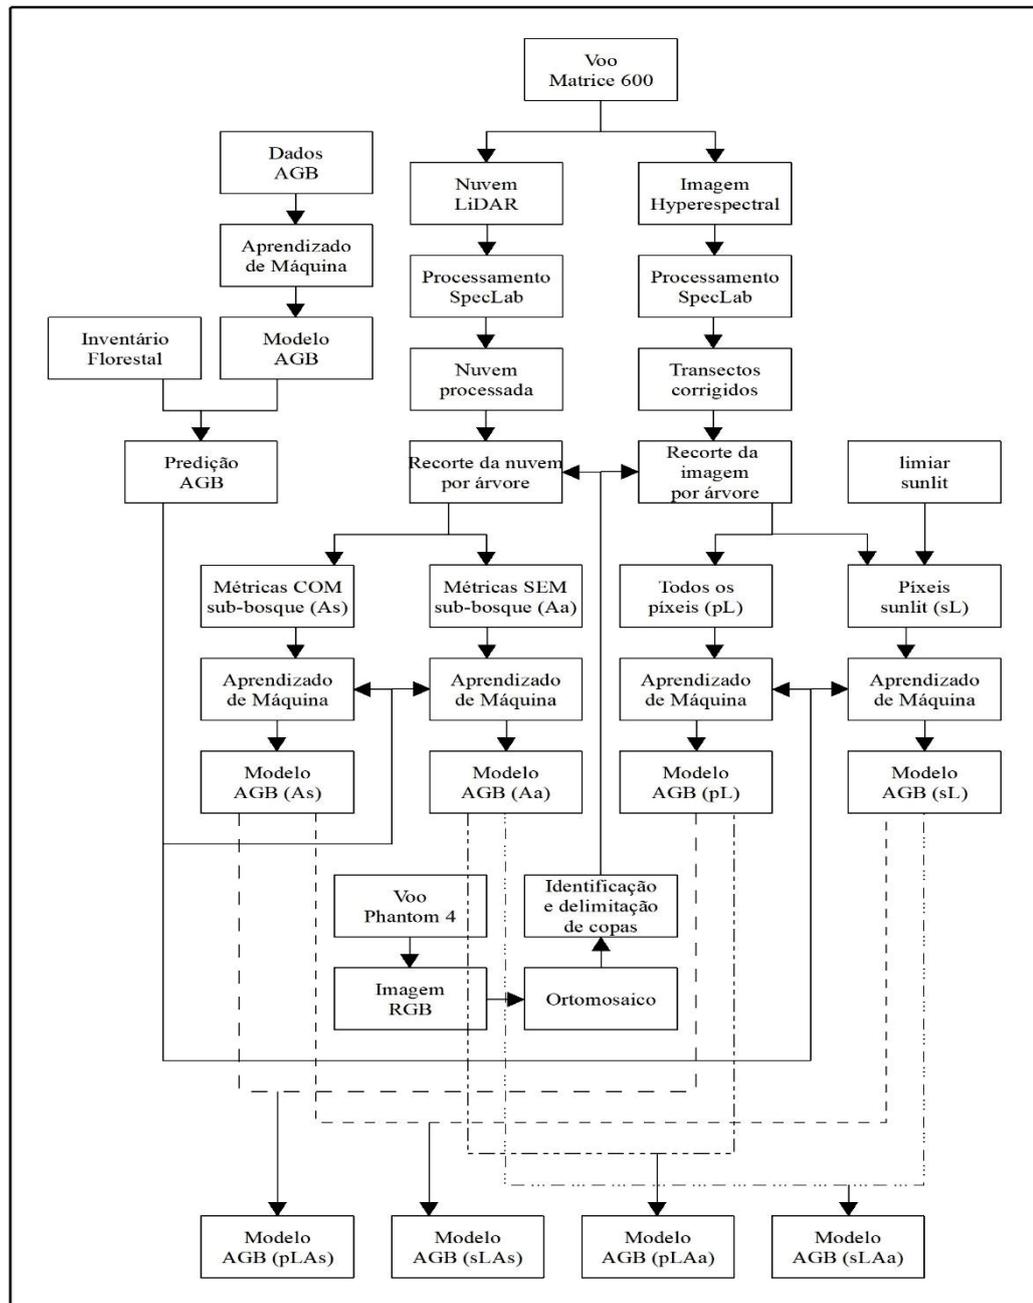
Os modelos desenvolvidos foram avaliados com a adoção de quatro métricas estatísticas: Raiz do Erro Médio Quadrático relativo (RMSE% – *Root Mean Square Error*), Coeficiente de Determinação (R^2), Erro Médio Absoluto (MAE – *Mean Absolut Error*) e Viés relativo (Bias %). Os modelos foram ranqueados conforme essas métricas onde o melhor modelo recebeu peso 0 (zero), os seguintes, pesos 2, 3 e, assim sucessivamente até o último modelo avaliado. O modelo que foi menos penalizado, somando todas as pontuações, foi o selecionado como o de melhor desempenho. Essas métricas foram obtidas com a função *Summary*, disponibilizada em (SOUZA, 2020).

3.4.6 Modelagem da Biomassa

A primeira modelagem realizada considerou a biomassa acima do solo de 44 árvores abatidas para quantificação da biomassa, contando também com as medições de altura e diâmetro. Foi utilizada a variável resposta sem transformação e transformada, utilizando o

logaritmo natural e a raiz quadrada: $\ln AGB$ e \sqrt{AGB} , respectivamente. As variáveis predictoras foram a altura total obtida (H) a partir da nuvem de pontos do LiDAR e o DAP (a partir do CAP medido em campo). A partir dessas, foram construídas novas variáveis: DAP^2 , DAP^{-1} , $(DAP^2)^{-1}$, $DAP*H$, $(DAP^2)*H$, $(D*H)^{-1}$, $((DAP^2)*H)^{-1}$, $\ln DAP$, $\ln DAP^2$, $\ln H$, $\ln((DAP^2)*H)$. A Figura 13 apresenta o fluxograma dos procedimentos utilizados para a modelagem da AGB.

FIGURA 13 – Fluxograma da aquisição dos dados à modelagem da biomassa acima do solo.



FONTE: O autor (2023).

Após a primeira modelagem, foi feita a predição da biomassa para as árvores da área de estudo. Em uma planilha eletrônica foram dispostas, para cada uma das 118 árvores, os atributos da biomassa estimada a partir do modelo selecionado, as 270 bandas espectrais e as métricas obtidas a partir da nuvem de pontos adquirida pelo sensor LiDAR. Além disso, também foi adicionado um campo para a variável área de copa, a qual foi obtida a partir do *shapefile* das copas delimitadas no ortomosaico. As demais modelagens da biomassa foram utilizadas apenas a variável resposta transformada *lnAGB* e *sqrtAGB*.

Dessa forma, foram realizados os ajustes da biomassa em função de todas as variáveis. Também foram feitos ajustes em função apenas das variáveis mais importantes (maiores ou iguais a 90%), obtidas com o pacote *caret*. Isso se repetiu para todas as modelagens de biomassa seguintes.

3.4.6.1 Modelagem da Biomassa com dados do sensor LiDAR

A AGB foi modelada a partir das métricas obtidas das nuvens de pontos do sensor LiDAR, um total de 92 métricas. Entre essas métricas estão as relativas à intensidade do sinal, elevação e número de retornos, além de estatísticas dessas variáveis. Ainda nessa modelagem com os dados LiDAR, foi adicionada a variável área de copa que, segundo Qiao et al. (2023), a introdução de variáveis da copa, como a área, pode ser um método viável para aumentar a acurácia da predição da biomassa de árvores individuais.

Para tanto, as métricas foram obtidas a partir de dois tratamentos da nuvem de pontos. Primeiro, as métricas da nuvem contendo todos os pontos, ou seja, os que compreendem a árvore de araucária e os que compreendem o sub-bosque abaixo da sua copa (As). Segundo, a partir apenas dos pontos que compreendem a árvore de araucária (Aa).

3.4.6.2 Modelagem da Biomassa com dados Hiperespectrais

Quanto ao uso dos dados hiperespectrais para a modelagem da AGB, foram utilizadas as 270 bandas do sensor, cujos comprimentos de onda compreendem o intervalo de 400 nm a 1.000 nm. A primeira modelagem foi realizada utilizando as reflectâncias de todos os píxeis obtidos desses comprimentos de onda (pL) e a segunda, apenas as reflectâncias dos píxeis iluminados (sL).

3.4.6.3 Modelagem da Biomassa com a integração dos dados LiDAR e Hiperespectrais

A integração dos dados de ambos os sensores se deu a partir da utilização de todas as variáveis preditoras, isto é, as 270 bandas hiperespectrais e as 92 métricas mais a área de copa. Essa última modelagem foi realizada com quatro combinações dos conjuntos das variáveis preditoras. Reflectâncias de todos os píxeis da amostra com a nuvem de pontos da Araucária contendo a vegetação do sub-bosque (pLAs), reflectâncias de todos os píxeis da amostra com a nuvem de pontos contendo somente a Araucária (sLAa), reflectâncias apenas dos píxeis iluminados (*sunlit*) com a nuvem de pontos da Araucária contendo a vegetação do sub-bosque (sLAs) e reflectâncias apenas dos píxeis iluminados (*sunlit*) com a nuvem de pontos contendo somente a Araucária (sLAa).

3.4.7 Modelagem dos índices de Vegetação com as métricas da nuvem de pontos do LiDAR

Os índices de vegetação foram calculados a partir dos comprimentos de onda obtidos na caracterização espectral da araucária, tanto utilizando todos os píxeis quanto apenas os píxeis iluminados. A modelagem foi feita a partir das métricas obtidas com o processamento da nuvem de pontos do LiDAR. Foram consideradas as nuvens onde os pontos do sub-bosque da FOM estão presentes junto aos indivíduos de Araucária (As) e onde os pontos do sub-bosque foram removidos (Aa), restando, assim, somente os pontos dos indivíduos de Araucária.

Da mesma forma que as modelagens da AGB, os modelos dos IVs foram obtidos a partir de três algoritmos. Inicialmente foram adotadas todas as métricas como variáveis preditoras e posteriormente foram selecionadas apenas as variáveis mais importantes, as quais apresentaram Importância igual ou superior a 90%.

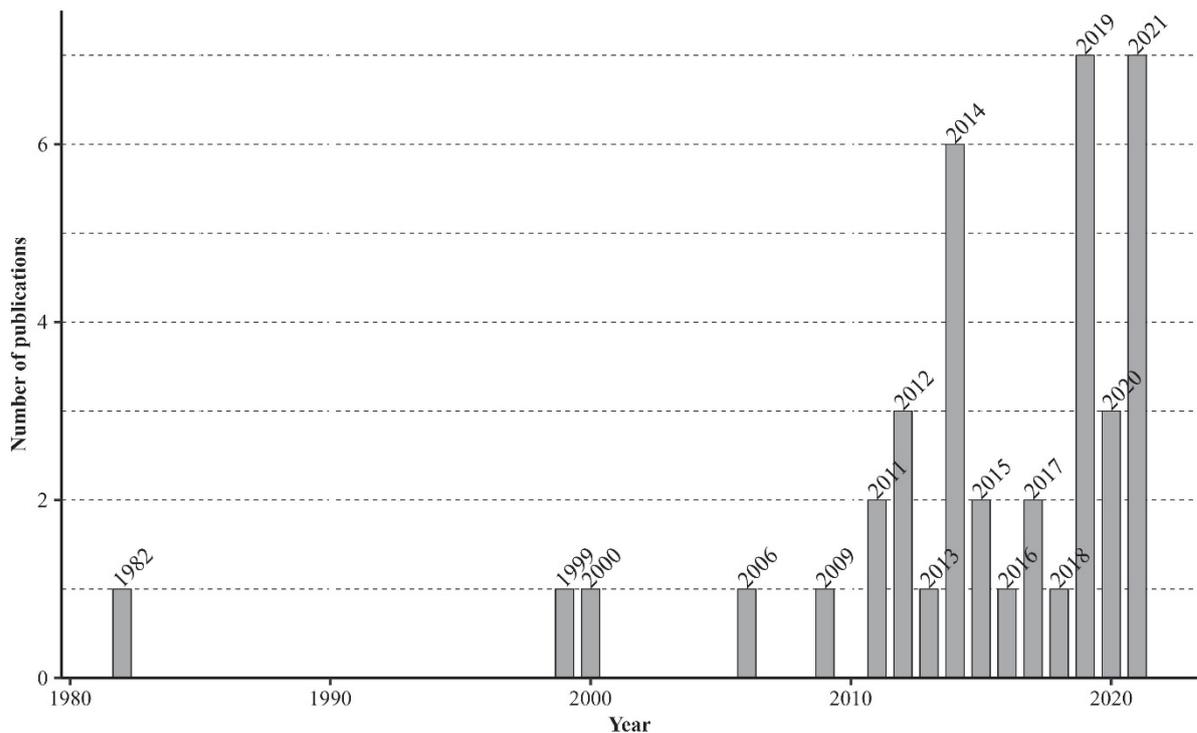
4 RESULTADOS

4.1 ANÁLISE BIBLIOMÉTRICA

Ao todo foram encontradas 118 publicações no *Scopus*, 121 na *Web of Science* e 18 na *Science Direct* relacionadas com o objeto deste trabalho, conforme escopo detalhado em materiais e métodos. Após a triagem, retirada das duplicatas e verificação dos critérios de exclusão, 40 artigos foram classificados para a próxima etapa, os quais foram analisados criteriosamente.

Quanto à distribuição dos trabalhos ao longo do tempo, a primeira publicação encontrada foi do ano de 1982 e até a primeira década do século XXI não passavam de apenas uma publicação por ano (Figura 14). Vale salientar que o trabalho de Enright (1982) pode não ter sido o primeiro a ser realizado sobre o tema, no entanto, foi o primeiro indexado em uma das plataformas de buscas, habilitando-o, portanto, como o primeiro trabalho dentre as fontes consultadas. Além disso, muitas publicações antigas estão em meio impresso, o que também pode dificultar o seu acesso.

FIGURA 14 – Distribuição dos manuscritos publicados, ao longo do tempo, relacionados com o estoque de carbono e/ou biomassa em *Araucaria* sp. e indexados nas bases de dados *Scopus*, *Web of Science* e/ou *Science Direct*, até o ano de 2021.



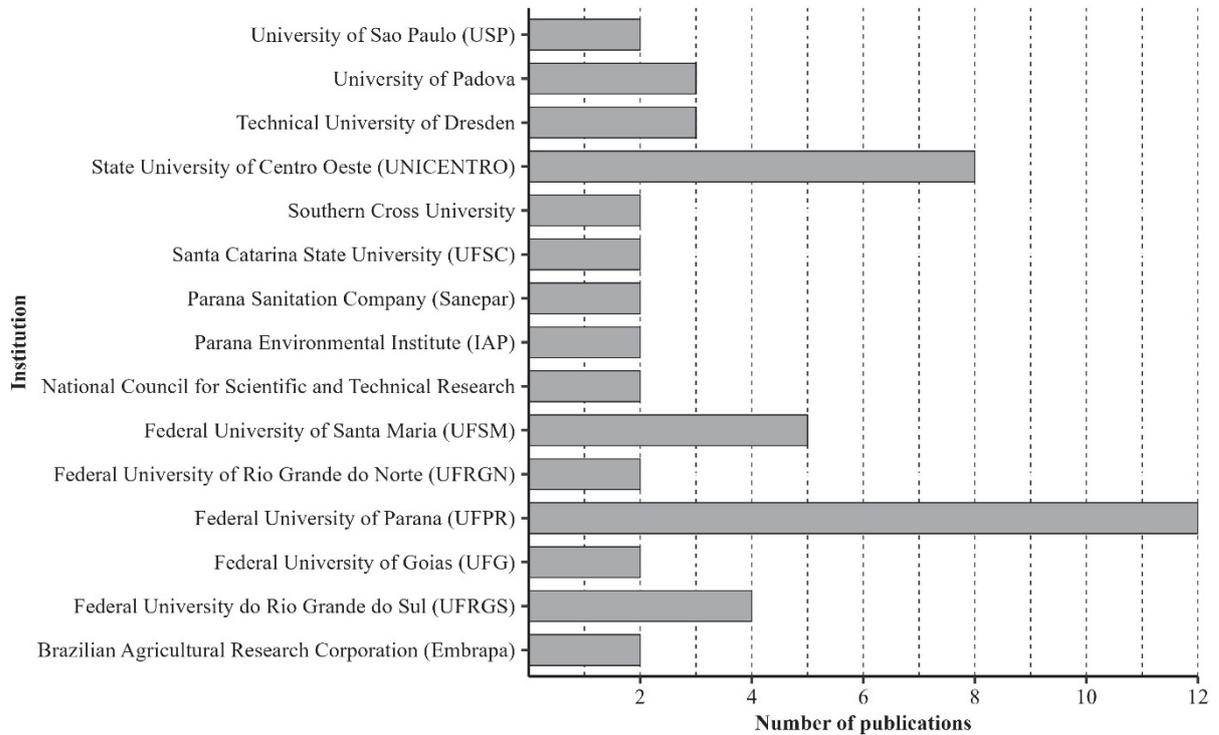
FONTE: O autor (2023).

A distribuição dos manuscritos ao longo do tempo apresentou irregularidade em sua distribuição, tendo picos de publicações em 2014 (6 publicações), 2019 e 2021 (ambos com 7 publicações). A maioria dos trabalhos foram publicados nos últimos 8 anos (29 trabalhos), concentrando 72,5% desde 1982. O aumento dos trabalhos a partir de 2014 pode ter sido influenciado pela COP-18, realizada em 2012 na cidade de Doha (Qatar), onde, segundo ONU (2012) foi aprovada a segunda fase do Protocolo de Quioto, incentivando, portanto, a pesquisa sobre estoques de biomassa e carbono em ambientes florestais. A queda no número de publicações entre os anos de 2019 e 2021 pode ser explicada pela deflagração da pandemia de Covid-19 em 2020, o que prejudicou o deslocamento para a realização de trabalhos a campo e também a redução de destinação de verbas para pesquisa em outras áreas de conhecimento, concentrando maior esforço e investimento de recursos para pesquisas na área da saúde.

Com relação ao tipo de documento, os trabalhos foram enquadrados nas categorias artigos científicos publicados em periódicos e trabalhos apresentados em conferências, sendo que os artigos representaram 95% das publicações, um total de 38 publicações. É importante destacar que na busca realizada não foram inseridas restrições quanto ao tipo de publicação. Foram encontrados trinta periódicos responsáveis pelas publicações dos artigos utilizados nesta pesquisa, dentre os quais dez são brasileiros com 19 trabalhos publicados, os demais, têm origem em outras nacionalidades. Os periódicos que mais se destacaram, quanto ao número de publicações, foram: *Revista Floresta*, *Scientia Forestalis* *Forest Sciences*, *Ciência Florestal* e *Floresta e Ambiente*, com 5, 3, 2 e 2 trabalhos, respectivamente.

Um total de 59 instituições estiveram envolvidas nas publicações encontradas. Destas, 15 instituições se vincularam com pesquisas relacionadas ao estoque de biomassa e carbono em *Araucaria* sp., sendo 73% dessas de nacionalidade brasileira (Figura 15). Com relação às brasileiras, destacou-se a Universidade Federal do Paraná (12 trabalhos), Universidade Estadual do Centro Oeste (8 trabalhos), Universidade Federal de Santa Maria (5 trabalhos) e Universidade Federal do Rio Grande do Sul (4 trabalhos), enquanto para as demais nacionalidades os destaques foram para *Technische Universität Dresden* (Alemanha) e *Università degli Studi di Padova* (Itália), ambas com 3 trabalhos.

FIGURA 15 – Instituição de afiliação dos autores com publicações, relacionadas com o estoque de carbono e/ou biomassa em *Araucaria* sp. e indexados nas bases de dados *Scopus*, *Web of Science* e/ou *Science Direct*, até o ano de 2021.



FONTE: O autor (2023).

As duas instituições com o maior número de publicações estão localizadas na região Sul do Brasil, contribuindo com 50% das pesquisas realizadas. Por estarem localizadas na tipologia florestal da Floresta Ombrófila Mista, é natural que seus pesquisadores invistam nas formações florestais existentes onde estão instaladas. Da mesma forma, o periódico com o maior número de publicações foi a Revista Floresta, a qual está vinculada à UFPR. Apesar de um terço dos periódicos serem de nacionalidade brasileira, a maioria dos artigos publicados neles está em língua inglesa, 52%, o que é positivo, pois tem maior alcance na difusão dos resultados e na divulgação científica.

As pesquisas foram realizadas em 8 países diferentes e 1, realizada por Papú et al. (2021), onde o local não foi especificado, possivelmente na Argentina ou Chile devido à espécie de estudo ser a *Araucaria araucana* e às instituições onde os pesquisadores estão vinculados (Tabela 6). Devido ao gênero *Araucaria* ocorrer naturalmente apenas no hemisfério sul, era esperado que os trabalhos fossem encontrados apenas nesses países.

TABELA 6 – Distribuição dos trabalhos por país.

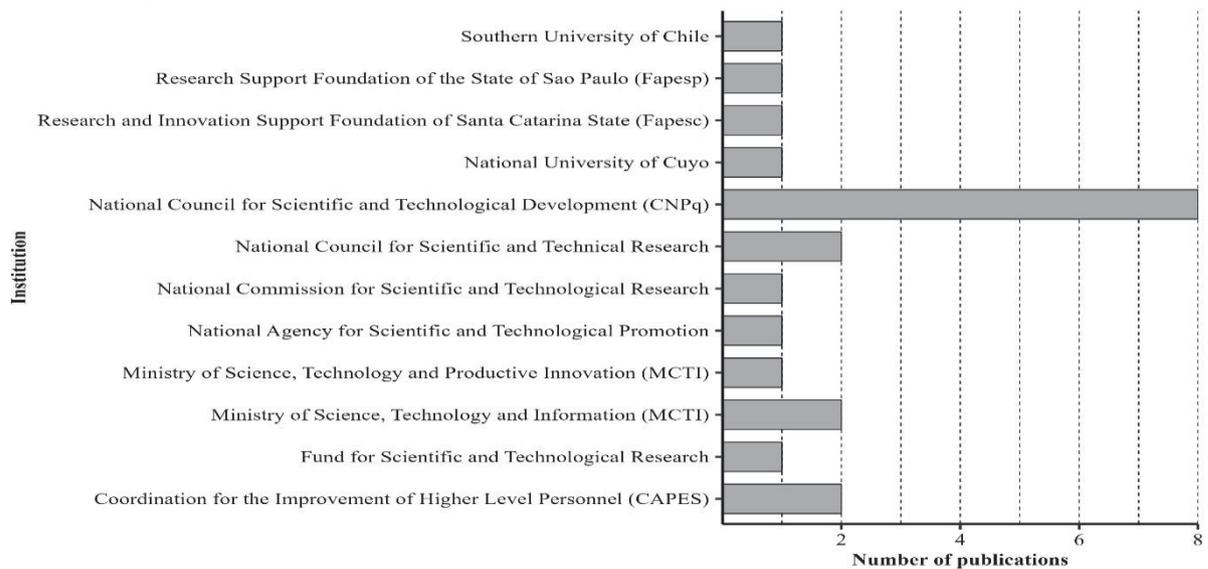
País	Trabalhos	N
Brasil	Alabrace e Dillenburg, 2012; Alabrace e Dillenburg, 2014; Alves et al., 2019; Amaral et al., 2014; Bull et al., 2021; Caldeira et al., 2015; Duarte e Dillenburg, 2000; Garcia et al., 2019; Inkotte et al., 2015; Lipinski et al., 2017; Orellana e Vanclay, 2018; Orellana et al., 2017; Rex et al., 2019; Rodrigues et al., 2021; Roik et al., 2020; Rossa et al., 2011; Rosenfield e Souza, 2014; Ruiz et al., 2021; Sanquetta et al., 2013; Sanquetta et al., 2014a; Sanquetta et al., 2014b; Schumacher et al., 2011; Sevegnani et al., 2019; Souza e Longhi, 2019; Vieira et al., 2019; Watzlawick et al., 2012; Watzlawick et al., 2014.	27
Chile	Kutchartt et al., 2021; Lusk et al., 2006; Pirotti et al., 2020.	3
Austrália	Bubb et al., 1999; Grace e Basso, 2012.	2
Argentina	Gallia et al., 2021.	1
Índia	Jain et al., 2019.	1
Papua Nova	Enright, 1982.	1
Guiné		
Paquistão	Dilshad et al., 2021.	1
Uganda	Orikiriza et al., 2009.	1
Não especificado	Papú et al., 2021.	1

FONTE: O autor (2023).

LEGENDA: N = número de trabalhos.

Entre as agências de fomento à pesquisa, o Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) foi o órgão que mais financiou pesquisas na área, seguido da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), do Ministério da Ciência, Tecnologia e Inovação (MCTIC) e do Consejo Nacional de Investigaciones Científicas y Técnicas (CONICET) (Figura 16).

FIGURA 16 – Agências de fomento à pesquisa, relacionadas com o estoque de carbono e/ou biomassa em *Araucaria* sp. e indexados nas bases de dados *Scopus*, *Web of Science* e/ou *Science Direct*, até o ano de 2021.



FONTE: O autor (2023).

As três primeiras agências pertencem ao Brasil, enquanto a última citada pertence à Argentina. O Brasil foi o país que mais atuou nessas pesquisas, contabilizando 27 trabalhos, seguido do Chile com 3. O que demonstra a importância das agências de fomento à pesquisa, já que, das 13 mencionadas nos trabalhos, três são do Brasil, representando 50% dos trabalhos financiados por elas.

A principal área da ciência, contemplada pelas publicações avaliadas, foi a de Agricultura e Ciências Biológicas, com a maioria das publicações, 52%, seguida da área de Ciências do Ambiente, 22%. *Biochemistry Genetics and Molecular Biology, Energy, Computer Science, Earth and Planetary Sciences* somaram 16% enquanto *Chemical Engineering, Chemistry, Engineering, Medicine, Physics and Astronomy, Social Sciences* somaram 10%. A maioria dos trabalhos está vinculada à área do conhecimento da Agricultura e Ciências Biológicas, seguida das Ciências do Ambiente. Juntas, são responsáveis por 75% das publicações.

Do total de trabalhos realizados, 23 foram em florestas nativas e 17 em plantios, sendo que 12 desses foram experimentos controlados com germinação de sementes e produção de mudas. Nesse último caso também foi quantificada a biomassa das raízes. Cinco espécies do gênero *Araucaria* foram utilizadas nas pesquisas (Tabela 7), destacando-se a espécie *Araucaria angustifolia* aparecendo em 68% dos trabalhos.

TABELA 7 – Distribuição dos trabalhos por espécies, relacionadas com o estoque de carbono e/ou biomassa em *Araucaria* sp. e indexados nas bases de dados *Scopus, Web of Science e/ou Science Direct*, até o ano de 2021.

Espécie	Trabalhos	N
<i>A. angustifolia</i>	Alabrace e Dillenburg, 2012; Alabrace e Dillenburg, 2014; Alves et al., 2019; Amaral et al., 2014; Bull et al., 2021; Caldeira et al., 2015; Duarte e Dillenburg, 2000; Garcia et al., 2019; Lipinski et al., 2017; Orellana e Vanclay, 2018; Orellana et al., 2017; Rex et al., 2019; Rodrigues et al., 2021; Roik et al., 2020; Rossa et al., 2011; Rosenfield e Souza, 2014; Ruiz et al., 2021; Sanquetta et al., 2013; Sanquetta et al., 2014a; Sanquetta et al., 2014b; Schumacher et al., 2011; Sevegnani et al., 2019; Souza e Longhi, 2019; Vieira et al., 2019; Watzlawick et al., 2012; Watzlawick et al., 2014.	26
<i>A. araucana</i>	Gallia et al., 2021; Kutchart et al., 2021; Lusk et al., 2006; Papú et al., 2021; Pirotti et al., 2020.	5
<i>A. cunninghamii</i>	Bubb et al., 1999; Dilshad et al., 2021; Enright, 1982; Grace e Basso, 2012; Orikiriza et al., 2009.	5
<i>A. hunsteinii</i>	Enright, 1982.	1
<i>A. cookie</i>	Jain et al., 2019.	1

FONTE: O autor (2023).

LEGENDA: N = número de trabalhos

Apenas 13 trabalhos tiveram como objetivo a predição e quantificação da biomassa e 8 a quantificação de carbono (Tabela 8), ambos contabilizaram 46,7% das pesquisas. Os demais trabalhos tiveram objetivos distintos, em que a biomassa foi utilizada como meio para alcançá-los.

TABELA 8 – Distribuição dos trabalhos conforme os objetivos propostos, relacionadas com o estoque de carbono e/ou biomassa em *Araucaria* sp. e indexados nas bases de dados *Scopus*, *Web of Science* e/ou *Science Direct*, até o ano de 2021.

Objetivos	Trabalhos	N
Biomassa	Caldeira et al., 2015; Garcia et al., 2019; Inkotte et al., 2015; Kutchartt et al., 2021; Lipinski et al., 2017; Orellana et al., 2017; Pirotti et al., 2020; Rex et al., 2019; Roik et al., 2020; Rosenfield e Souza, 2014; Sanquetta et al., 2014a; Schumacher et al., 2011; Watzlawick et al., 2012.	13
Carbono	Caldeira et al., 2015; Lipinski et al., 2017; Roik et al., 2020; Sanquetta et al., 2013; Sanquetta et al., 2014a; Sanquetta et al., 2014b; Watzlawick et al., 2012; Watzlawick et al., 2014.	8
Bioquímica (nutrição, defesa e pigmentos)	Alabrace e Dillenburg, 2012; Alabrace e Dillenburg, 2014; Bubb et al., 1999; Bull et al., 2021; Dilshad et al., 2021; Gallia et al., 2021; Papú et al., 2021.	7
Crescimento	Enright, 1982; Lusk et al., 2006; Orellana e Vanclay, 2018; Orellana et al., 2017; Oriquiriza et al., 2009; Rossa et al., 2011; Vieira et al., 2019.	7
Energia	Alves et al., 2019; Rodrigues et al., 2021; Ruiz et al., 2021.	3
Emissões de gases	Amaral et al., 2014; Grace e Basso, 2012.	2
Estrutura, dinâmica e diversidade	Sevegnani et al., 2019; Souza e Longhi, 2019.	2
Morfologia e fisiologia	Duarte e Dillenburg, 2000; Papú et al., 2021.	2
Condições de plantio	Jain et al., 2019.	1

FONTE: O autor (2023).

LEGENDA: N = número de trabalhos.

O método direto de quantificação da biomassa, ou seja, empregando o método destrutivo do material vegetal coletado, foi o mais empregado pelos autores, somando 28 trabalhos. Os outros métodos utilizados foram o da modelagem matemática com o uso de equações ajustadas para realizar a predição (7 trabalhos) e simulação (3 trabalhos). Entre as equações já disponíveis na literatura foram utilizadas as publicadas por Sanquetta et al. (2003), Chave et al. (2014) e Ratuchne (2015). O material vegetal mais utilizado, foi a biomassa acima do solo (Tabela 9), presente em 87% dos trabalhos e todos que fizeram a biomassa de raiz não foram realizados em florestas nativas.

TABELA 9 – Distribuição por material, relacionados com o estoque de carbono e/ou biomassa em *Araucaria* sp. e indexados nas bases de dados *Scopus*, *Web of Science* e/ou *Science Direct*, até o ano de 2021.

Material	Trabalhos	N
Biomassa acima do solo	Alabrace e Dillenburg, 2012; Alabrace e Dillenburg, 2014; Amaral et al., 2014; Bubb et al., 1999; Bull et al., 2021; Caldeira et al., 2015; Dilshad et al., 2021; Duarte e Dillenburg, 2000; Enright, 1982; Gallia et al., 2021; Garcia et al., 2019; Grace e Basso, 2012; Jain et al., 2019; Kutchartt et al., 2021; Lipinski et al., 2017; Lusk et al., 2006; Orellana et al., 2017; Orellana e Vanclay, 2018; Orikiriza et al., 2009; Papú et al., 2021; Pirotti et al., 2020; Rex et al., 2019; Roik et al., 2020; Rosenfield e Souza, 2014; Rossa et al., 2011; Sanquetta et al., 2013; Sanquetta et al., 2014b; Schumacher et al., 2011; Sevegnani et al., 2019; Souza e Longhi, 2019; Vieira et al., 2019; Watzlawick et al., 2012; Watzlawick et al., 2014.	33
Raiz	Alabrace e Dillenburg, 2012; Alabrace e Dillenburg, 2014; Bubb et al., 1999; Bull et al., 2021; Duarte e Dillenburg, 2000; Enright, 1982; Gallia et al., 2021; Grace e Basso, 2012; Jain et al., 2019; Lusk et al., 2006; Orikiriza et al., 2009; Papú et al., 2021; Rossa et al., 2011; Sanquetta et al., 2013; Sanquetta et al., 2014b; Schumacher et al., 2011; Vieira et al., 2019.	17
Serapilheira	Inkotte et al., 2015; Sanquetta et al., 2014a; Schumacher et al., 2011.	3
Ramos	Dilshad et al., 2021; Rodrigues et al., 2021; Ruiz et al., 2021.	3
Semente	Alabrace e Dillenburg, 2012; Alabrace e Dillenburg, 2014; Alves et al., 2019; Gallia et al., 2021.	4
Madeira morta e vegetação não madeireira	Sanquetta et al., 2014a.	1

FONTE: O autor (2023).

LEGENDA: N = número de trabalhos.

Os métodos utilizados para a determinação do teor de carbono orgânico, entre os trabalhos que fizeram essa avaliação foram a Conversão da matéria orgânica (Mufla), 3 trabalhos (AMARAL et al., 2014; RODRIGUES et al., 2021; RUIZ et al., 2021), Combustão Seca, 5 trabalhos (ALVES et al., 2019; ROIK et al., 2020; SANQUETTA et al., 2013; SANQUETTA et al., 2014a; SANQUETTA et al., 2014b), Combustão Úmida, 3 trabalhos (CALDEIRA et al., 2015; WATZLAWICK et al., 2012; WATZLAWICK et al., 2014) e em 2 trabalhos o Fator de Conversão (GRACE e BASSO, 2012; ROSENFELD e SOUZA, 2014), que utilizaram um fator de 0,5 (BALBINOT, 2004; HOUGHTON, 2007; GIFFORD, 2000a, GIFFORD, 2000b).

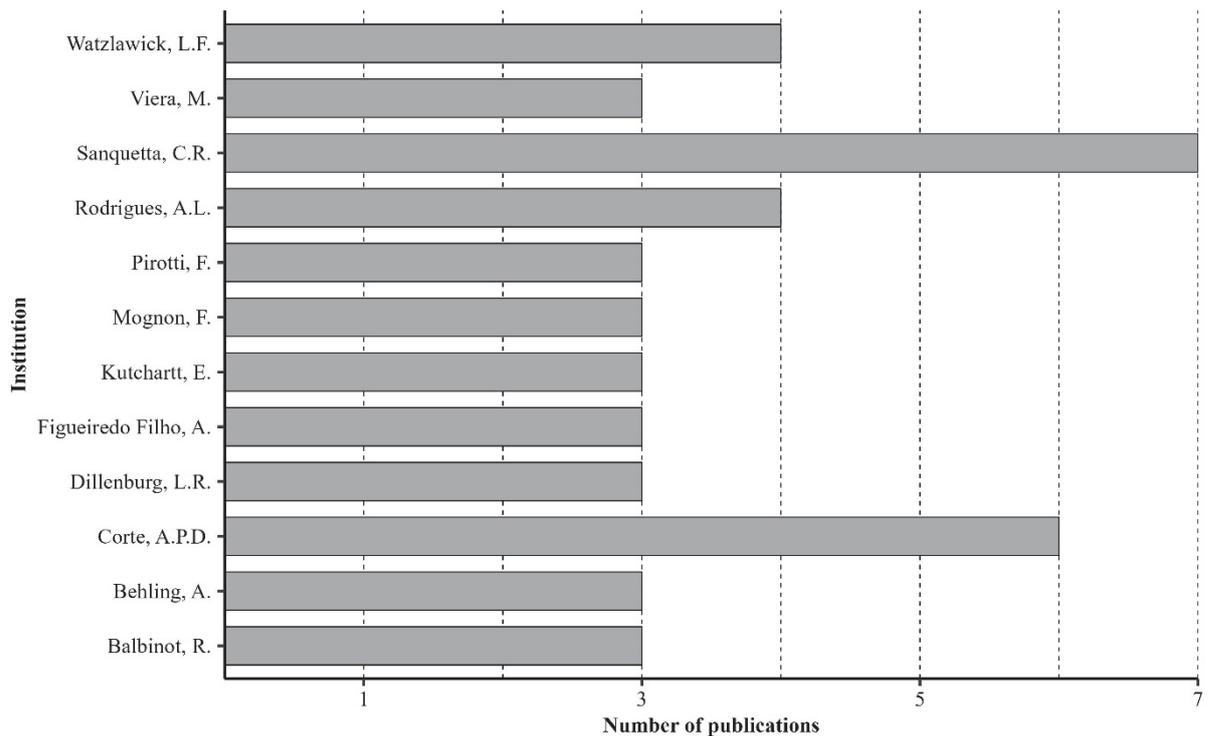
Embora o emprego de geotecnologias já seja difundido para a finalidade de predição de biomassa e carbono (WATZLAWICK et al., 2009; ALONZO et al., 2016; JAAFAR et al., 2017; d'OLIVEIRA et al., 2020), apenas dois trabalhos adotando o sensoriamento remoto foram encontrados, Rex et al. (2019) adotando o sensor LiDAR – *Ligh Detection and Range*, e Pirotti et al. (2020) com os satélites da série Landsat 5, 7 e 8, Sentinel-2 e Palsar, além disso, foi utilizado o *Google Earth Engine* como provedor dos dados e processamento.

O que chamou a atenção foi que nenhum dos trabalhos publicados utilizaram técnicas de inteligência artificial como os algoritmos de aprendizado de máquina. Tais algoritmos já foram implementados nas predições da biomassa, entre eles: *Random Forest - RF*, *Artificial*

Neural Network – ANN, k-Nearest Neighbour – k-NN e Support Vector Machine – SVM (MARCHESAN et al., 2020; REX et al., 2020; SCHUH et al., 2020).

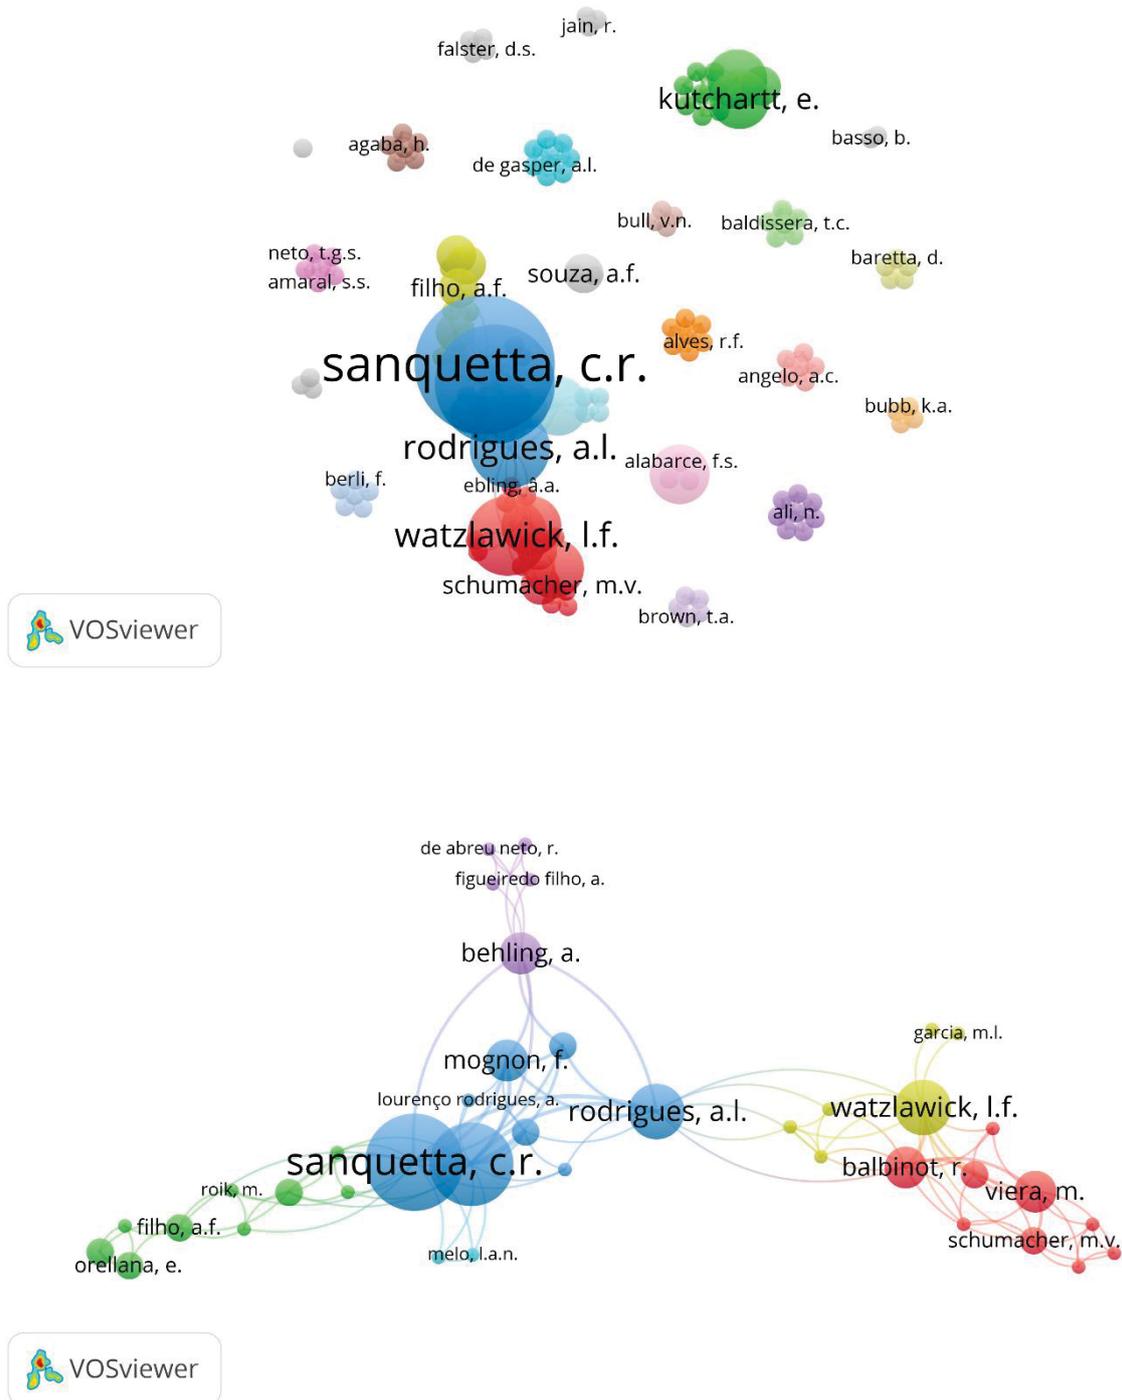
Foram contabilizados 139 autores, e os que mais se destacaram quanto ao número de publicações foram o Dr. Calos Roberto Sanquetta, seguido da Dr.^a Ana Paula Dalla Corte, Dr. Luciano Farinha Watzlawick e Dr. Aurélio Lourenço Rodrigues (Figura 17). Como primeiro autor, o Dr. Carlos Roberto Sanquetta foi o que teve mais trabalhos publicados, somando 3 publicações (SANQUETTA et al., 2013; 2014a; 2014b). Outros 3 autores apareceram duas vezes como primeiro autor, Dr. Fernanda da Silva Alabarce (ALABARCE e DILLENBURG. 2012; 2014), Dr. Enrique Orellana (ORELLANA et al., 2017; ORELLANA e VANCLAY, 2018) e Dr. Luciano Farinha Watzlawick (WATZLAWICK et al., 2012; 2014). Na Figura 18 observa-se a teia de integração dos autores.

FIGURA 17 – Autores com pelo menos três publicações, relacionadas com o estoque de carbono e/ou biomassa em *Araucaria* sp. e indexados nas bases de dados *Scopus*, *Web of Science* e/ou *Science Direct*, até o ano de 2021.



FONTE: O autor (2023).

FIGURA 18 – Teia de integração, de cocitação, dos autores com publicações, relacionadas com o estoque de carbono e/ou biomassa em *Araucaria* sp. e indexados nas bases de dados *Scopus*, *Web of Science* e/ou *Science Direct*, até o ano de 2021.



FONTE: O autor (2023).

4.2 INVENTÁRIO FLORESTAL E FITOSSOCIOLOGIA

4.2.1 Diversidade florística

Foram identificadas 75 espécies, 56 gêneros e 34 famílias (Tabela 10). Entre os indivíduos não identificados (NI), em 34 foi possível identificar o gênero e família, enquanto entre os demais NI em 14 pode-se chegar ao nível de família. Os gêneros mais abundantes foram *Araucaria*, *Nectandra*, *Ilex*, *Blepharocalyx*, *Cinnamomum*, *Matayba* e *Eugenia*, com 507, 405, 191, 140, 120, 113 e 100 indivíduos, respectivamente. As famílias mais abundantes foram Lauraceae, Araucariaceae, Myrtaceae, Aquifoliaceae e Sapindaceae, com 606, 507, 364, 191 e 164 indivíduos, respectivamente. Essas famílias também foram as mais abundantes encontradas por Longhi (1980) que, na mesma área, encontrou 51 espécies, 36 gêneros e 26 famílias. Faz-se a ressalva de que o DAP de inclusão usado por Longhi (1980) foi maior ou igual a 20 cm.

TABELA 10 – Composição florística da área de estudo.

(continua)

Espécie	Família
<i>Actinostemon concolor</i> (Spreng.) Müll.Arg.	EUPHORBIACEAE
<i>Aegiphila integrifolia</i> (Jacq.) Moldenke	LIMIACEAE
<i>Allophylus edulis</i> (A.St.-Hil. et al.) Hieron. ex Niederl.	SAPINDACEAE
<i>Allophylus semidentatus</i> (Miq.) Raddlk.	SAPINDACEAE
<i>Araucaria angustifolia</i> (Bertol.) Kuntze	ARAUCARIACEAE
<i>Blepharocalyx salicifolius</i> (Kunth) O. Berg	MYRTACEAE
<i>Campomanesia guazumifolia</i> (Cambess.) O. Berg	MYRTACEAE
<i>Campomanesia xanthocarpa</i> (Mart.) O.Berg	MYRTACEAE
<i>Casearia decandra</i> Jacq.	SALICACEAE
<i>Casearia obliqua</i> Spreng.	SALICACEAE
<i>Casearia sylvestris</i> Sw.	SALICACEAE
<i>Cedrela fissilis</i> Vell.	MELIACEAE
<i>Cinnamodendron dinisii</i> Schwacke	CANELLACEAE
<i>Cinnamomum amoenum</i> (Nees & Mart.) Kosterm.	LAURACEAE
<i>Cinnamomum sellowianum</i> (Ness & Mart.) Kosterm.	LAURACEAE
<i>Citronella gongonha</i> (Mart.) R.A.Howard	CARDIOPTERIDACEAE
<i>Clethra scabra</i> Pers.	CLETHRACEAE
<i>Cryptocarya aschersoniana</i> Mez	LAURACEAE
<i>Cupania vernalis</i> Cambess.	SAPINDACEAE
<i>Dahlstedtia muehlbergiana</i> (Hassl.) M.J.Silva & A.M.G.Azevedo	FABACEAE
<i>Drimys brasiliensis</i> Miers.	WINTERACEAE
<i>Erythroxylum deciduum</i> A. St.-Hil.	ERYTHROXYLACEAE
<i>Eugenia chlorophylla</i> O.Berg	MYRTACEAE
<i>Eugenia handroana</i> D. Legrand	MYRTACEAE
<i>Eugenia involucrata</i> DC.	MYRTACEAE
<i>Eugenia uniflora</i> L.	MYRTACEAE
<i>Gymnanthes klotzschiana</i> Müll.Arg.	EUPHORBIACEAE
<i>Hovenia dulcis</i> Thunb.	RHAMNACEAE

TABELA 10 – Composição florística da área de estudo.

(continuação)

Espécie	Família
<i>Ilex brevicuspis</i> Reissek	AQUIFOLIACEAE
<i>Ilex dumosa</i> Reissek	AQUIFOLIACEAE
<i>Ilex paraguariensis</i> A. St.-Hil.	AQUIFOLIACEAE
<i>Ilex theezans</i> Mart. ex Reissek	AQUIFOLIACEAE
<i>Jacaranda puberula</i> Cham.	BIGNONIACEAE
<i>Lithraea brasiliensis</i> Marchand	ANACARDIACEAE
<i>Lithraea molleoides</i> (Vell.) Engl.	ANACARDIACEAE
<i>Luehea divaricata</i> Mart.	MALVACEAE
<i>Machaerium stipitatum</i> Vogel	FABACEAE
<i>Matayba elaeagnoides</i> Radlk.	SAPINDACEAE
<i>Monteverdia ilicifolia</i> (Mart. ex Reissek) Biral	CELASTRACEAE
<i>Moquiniastrum polymorphum</i> (Less.) G. Sancho	ASTERACEAE
<i>Myrceugenia euosma</i> (O. Berg) D. Legrand	MYRTACEAE
<i>Myrcia guianensis</i> (Aubl.) DC.	MYRTACEAE
<i>Myrcia hatschbachii</i> D. Legrand	MYRTACEAE
<i>Myrcia palustris</i> DC.	MYRTACEAE
<i>Myrcia splendens</i> (Sw.) DC.	MYRTACEAE
<i>Myrsine coriacea</i> (Sw.) R.Br. ex Roem. & Schult.	PRIMULACEAE
<i>Myrsine umbellata</i> Mart.	PRIMULACEAE
<i>Nectandra grandiflora</i> Nees & Mart	LAURACEAE
<i>Nectandra lanceolata</i> Nees	LAURACEAE
<i>Nectandra megapotamica</i> (Spreng.) Mez	LAURACEAE
<i>Ocotea corymbosa</i> (Meisn.) Mez	LAURACEAE
<i>Ocotea diospyrifolia</i> (Meisn.) Mez	LAURACEAE
<i>Ocotea porosa</i> (Nees & Mart.) Barroso	LAURACEAE
<i>Ocotea puberula</i> (Rich.) Nees	LAURACEAE
<i>Piptocarpha axillaris</i> (Less) Baker.	ASTERACEAE
<i>Piptocarpha angustifolia</i> Dusén ex. Malme	ASTERACEAE
<i>Prunus brasiliensis</i> (Cham. & Schtdl.) D. Dietr.	ROSACEAE
<i>Psidium myrtoides</i> O.Berg	MYRTACEAE
<i>Randia armata</i> (Sw.) DC.	RUBIACEAE
<i>Roupala brasiliensis</i> Klotz.	PROTEACEAE
<i>Sapium glandulosum</i> (L.) Morong	EUPHORBIACEAE
<i>Schinus terebinthifolia</i> Raddi	ANACARDIACEAE
<i>Sebastiania brasiliensis</i> Spreng.	EUPHORBIACEAE
<i>Sloanea lasiocoma</i> K. Schum.	ELAEOCARPACEAE
<i>Solanum erianthum</i> D. Don.	SOLANACEAE
<i>Solanum sanctae-catharinae</i> Dunal	SOLANACEAE
<i>Styrax leprosus</i> Hook. & Arn.	STYRACACEAE
<i>Syagrus romanzoffiana</i> (Cham.) Glassman	ARECACEAE
<i>Symplocos celastrinea</i> Mart.	SYMPLOCACEAE
<i>Trichilia elegans</i> A. Juss.	MELIACEAE
<i>Vernonanthura discolor</i> (Spreng.) H.Rob.	ASTERACEAE
<i>Vitex megapotamica</i> (Spreng.) Moldenke	LAMIACEAE

TABELA 10 – Composição florística da área de estudo.

(conclusão)

Espécie	Família
<i>Xylosma pseudosalzmannii</i> Sleumer	SALICACEAE
<i>Zanthoxylum kleinii</i> (R. S. Cowan) P.G. Waterman	RUTACEAE
<i>Zanthoxylum rhoifolium</i> Lam.	RUTACEAE
<i>Annona</i> sp.	ANNONACEAE
<i>Eugenia</i> sp.	MYRTACEAE
<i>Lonchocarpus</i> sp.	FABACEAE
<i>Machaerium</i> sp.	FABACEAE
<i>Myrcia</i> sp.	MYRTACEAE
<i>Nectandra</i> sp.	LAURACEAE
<i>Ocotea</i> sp.	LAURACEAE
<i>Persea</i> sp.	LAURACEAE
<i>Pouteria</i> sp.	SAPOTACEAE
<i>Rollinia</i> sp.	ANNONACEAE
<i>Solanum</i> sp.	SOLANACEAE
<i>Symplocos</i> sp.	SYMPLOCACEAE
Liana lenhosa	NI

FONTE: O autor (2023).

LEGENDA: NI = não identificada.

A diversidade indicada pelo índice de *Shannon* foi de 3,23, enquanto o índice de equabilidade de *Pielou* foi de 0,71. Em trabalho realizado por Dalla Lana (2013), na mesma área, foram encontrados índice de *Shannon* de 3,28 e 3,25 para os anos de 1995 e 2011 (respectivamente) e índice de *Pielou* de 0,77 para ambos os anos. Em um fragmento de FOM no município de Turvo, Paraná, Mazon et al. (2019) encontraram valores para o índice de *Shannon* e *Pielou* de 3,25 e 0,78, respectivamente. Ao comparar com a Floresta Ombrófila Densa de Terra Firme, no bioma Amazônia, percebe-se que esses índices apresentam valores maiores, *Shannon* de 4,43 e *Pielou* de 0,87, conforme Gama et al. (2022). Esses valores demonstram que a FOM tem menor diversidade que a fitofisionomia estudada por Gama et al. (2022). No entanto, a FOM possui maior diversidade ao se comparar com uma floresta de Caatinga no município de Serra do Mel, Rio Grande do Norte, que, de acordo com Souza et al. (2020), apresentou valores de 1,61 e 0,65 para *Shannon* e *Pielou*, respectivamente.

4.2.2 Estrutura horizontal da vegetação da área de estudo.

A espécie mais importante do fragmento foi *A. angustifolia*, com um valor de importância percentual (VIp) de 28,51% (Tabela 11). Juntamente com a segunda espécie mais importante, *N. grandiflora*, somam 39,51% de importância na área de estudo. As demais

espécies apresentaram VIp menor que 5%. Longhi (1980) também teve *A. angustifolia* como a espécie mais importante na ocasião de seu estudo (34,53%), cerca de 6% maior que o presente estudo. Dalla Lana (2013) obteve VIp para *A. angustifolia* de 28,9% (1995) e 28,1% (2011), valores mais próximos com os deste estudo. Apesar dessa espécie ser a mais característica da FOM, nem sempre será a mais representativa nos fragmentos estudados, em função de seu uso e exploração histórica. No estudo de Mazon et al. (2019), a espécie mais importante foi *O. porosa* com VIp de 9,3%, seguida de *A. angustifolia* com VIp de 6,5%.

TABELA 11 – Parâmetros fitossociológicos da área de estudo. (continua)

Espécie	N	AB	DA	DR	DoA	DoR	FA	FR	VIp
<i>Araucaria angustifolia</i>	507	69,75	144,86	20,21	19,93	50,45	67,14	14,87	28,51
<i>Nectandra grandiflora</i>	385	8,99	110,00	15,34	2,57	6,50	50,29	11,14	11,00
<i>Matayba elaeagnoides</i>	113	7,67	32,29	4,50	2,19	5,54	21,14	4,68	4,91
<i>Ilex paraguariensis</i>	163	3,37	46,57	6,50	0,96	2,44	24,29	5,38	4,77
<i>Blepharocalyx salicifolius</i>	140	2,13	40,00	5,58	0,61	1,54	24,00	5,32	4,15
NI	102	1,29	29,14	4,07	0,37	0,93	24,57	5,44	3,48
<i>Ocotea porosa</i>	29	8,89	8,29	1,16	2,54	6,43	7,14	1,58	3,06
<i>Cinnamomum amoenum</i>	86	2,30	24,57	3,43	0,66	1,67	15,43	3,42	2,84
<i>Campomanesia xanthocarpa</i>	63	2,90	18,00	2,51	0,83	2,10	13,14	2,91	2,51
<i>Prunus brasiliensis</i>	63	2,71	18,00	2,51	0,77	1,96	12,86	2,85	2,44
<i>Casearia decandra</i>	64	1,44	18,29	2,55	0,41	1,04	14,57	3,23	2,27
<i>Eugenia uniflora</i>	63	0,84	18,00	2,51	0,24	0,61	10,57	2,34	1,82
<i>Cinnamodendron dinisii</i>	42	2,31	12,00	1,67	0,66	1,67	8,57	1,90	1,75
<i>Ocotea puberula</i>	40	2,07	11,43	1,59	0,59	1,50	8,00	1,77	1,62
Morta	39	0,83	11,14	1,55	0,24	0,60	10,29	2,28	1,48
<i>Cedrela fissilis</i>	33	1,60	9,43	1,32	0,46	1,16	8,29	1,84	1,44
<i>Lithraea brasiliensis</i>	32	1,15	9,14	1,28	0,33	0,84	6,86	1,52	1,21
<i>Styrax leprosus</i>	32	1,22	9,14	1,28	0,35	0,88	6,57	1,46	1,20
<i>Cinnamomum sellowianum</i>	34	1,09	9,71	1,36	0,31	0,79	5,71	1,27	1,14
<i>Allophylus edulis</i>	29	0,53	8,29	1,16	0,15	0,38	7,71	1,71	1,08
<i>Myrceugenia euosma</i>	31	0,78	8,86	1,24	0,22	0,57	5,43	1,20	1,00
<i>Luehea divaricata</i>	16	1,88	4,57	0,64	0,54	1,36	4,29	0,95	0,98
<i>Clethra scabra</i>	27	0,65	7,71	1,08	0,19	0,47	4,86	1,08	0,87
<i>Cupania vernalis</i>	21	0,38	6,00	0,84	0,11	0,28	5,43	1,20	0,77
<i>Sapium glandulosum</i>	18	0,42	5,14	0,72	0,12	0,30	5,14	1,14	0,72
<i>Gymnanthes klotzschiana</i>	22	0,38	6,29	0,88	0,11	0,28	4,29	0,95	0,70
<i>Jacaranda puberula</i>	18	0,57	5,14	0,72	0,16	0,41	4,00	0,89	0,67
<i>Hovenia dulcis</i>	16	0,54	4,57	0,64	0,15	0,39	4,00	0,89	0,64
<i>Eugenia handroana</i>	22	0,37	6,29	0,88	0,11	0,27	3,43	0,76	0,64
<i>Syagrus romanzoffiana</i>	15	0,63	4,29	0,60	0,18	0,46	3,71	0,82	0,63
<i>Myrsine coriacea</i>	16	0,45	4,57	0,64	0,13	0,32	3,71	0,82	0,59
<i>Ilex theezans</i>	14	0,61	4,00	0,56	0,17	0,44	3,14	0,70	0,57
<i>Eugenia involucrata</i>	13	0,31	3,71	0,52	0,09	0,22	3,43	0,76	0,50

TABELA 11 – Parâmetros fitossociológicos da área de estudo.

(continuação)

Espécie	N	AB	DA	DR	DoA	DoR	FA	FR	VIp
<i>Zanthoxylum rhoifolium</i>	12	0,33	3,43	0,48	0,10	0,24	2,86	0,63	0,45
<i>Cryptocarya aschersoniana</i>	1	1,54	0,29	0,04	0,44	1,12	0,29	0,06	0,41
<i>Nectandra lanceolata</i>	11	0,48	3,14	0,44	0,14	0,35	1,71	0,38	0,39
<i>Moquiniastrium polymorphum</i>	10	0,22	2,86	0,40	0,06	0,16	2,29	0,51	0,35
<i>Ocotea sp.</i>	6	0,77	1,71	0,24	0,22	0,55	1,14	0,25	0,35
<i>Machaerium stipitatum</i>	8	0,17	2,29	0,32	0,05	0,12	2,29	0,51	0,32
<i>Sloanea lasiocoma</i>	8	0,12	2,29	0,32	0,03	0,08	2,29	0,51	0,30
<i>Vernonanthura discolor</i>	7	0,27	2,00	0,28	0,08	0,20	1,43	0,32	0,26
<i>Ilex brevicuspis</i>	9	0,13	2,57	0,36	0,04	0,09	1,43	0,32	0,26
<i>Myrcia splendens</i>	7	0,11	2,00	0,28	0,03	0,08	1,71	0,38	0,25
<i>Myrcia sp.</i>	6	0,13	1,71	0,24	0,04	0,09	1,71	0,38	0,24
<i>Nectandra megapotamica</i>	4	0,36	1,14	0,16	0,10	0,26	1,14	0,25	0,22
<i>Actinostemon concolor</i>	6	0,14	1,71	0,24	0,04	0,10	1,43	0,32	0,22
<i>Myrsine umbellata</i>	7	0,15	2,00	0,28	0,04	0,11	1,14	0,25	0,21
<i>Zanthoxylum kleinii</i>	5	0,09	1,43	0,20	0,03	0,07	1,43	0,32	0,19
<i>Ilex dumosa</i>	5	0,06	1,43	0,20	0,02	0,05	1,43	0,32	0,19
<i>Nectandra sp.</i>	4	0,19	1,14	0,16	0,05	0,14	1,14	0,25	0,18
<i>Aegiphila integrifolia</i>	5	0,09	1,43	0,20	0,03	0,07	1,14	0,25	0,17
<i>Piptocarpha angustifolia</i>	3	0,27	0,86	0,12	0,08	0,19	0,86	0,19	0,17
<i>Schinus terebinthifolia</i>	5	0,07	1,43	0,20	0,02	0,05	1,14	0,25	0,17
<i>Erythroxylum deciduum</i>	4	0,12	1,14	0,16	0,03	0,08	1,14	0,25	0,17
<i>Campomanesia guazumifolia</i>	4	0,09	1,14	0,16	0,03	0,07	1,14	0,25	0,16
<i>Casearia obliqua</i>	4	0,06	1,14	0,16	0,02	0,05	1,14	0,25	0,15
<i>Symplocos celastrinea</i>	4	0,11	1,14	0,16	0,03	0,08	0,86	0,19	0,14
<i>Sebastiania brasiliensis</i>	4	0,08	1,14	0,16	0,02	0,06	0,86	0,19	0,14
<i>Persea sp.</i>	3	0,06	0,86	0,12	0,02	0,04	0,86	0,19	0,12
<i>Machaerium sp.</i>	3	0,05	0,86	0,12	0,02	0,04	0,86	0,19	0,12
<i>Rollinia sp.</i>	3	0,05	0,86	0,12	0,01	0,04	0,86	0,19	0,11
<i>Solanum sp.</i>	3	0,04	0,86	0,12	0,01	0,03	0,86	0,19	0,11
<i>Monteverdia ilicifolia</i>	3	0,04	0,86	0,12	0,01	0,03	0,86	0,19	0,11
Liana lenhosa	3	0,04	0,86	0,12	0,01	0,03	0,86	0,19	0,11
<i>Lithraea molleoides</i>	3	0,04	0,86	0,12	0,01	0,03	0,57	0,13	0,09
<i>Vitex megapotamica</i>	2	0,09	0,57	0,08	0,02	0,06	0,57	0,13	0,09
<i>Piptocarpha axillaris</i>	2	0,08	0,57	0,08	0,02	0,06	0,57	0,13	0,09
<i>Xylosma pseudosalzmannii</i>	2	0,04	0,57	0,08	0,01	0,03	0,57	0,13	0,08
<i>Drimys brasiliensis</i>	2	0,04	0,57	0,08	0,01	0,03	0,57	0,13	0,08
<i>Casearia sylvestris</i>	2	0,02	0,57	0,08	0,01	0,01	0,57	0,13	0,07
<i>Lonchocarpus sp.</i>	2	0,07	0,57	0,08	0,02	0,05	0,29	0,06	0,06
<i>Ocotea diospyrifolia</i>	1	0,08	0,29	0,04	0,02	0,06	0,29	0,06	0,05
<i>Symplocos sp.</i>	1	0,07	0,29	0,04	0,02	0,05	0,29	0,06	0,05
<i>Ocotea corymbosa</i>	1	0,03	0,29	0,04	0,01	0,02	0,29	0,06	0,04
<i>Myrcia hatschbachii</i>	1	0,03	0,29	0,04	0,01	0,02	0,29	0,06	0,04
<i>Solanum sanctae-catharinae</i>	1	0,02	0,29	0,04	0,01	0,02	0,29	0,06	0,04
<i>Solanum erianthum</i>	1	0,02	0,29	0,04	0,01	0,01	0,29	0,06	0,04

TABELA 11 – Parâmetros fitossociológicos da área de estudo.

Espécie	N	AB	DA	DR	DoA	DoR	(conclusão)		
							FA	FR	VIp
<i>Randia armata</i>	1	0,02	0,29	0,04	0,00	0,01	0,29	0,06	0,04
<i>Myrcia guianensis</i>	1	0,01	0,29	0,04	0,00	0,01	0,29	0,06	0,04
<i>Dahlstedtia muehlbergiana</i>	1	0,01	0,29	0,04	0,00	0,01	0,29	0,06	0,04
<i>Citronella gongonha</i>	1	0,01	0,29	0,04	0,00	0,01	0,29	0,06	0,04
<i>Myrcia palustris</i>	1	0,01	0,29	0,04	0,00	0,01	0,29	0,06	0,04
<i>Trichilia elegans</i>	1	0,01	0,29	0,04	0,00	0,01	0,29	0,06	0,04
<i>Allophylus semidentatus</i>	1	0,01	0,29	0,04	0,00	0,01	0,29	0,06	0,04
<i>Roupala brasiliensis</i>	1	0,01	0,29	0,04	0,00	0,01	0,29	0,06	0,04
<i>Annona sp.</i>	1	0,01	0,29	0,04	0,00	0,01	0,29	0,06	0,04
<i>Eugenia chlorophylla</i>	1	0,01	0,29	0,04	0,00	0,01	0,29	0,06	0,04
<i>Pouteria sp.</i>	1	0,01	0,29	0,04	0,00	0,01	0,29	0,06	0,04
<i>Psidium myrtoides</i>	1	0,01	0,29	0,04	0,00	0,01	0,29	0,06	0,04
<i>Eugenia sp.</i>	1	0,01	0,29	0,04	0,00	0,01	0,29	0,06	0,04
	2509	138,25	716,94	100,08	39,48	100,05	451,52	99,97	100,04

FONTE: O autor (2023).

LEGENDA: N = número de indivíduos medidos, AB = área basal (m²), DA = densidade absoluta (indivíduos.ha⁻¹), DR = densidade relativa (%), DoA = dominância absoluta (m².ha⁻¹), DoR = dominância relativa (%), FA = frequência absoluta (indivíduos.parcela⁻¹), FR = frequência relativa (%), VIp = valor de importância percentual (%).

A densidade total foi de 716,86 indivíduos por hectare, valor que se situou entre as duas ocasiões estudadas por Dalla Lana (2013), 666 indivíduos por hectare (para o ano de 1995) e 781,7 indivíduos por hectare (para o ano de 2011). Lingner et al. (2007) encontraram 201 árvores por hectare em um fragmento de FOM no município de Caçador, Santa Catarina. No município de Nova Prata, Rio Grande do Sul, em um fragmento de FOM, Callegaro et al. (2015) encontraram 556,1 indivíduos em uma área de estágio avançado de regeneração. As cinco espécies mais importantes também foram as mais numerosas (1.308 indivíduos) e somaram 52,13% da densidade relativa. Destaque para *A. angustifolia* com 144,86 indivíduos por hectare, 20,1% do total de indivíduos e *N. grandiflora* com 110 indivíduos por hectare, ou seja, 115,34% do total de indivíduos da área em questão. Lingner et al. (2007) também encontraram uma maior densidade de *A. angustifolia*, representando 32,27% do total dos indivíduos, porém com uma densidade absoluta menor, 64,8 indivíduos por hectare.

A dominância total, que está relacionada à área basal, foi de 39,48 m².ha⁻¹. Valor próximo ao encontrado por Higuchi et al. (2012) de 36,42 m².ha⁻¹, em fragmento de FOM no município de Lages, Santa Catarina; e ao encontrado por Callegaro et al. (2015), 34,73 m².ha⁻¹. A espécie que mais se destacou foi *A. angustifolia* que apresentou mais da metade da dominância (50,45%), a qual aumentou 4,91% e 22,15% desde 1995 e 2011, respectivamente, considerando a pesquisa de Dalla Lana (2013) na mesma área de estudo. As 5 espécies com

maior dominância somaram 71,36%. Também se destacou a espécie *O. porosa*, que apesar de não estar entre as mais numerosas (apenas 29 indivíduos), apresentou a terceira maior dominância (6,43%), isto porque na parcela Imbuia foram encontrados dois indivíduos cujos diâmetros à altura do peito superaram os 160 cm.

4.3 CARACTERIZAÇÃO ESPECTRAL

Com o uso dos dados hiperespectrais obteve-se a curva média do comportamento espectral da araucária e do dossel da Floresta Ombrófila Mista na área de estudo. Além disso, identificaram-se as principais bandas espectrais que caracterizam e diferenciam a espécie Araucária presente no dossel, as quais podem ser utilizadas como referência para a utilização em índices de vegetação empregados para diferentes finalidades, principalmente no que tange ao seu reconhecimento. Nas Tabelas 12 e 13 podem ser observados os píxeis amostrados para a Araucária e a FOM, respectivamente.

TABELA 12 – Píxeis e píxeis *sunlit* amostrados para a espécie *Araucaria angustifolia*.

Parcela	N	Píxeis	Média	Lim.ρ	Sunlit	Média sunlit
Araucária	39	76.541	1.962,6	0,28	7.604	195
Fogo	38	51.676	1.359,9	0,26	7.974	209
Imbuia	13	45.320	3.486,1	0,26	9.360	720
Rio	28	53.803	1921,5	0,28	5.036	180
Total	118	227.340			29.974	

FONTE: O autor (2023).

LEGENDA: N = número de indivíduos amostrados, Lim.ρ = limiar de reflectância média da região do infravermelho próximo para a seleção dos píxeis *sunlit*.

TABELA 13 – Píxeis e píxeis *sunlit* amostrados para o dossel da Floresta Ombrófila Mista (exceto araucária).

Parcela	N	Píxeis	Média	Lim.ρ	Sunlit	Média sunlit
Araucária	60	102.074	1.701,2	0,27	13.560	226,0
Fogo	96	106.417	1.108,5	0,27	15.690	163,4
Imbuia	60	93.859	1.564,3	0,26	29.511	492,0
Rio	50	89.402	1.788,0	0,23	25.261	505,2
Total	266	391.752			84.022	

FONTE: O autor (2023).

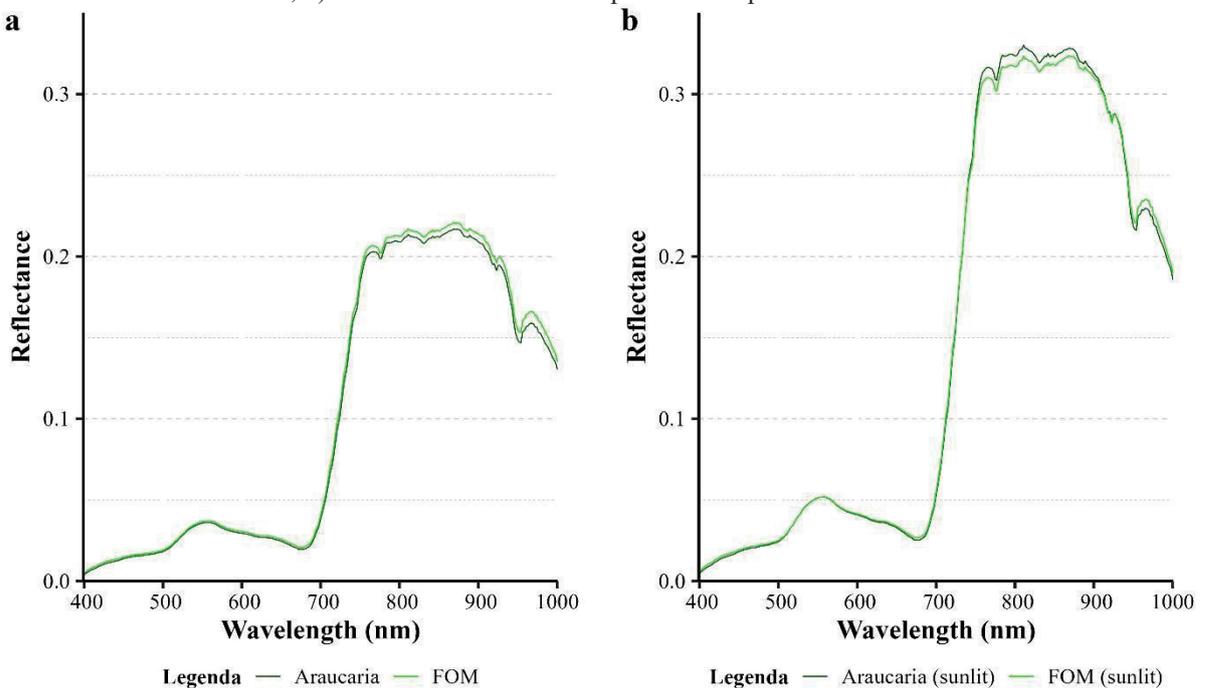
LEGENDA: N = número de indivíduos amostrados, Lim.ρ = limiar de reflectância média da região do infravermelho próximo para a seleção dos píxeis *sunlit*.

4.3.1 Comportamento espectral da Araucária

A Figura 19 demonstra que a espécie Araucária apresentou o comportamento espectral típico da vegetação sadia, com absorção da energia eletromagnética nas regiões do azul e vermelho, reflexão no verde e acentuada reflexão na região do infravermelho próximo. As

curvas apresentadas são dos valores de reflectância médios, considerando-se todos os píxeis e apenas os píxeis iluminados (*sunlit*). Na comparação com o dossel da FOM, percebeu-se que o comportamento espectral da Araucária se assemelhou com o comportamento do dossel da FOM (sem a Araucária), variando a quantidade de energia refletida na região do infravermelho próximo (750-1.000 nm). Notou-se também que nessa região houve uma inversão na posição das curvas com os píxeis *sunlit*, a Araucária passou a apresentar maior reflectância que o dossel da FOM.

FIGURA 19 – Comportamento espectral. a) Reflectâncias médias de todos os píxeis amostrados para a araucária e o dossel da FOM; b) Reflectâncias médias dos píxeis *sunlit* para a araucária e o dossel da FOM.



FONTE: O autor (2023).

Também é possível notar uma diminuição da reflectância em torno dos 950 nm em todas as curvas, o que é devido à absorção da energia eletromagnética pelo vapor de água presente na atmosfera. Os comprimentos de onda que caracterizaram a espécie Araucária podem ser vistos na Tabela 14.

TABELA 14 – Comprimentos de onda da espécie Araucária.

	Comprimentos de onda (nm)					
	B	G	R	RE	NIR	
Todos os píxeis	400	558	672	744	869	
Píxeis <i>sunlit</i>	400	558	677	744	811	

FONTE: O autor (2023).

LEGENDA: B = região do azul do espectro eletromagnético (EEM), G = região do verde do EEM, R = região do vermelho do EEM, RE = região da borda do vermelho do EEM, NIR = região do infravermelho próximo do EEM.

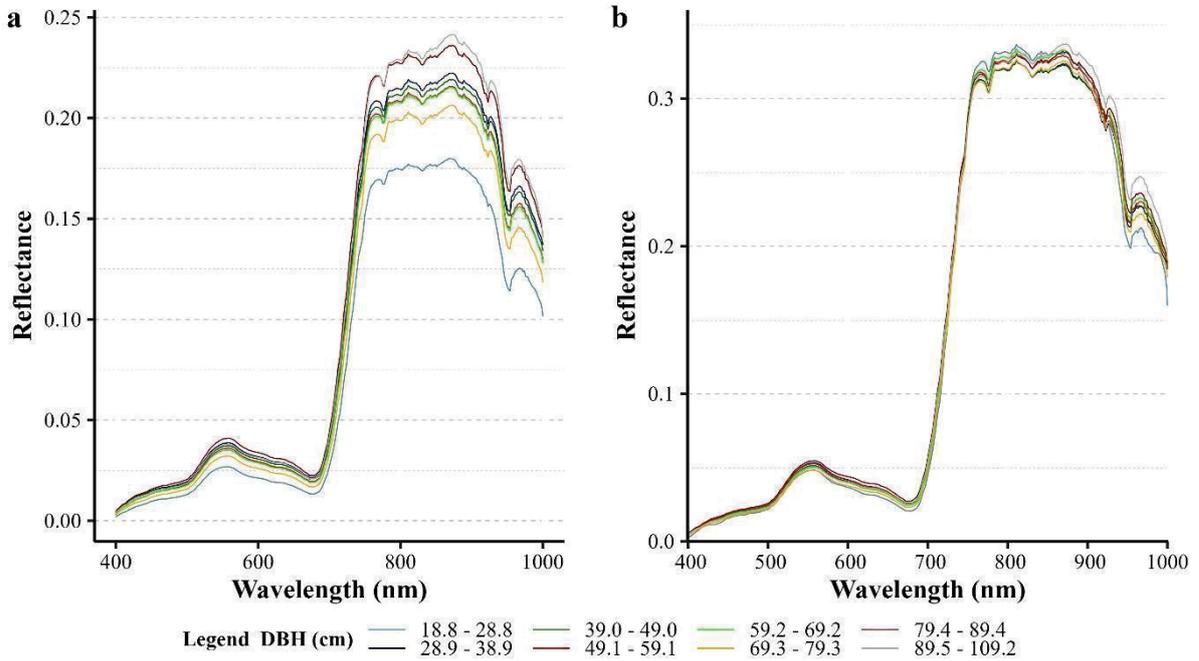
Esses comprimentos de onda poderão ser usados nos cálculos de índices de vegetação para a espécie Araucária, além de serem usados como referência na discriminação de outras espécies da FOM. Vangi et al. (2021) fizeram a discriminação de tipos de florestas usando sensor hiperespectral (PRISMA) e multiespectral (Sentinel-2) e constataram uma maior separabilidade entre espécies de coníferas e folhosas com os dados do sensor hiperespectral. Tipologia florestal que se assemelha com a FOM, por isso, dados de sensores hiperespectrais podem auxiliar na discriminação de espécies presentes nessa floresta.

Sothe et al. (2020) realizaram a discriminação de 16 espécies na Mata Atlântica, entre elas a Araucária, que apresentou a menor radiância na região do visível do EEM. Os autores também constataram que na região do infravermelho próximo foi onde se conseguiu fazer mais facilmente a discriminação das espécies estudadas. Assim, a partir dessas características, as bibliotecas espectrais desempenham um importante papel na interpretação acurada de imagens de sensoriamento remoto via um rápido reconhecimento de feições desconhecidas e melhorando a classificação e o nível de interpretação do sensoriamento remoto, além disso, reduz a influência da análise subjetiva do ser humano (MA et al., 2021).

4.3.2 Comportamento espectral da espécie Araucária em função das classes de DAP

Quanto às classes de DAP, ao se analisar todos os píxeis amostrados, as curvas médias das classes apresentaram comportamentos distintos, principalmente na região do infravermelho próximo (Figura 20a), com a menor classe de DAP apresentando a curva com menor reflectância e as duas maiores classes de DAP com curvas similares e maiores reflectâncias. Esse comportamento pode ser porque as árvores que estão nas maiores classes de diâmetro são, geralmente, as que possuem maior altura, recebendo, assim, maior quantidade de EEM e refletindo mais na região do NIR. Enquanto as árvores na menor classe de diâmetro, geralmente, possuem menor altura e acabam sendo sombreadas pelas outras árvores, ou seja, recebem menos EEM. Quando houve a seleção apenas dos píxeis iluminados (*sunlit*), as curvas médias de reflectância se apresentaram mais próximas umas das outras, sobrepostas na região da borda do vermelho e se diferenciando minimamente no infravermelho próximo (Figura 20b). Ou seja, ao remover os píxeis sombreados, as árvores de todas as classes de DAP passaram a apresentar comportamentos espectrais mais próximos.

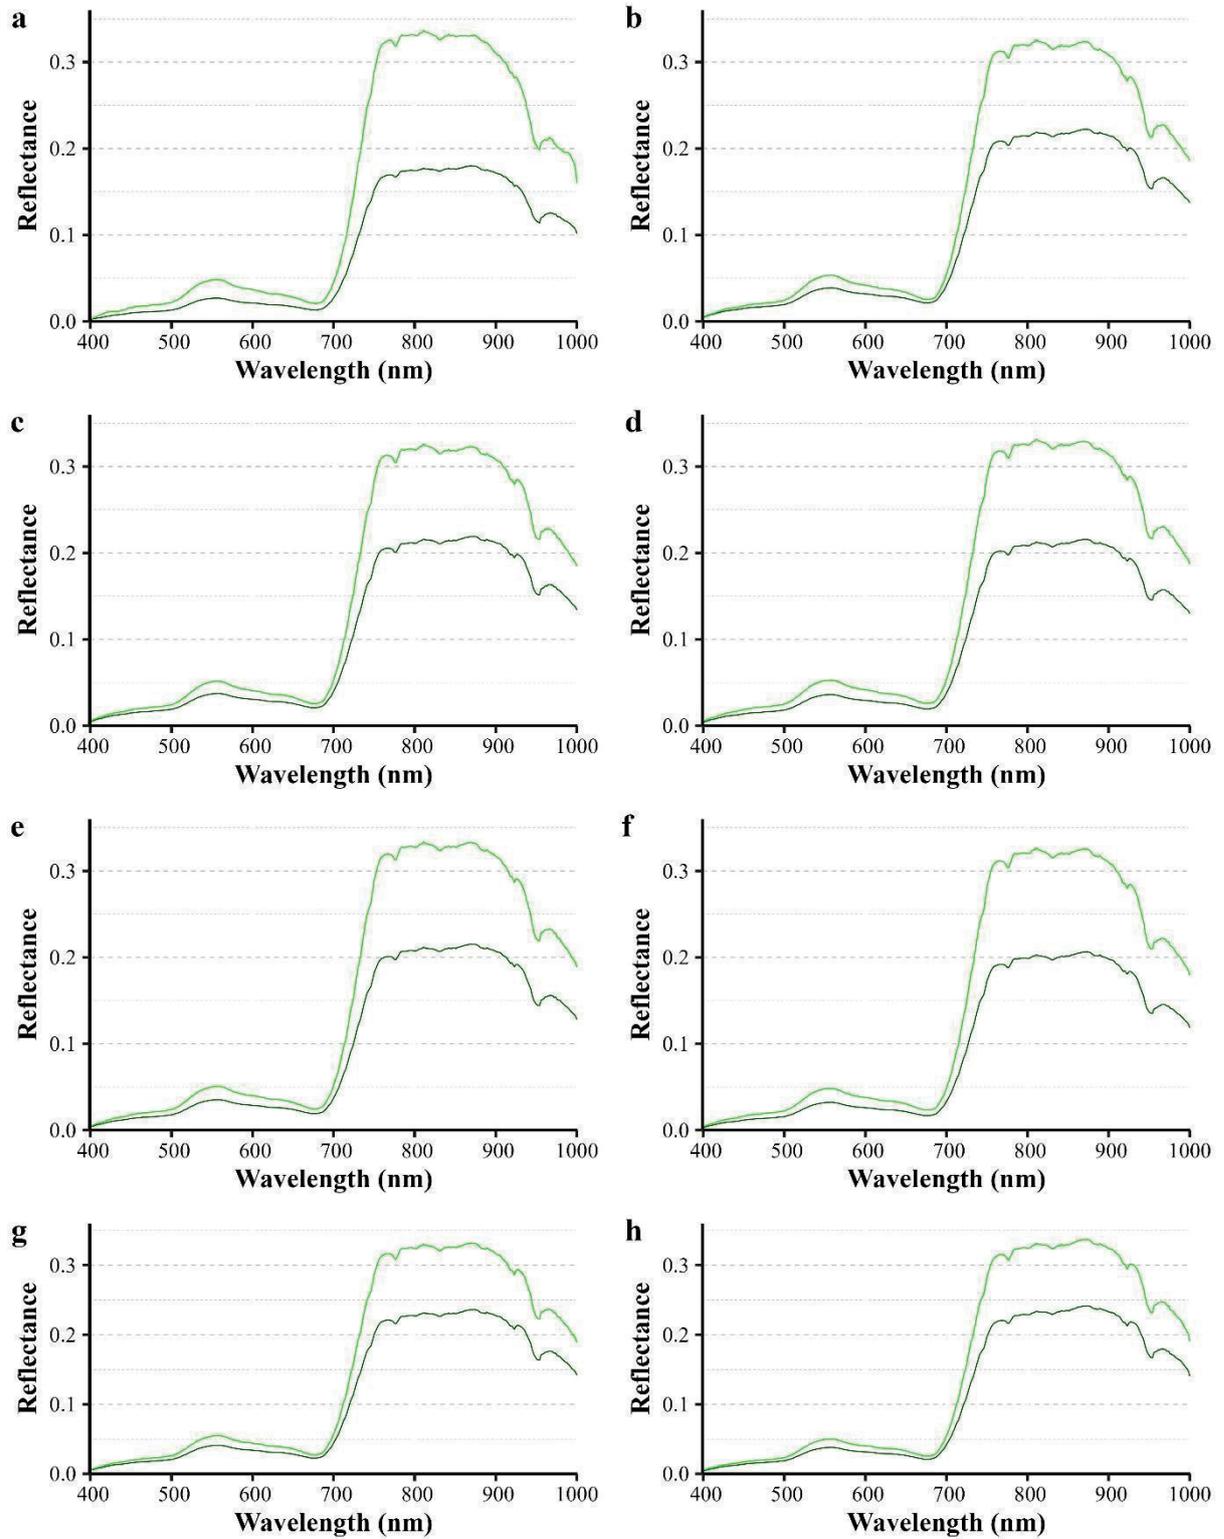
FIGURA 20 – Avaliação do comportamento espectral da espécie Araucária em função das classes de DAP. a) Reflectâncias médias da Araucária de todos os pixels amostrados por classe de DAP; b) reflectâncias médias da espécie Araucária apenas dos pixels iluminados (*sunlit*) por classe de DAP.



FONTE: O autor (2023).

Na Figura 21 pode-se observar detalhadamente o comportamento espectral por classe de diâmetro. É possível notar a diferença entre as curvas referentes a todos os pixels e apenas os pixels iluminados, em todas as classes. Esta diferença é mais evidente na região do NIR do que na região do visível (bandas R, G e B).

FIGURA 21 – Reflectâncias médias de todos os pixels amostrados e apenas dos pixels iluminados (*sunlit*) da Araucária por classes de diâmetros. a) Classe 1, 18,8 – 28,8 cm; b) Classe 2, 28,9 – 38,9 cm; c) Classe 3, 39,0 – 49,0 cm; d) Classe 4, 49,1 – 59,1 cm; e) Classe 5, 59,2 – 69,2 cm; f) Classe 6, 69,3 – 79,3 cm; g) Classe 7, 79,4 – 89,4 cm; h) Classe 8, 89,5 – 109,2 cm.



Legenda — All pixel — Sunlit pixel

FONTE: O autor (2023).

Os comprimentos de onda nas regiões do azul, verde e borda do vermelho se mantiveram os mesmos em todas as classes, tanto para todos os píxeis quanto para os píxeis iluminados (Tabela 15). Na região do vermelho, apenas a classe 1 apresentou comprimento de onda diferente das demais classes, considerando todos os píxeis. Já considerando apenas os píxeis iluminados, as classes 3 e 8 apresentaram comprimentos de onda diferentes na região do vermelho. Na região do infravermelho próximo, os comprimentos de onda apresentaram dois valores quando todos os píxeis foram analisados: 869 nm e 873 nm. Quando apenas os píxeis iluminados foram analisados, os comprimentos de onda permaneceram os mesmos da Classe 1 à Classe 6 (811 nm), apresentando valores distintos nas classes seguintes.

TABELA 15 – Comprimentos de onda da espécie Araucária para as classes de DAP.

Classe DAP (cm)	Comprimentos de onda (nm)									
	Todos os píxeis					Sunlit				
	B	G	R	RE	NIR	B	G	R	RE	NIR
1: 18,8 – 28,8	400	558	677	744	869	400	558	677	744	811
2: 28,9 – 38,9	400	558	672	744	873	400	558	677	744	811
3: 39,0 – 49,0	400	558	672	744	873	400	558	672	744	811
4: 49,1 – 59,1	400	558	672	744	869	400	558	677	744	811
5: 59,2 – 69,2	400	558	672	744	869	400	558	677	744	811
6: 69,3 – 79,3	400	558	672	744	873	400	558	677	744	811
7: 79,4 – 89,4	400	558	672	744	873	400	558	677	744	869
8: 89,5 -109,2	400	558	672	744	873	400	558	672	744	873

FONTE: O autor (2023).

LEGENDA: B = região do azul do espectro eletromagnético (EEM), G = região do verde do EEM, R = região do vermelho do EEM, RE = região da borda do vermelho do EEM, NIR = região do infravermelho próximo do EEM.

4.3.3 Avaliação do comportamento espectral por classe de DAP para a espécie Araucária

A ANOVA foi aplicada para testar se havia diferença significativa entre os comprimentos de onda para as diferentes classes de diâmetro da espécie araucária. Observou-se que não houve diferença entre as classes diamétricas (Tabela 16) uma vez que os F calculados foram todos menores que os F tabelados para 95% de significância. Assim, apesar de visualmente se observar uma pequena diferença entre as classes, estatisticamente elas não foram significativas a ponto de haver necessidade de se analisar o comportamento espectral da espécie Araucária em classes de diâmetros em separado.

TABELA 16 – ANOVA para as classes de diâmetro da espécie *Araucaria angustifolia*.

	Todos os píxeis					Sunlit				
	B	G	R	RE	NIR	B	G	R	RE	NIR
F_{tab}	1,434	1,422	1,382	1,432	1,462	0,821	0,851	0,797	0,835	0,866
F_{cal}	0,198	0,203	0,219	0,199	0,188	0,571	0,547	0,590	0,560	0,535

FONTE: O autor (2023).

LEGENDA: B = região do azul do espectro eletromagnético (EEM), G = região do verde do EEM, R = região do vermelho do EEM, RE = região da borda do vermelho do EEM, NIR = região do infravermelho próximo do EEM, Ftab = estatística F tabelada, Fcal = estatística F calculada.

4.4 MODELAGEM DA BIOMASSA AÉREA INDIVIDUAL PARA *A. ANGUSTIFOLIA*

Conforme a lacuna detectada na revisão bibliométrica, esse é o primeiro trabalho a usar algoritmos de aprendizado de máquina para realizar a predição da biomassa acima do solo para a espécie *Araucaria angustifolia*. Ao longo dos próximos resultados serão apresentadas as modelagens da AGB a partir de variáveis biofísicas obtidas em campo, de dados obtidos com o sensor LiDAR, de dados obtidos com sensor hiperespectral e, por fim, a modelagem com a integração dos dados de ambos os sensores, bem como uma síntese das modelagens realizadas.

4.4.1 Modelos testados para predição da biomassa aérea individual para *A. angustifolia*

As variáveis utilizadas para a predição da AGB com os modelos testados foram o DAP obtido no inventário florestal e a métrica “*Elev maximum*” obtida da nuvem do sensor LiDAR, a qual foi considerada a altura total (H) de cada árvore. Observou-se que não houve diferença nessa métrica quando extraída da nuvem com todos os pontos (As) e quando da nuvem contendo somente a Araucária (Aa). Um resumo estatístico dessas duas variáveis preditoras podem ser vistas na Tabela 17.

TABELA 17 – Resumo estatístico das variáveis preditoras DAP e H das árvores selecionadas para esse estudo.

Variável	N	Média	Sd	Mínimo	Máximo
DAP (cm)	118	54,78	14,98	18,80	109,20
H (m)	118	24,40	2,73	17,37	31,99

FONTES: O autor (2023).

LEGENDA: N = número de indivíduos, sd = desvio padrão.

Os resultados das modelagens apresentaram uma variação do R^2 de 0,8273 a 0,9572, e um R^2 médio de 0,9283. Os demais indicadores estatísticos variaram de 3,5954 a 46,8325 para o RMSE%, de 0,1733 a 203,1948 para o MAE e de 0,0059 a 16,037 para o Bias (%). O modelo com o melhor desempenho foi então selecionado conforme os 4 indicadores apresentados na Tabela 18.

TABELA 18 - Indicadores estatísticos da modelagem da biomassa acima do solo para *A. angustifolia*.

Mod	ML	Y	X	RMSE%	R ²	MAE	Bias%	RMSE% sd	R ² sd	MAE sd	Bias% sd
1	SVR	lnAGB	Imp.	3,5954	0,9572	0,1733	0,3885	1,4008	0,0673	0,0685	2,16
2	SVR	lnAGB	Todas	3,6898	0,9513	0,1784	0,3062	1,354	0,0765	0,0676	2,1107
3	RF	lnAGB	Todas	5,2812	0,9459	0,2459	-0,4268	3,2883	0,0761	0,1511	3,3646
4	RF	lnAGB	Imp.	5,3141	0,9422	0,2447	-0,4228	3,3071	0,0745	0,1518	3,2756
5	ENET	lnAGB	Imp.	6,2526	0,9135	0,2335	-0,0059	7,6195	0,1704	0,1867	3,4852
6	ENET	lnAGB	Todas	6,9378	0,9081	0,255	0,0327	8,64	0,158	0,2104	4,0609
7	SVR	sqrtAGB	Todas	12,2392	0,9371	1,8456	0,1259	5,0221	0,0935	0,974	7,2153
8	SVR	sqrtAGB	Imp.	10,8012	0,9418	1,5975	0,5157	5,3345	0,1074	0,8211	6,3549
9	ENET	sqrtAGB	Imp.	20,4229	0,9548	2,5607	2,8806	25,5592	0,0421	2,5992	11,7362
10	ENET	sqrtAGB	Todas	20,1901	0,953	2,6534	2,6515	17,8573	0,0425	1,9818	9,0505
11	RF	sqrtAGB	Imp.	18,0962	0,9403	2,8701	-2,9677	16,5548	0,0879	3,3986	12,8731
12	RF	sqrtAGB	Todas	18,5401	0,9372	2,9506	-3,0564	17,0279	0,0948	3,4686	13,2803
13	SVR	AGB	Imp.	36,2096	0,8571	121,6447	-2,6649	21,3851	0,2294	105,6421	23,826
14	ENET	AGB	Imp.	46,8325	0,954	159,9782	16,037	18,8235	0,0547	82,3618	19,4965
15	ENET	AGB	Todas	43,2706	0,9429	139,5751	12,7025	14,7733	0,0533	80,1237	17,3235
16	RF	AGB	Imp.	39,7471	0,9273	202,7386	-4,4012	35,119	0,1136	372,1602	28,1109
17	SVR	AGB	Todas	36,934	0,8273	121,0662	6,0262	20,3509	0,2682	107,9455	23,158
18	RF	AGB	Todas	40,0912	0,9189	203,1948	-3,6416	32,9288	0,1518	362,4878	27,7609

FONTE: O autor (2023).

LEGENDA: Mod. = modelo, ML = algoritmo de aprendizado de máquina, SVR = *Support Vector Regression*, RF = *Random Forest*, ENET = *Elastic net*, Y = variável resposta, X = variável preditora, RMSE% = raiz do erro médio quadrático percentual, R² = coeficiente de determinação, MAE = erro médio absoluto, Bias% = viés percentual, sd = desvio padrão, AGB = biomassa acima do solo, lnAGB = logaritmo neperiano da AGB, sqrtAGB, raiz quadrada da AGB, Imp. = variáveis mais importantes.

O modelo selecionado apresentou R² igual a 0,9572, valor superior aos encontrados por Zanette et al. (2021) que variaram entre 0,23 e 0,93 (R²_{aj} - coeficiente de determinação ajustado) em 6 áreas amostrais no estado do Paraná. Schumacher et al. (2011) ajustaram um modelo de biomassa para árvores de Araucárias e encontraram R²_{aj} similar a este estudo (0,965). Porém, aquele estudo se tratava de plantios florestais com idade de 27 anos, enquanto o povoamento deste estudo é inequiano. Conforme Gonçalves et al. (2004), a idade do povoamento é um dos fatores que mais influenciam na distribuição da biomassa da árvore, a qual está relacionada com os diferentes estágios nutricionais das árvores e suas características morfométricas. Russo et al. (1983) relacionaram a idade como um dos fatores que influenciam a biomassa e incluem, também, a variabilidade genética, a altitude, a umidade do solo e desbastes realizados. Ao aplicar o melhor modelo no conjunto de teste, esse apresentou um R² de 0,9425. Essa pequena diferença entre os valores do R² confere uma alta precisão do modelo.

Dos 3 algoritmos testados, o SVR foi o que demonstrou melhor desempenho com a utilização apenas das variáveis preditoras mais importantes, ou seja, aquelas que apresentaram importância maior ou igual a 90% (DAP, DAP⁻¹, ln(DAP²), ln(DAP), DAP², ln(DAP².H),

(DAP^2)⁻¹, ($DAP^2.H$)⁻¹, $DAP.H$, $DAP^2.H$). As demais variáveis preditoras tiveram importância menor que 1%. Quanto à variável resposta, a que apresentou melhor desempenho foi a que teve a transformação logarítmica ($\ln AGB$), a qual participou dos 6 modelos com os melhores desempenhos. Schumacher et al. (2011) também obtiveram um melhor desempenho quando a variável resposta teve transformação logarítmica. Já os 6 piores modelos foram os que utilizaram a variável resposta sem transformação.

A partir desse modelo foi possível prever a biomassa aérea individual das 118 árvores utilizadas no presente estudo. A biomassa aérea individual média foi de 1.954,32 kg.indivíduo⁻¹, com um desvio padrão de 1.160,29 kg.indivíduo⁻¹ e variou entre 66,56 kg.indivíduo⁻¹ a 6.000,12 kg.indivíduo⁻¹. Em um estudo realizado por Roik et al. (2020) na região centro-sul do Paraná foi encontrada uma biomassa acima do solo média por indivíduo de 2.126,5 kg.indivíduo⁻¹. O valor superior da média encontrada pelos autores pode ser devido ao diâmetro de inclusão utilizado, que foi $DAP \geq 40$ cm, assim, não considerando árvores menores que, por consequência, apresentariam menor biomassa aérea individual. Caldeira et al. (2015) encontraram uma média de 423,7 kg.indivíduo⁻¹, variando de 102,9 a 905,1 kg.indivíduo⁻¹, em povoamento com idades de 23 a 32 anos, com DAP de inclusão mínimo de 8 cm.

4.4.2 Modelagem da AGB a partir dos dados do sensor LiDAR

O processamento das nuvens de pontos do sensor LiDAR retornou 92 métricas. No entanto, duas métricas foram excluídas por apresentarem valores constantes para todas as árvores de araucária, *Int.P90* (intensidade no percentil 90) e *Int.P95* (Intensidade no percentil 95). Assim, não foi possível calcular a variância para essas duas variáveis, o que causava erro nos algoritmos usados.

Como descrito nos materiais e métodos, foram utilizadas duas nuvens de pontos para a extração das métricas da nuvem de pontos coletadas com LiDAR. Uma contendo todos os pontos do recorte da copa da árvore, isto é, pontos da copa, fuste e sub-bosque sob a copa (As), e outra onde os pontos do sub-bosque foram removidos, restando apenas os pontos da copa e fuste da árvore analisada (Aa). Comparando as nuvens As e Aa quanto ao R^2 , verificou-se que houve um incremento no valor da média, partindo de 0,5750 para 0,6093, respectivamente (Tabela 19). Os valores mínimo e máximo ficaram, respectivamente, em 0,4791 e 0,6654 (As) e 0,5236 e 0,7008 (Aa). Considerando os pares de nuvens As-Aa (modelos com o mesmo algoritmo, variável resposta e mesmo critério de seleção de variáveis preditoras), percebeu-se um acréscimo no R^2 nos modelos com SVR e RF, enquanto com ENET houve acréscimo apenas

nos modelos que utilizaram todas as variáveis preditoras. O modelo que apresentou o melhor desempenho foi com a nuvem Aa e, em relação ao seu análogo (As), o valor do R² aumentou de 0,6356 para 0,6614. Da mesma forma, o modelo com o maior R² (0,7008) aumentou em relação ao seu análogo As, que foi de 0,6654. No APÊNDICE 1 e APÊNDICE 2 é possível observar o correlograma, método de Pearson, entre a AGB e a nuvem de pontos As e Aa, respectivamente.

TABELA 19 – Métricas de ajuste dos modelos de biomassa com dados LiDAR.

Algoritmo	Y	X'	X''	RMSE%	R ²	MAE	Bias%	RMSE% sd	R ² sd	MAE sd	Bias% sd
SVR	lnAGB	Aa	Imp.	5,7356	0,6614	0,2928	0,1238	2,9113	0,1955	0,1099	2,1113
SVR	lnAGB	As	Imp.	6,0993	0,6356	0,3186	-0,0468	2,6398	0,1987	0,1055	2,289
SVR	lnAGB	Aa	Todas	6,1346	0,6263	0,3257	0,4197	3,1983	0,2088	0,1287	2,2078
RF	lnAGB	As	Imp.	6,7774	0,5389	0,3535	0,0008	2,6867	0,2404	0,1235	2,5781
RF	lnAGB	Aa	Todas	6,6574	0,5542	0,3627	-0,2926	3,1291	0,2215	0,1289	2,4553
RF	lnAGB	Aa	Imp.	6,6855	0,5636	0,3551	-0,3044	3,2505	0,2352	0,1256	2,6193
ENET	lnAGB	As	Imp.	6,9587	0,5536	0,3775	0,0124	2,8108	0,1661	0,1017	2,3541
ENET	lnAGB	Aa	Todas	6,8245	0,5332	0,3616	0,0792	2,9475	0,2195	0,1145	1,9933
ENET	sqrtAGB	As	Imp.	19,5666	0,6302	6,2181	0,0603	5,9953	0,1944	1,7463	6,9125
ENET	lnAGB	As	Todas	7,048	0,4791	0,3792	0,0057	2,841	0,205	0,1072	1,9503
SVR	sqrtAGB	Aa	Imp.	17,0481	0,7008	5,3938	-1,0112	6,0596	0,1827	1,6654	5,9764
RF	lnAGB	As	Todas	6,7768	0,535	0,369	-0,2941	3,0239	0,218	0,1224	2,5266
SVR	lnAGB	As	Todas	6,6724	0,5368	0,3647	0,4423	3,1044	0,2065	0,1214	2,3315
ENET	sqrtAGB	Aa	Todas	18,9723	0,6297	6,0943	0,4083	6,1939	0,2435	1,7795	5,7494
SVR	sqrtAGB	Aa	Todas	18,2146	0,6774	6,0297	-1,1629	6,0435	0,1931	1,757	6,538
ENET	lnAGB	Aa	Imp.	8,3731	0,5236	0,4654	0,1218	2,8706	0,1892	0,0973	2,1625
SVR	sqrtAGB	As	Imp.	18,3417	0,6654	5,8219	-1,5963	5,9974	0,1962	1,7796	6,7653
ENET	sqrtAGB	As	Todas	19,9403	0,5879	6,3163	0,237	5,932	0,2262	1,6374	5,008
RF	sqrtAGB	As	Imp.	21,016	0,5608	6,775	0,0303	6,4309	0,2247	1,9778	7,6369
RF	sqrtAGB	Aa	Imp.	19,5823	0,6235	6,2855	-0,548	6,5173	0,2016	1,7652	7,2087
SVR	sqrtAGB	As	Todas	19,813	0,6004	6,8208	-0,3475	5,6471	0,1889	1,6358	6,5799
RF	sqrtAGB	Aa	Todas	20,2904	0,6049	6,7753	-0,8053	6,3028	0,1955	1,7599	6,9359
RF	sqrtAGB	As	Todas	20,6652	0,5766	6,9329	-0,6801	5,9906	0,1921	1,7936	6,871
ENET	sqrtAGB	Aa	Imp.	24,9292	0,6131	8,2372	0,6973	5,1333	0,1937	1,3711	5,7183

FONTE: O autor.

LEGENDA: SVR = *Support Vector Regression*, RF = *Random Forest*, ENET = *Elastic net*, Y = variável resposta, X' = variável preditora quanto à natureza dos dados, X'' = critério de seleção de variáveis preditoras, RMSE% = raiz do erro médio quadrático percentual, R² = coeficiente de determinação, MAE = erro médio absoluto, Bias% = viés percentual, sd = desvio padrão, lnAGB = logaritmo neperiano da AGB, sqrtAGB, raiz quadrada da AGB, Aa = nuvem com somente os pontos da árvore de Araucária, As = nuvem com pontos da árvore de Araucária e o sub-bosque sob ela, Imp. = variáveis mais importantes.

O modelo com o melhor desempenho foi o obtido com o algoritmo SVR, variável resposta com transformação logarítmica (*lnAGB*) e variáveis preditoras mais importantes (*'Return 2 count above 1.30'*, *'crown_area_m2'*, *'Total return count'*, *'Total all returns'*, *'All returns above 1.30'*, *'Total return count above 1.30'*, *'All returns above mean'*, *'First returns above mean'*), reduzindo, assim, a quantidade de variáveis de 90 para 8. A nuvem de pontos

utilizada foi a que apresentou apenas os pontos das árvores de Araucária (Aa). Contudo, o R^2 de 0,6614 não foi o maior valor encontrado nos ajustes. O maior R^2 foi de 0,7008, também com SVR e as mesmas variáveis preditoras, diferenciando-se apenas na variável resposta que utilizou a transformação raiz quadrada (*sqr*AGB). Já o menor R^2 foi de 0,4791, oriundo do ajuste com ENET, transformação logarítmica e utilizando todas as variáveis obtidas com a nuvem de pontos composta pelos pontos das Araucárias e o sub-bosque sob ela. O RMSE% variou de 6,0993 a 21,016, o MAE ficou entre 0,3186 e 6,9329 e o Bias% entre -1,5963 e 0,4423 para a nuvem As, enquanto que para a nuvem Aa, o RMSE% variou de 5,7356 % a 24,9292 %, o MAE ficou entre 0,2928 e 8,2372 e o Bias% entre -1,1629 % e 0,6973 %.

Rex et al. (2019) estimaram a biomassa a partir da área de copa das árvores de Araucária utilizando dados LiDAR. Naquele estudo, os autores obtiveram bons resultados a partir de dois modelos, os quais apresentaram coeficientes de determinação iguais a 0,96 e 0,98 e um RMSE% de 0,03 % e 1,01 %, respectivamente. Cujos valores foram superiores aos obtidos no presente trabalho.

Considerando outras espécies de coníferas, também foi possível encontrar trabalhos que relacionaram a biomassa aérea individual com dados oriundos de sensores LiDAR. Tojal et al. (2019) desenvolveram um modelo linear de regressão para prever a biomassa acima do solo de *Pinus radiata* a partir de dados LiDAR, na região norte da Espanha. Os autores encontraram um coeficiente de determinação ajustado igual a 0,79, valor superior ao encontrado por esse trabalho. O trabalho desenvolvido por Cerrillo et al. (2018) com *Pinus halepensis*, esse na região sul da Espanha, obteve modelos com coeficientes de determinação que variaram de 0,35 a 0,82, sendo o RF um dos algoritmos utilizados, o qual apresentou R^2 de 0,71 e RMSE% de 40,36 %. Gao e Zhang (2021) investigaram diferentes espécies em uma fazenda de floresta plantada na China. Os autores encontraram para *Cunninghamia lanceolata*, *Pinus* sp., *Eucalyptus* sp. e outras espécies folhosas coeficientes de determinação de 0,19, 0,76, 0,71 e 0,40, respectivamente. Hansen et al. (2015) encontraram um R^2 que variou de 0,48 a 0,71 em 6 modelos, com um RMSE% médio de 33 % em uma floresta tropical na Tanzânia. Os autores avaliaram variáveis derivadas do modelo de superfície do dossel e constataram que variáveis das partes mais baixas do dossel e variáveis de densidade do dossel explicaram mais a densidade da AGB que variáveis representando a altura do dossel.

4.4.3 Modelagem da AGB a partir dos dados hiperespectrais

Como descrito nos materiais e métodos, foram utilizadas duas formas de obtenção dos valores das reflectâncias das bandas espectrais. Uma contendo todos os pixels do recorte da copa da árvore (pL), e a outra em que apenas os pixels iluminados, *sunlit*, foram utilizados (sL). Comparando as duas formas de obtenção das reflectâncias dos pixels, pL e sL, quanto ao R², verificou-se que houve um decréscimo no valor da média, partindo de 0,2111 para 0,1963, respectivamente (Tabela 20). Os valores mínimo e máximo ficaram, respectivamente, em 0,0878 e 0,3937 (pL) e em 0,0797 e 0,2953 (sL). Considerando os pares análogos de modelos, quanto a obtenção das reflectância (pL-sL), isto é, modelos com o mesmo algoritmo, variável resposta e mesmo critério de seleção de variáveis predictoras, percebeu-se um decréscimo no R² nos modelos com ENET, enquanto que com SVR e RF houve decréscimo em apenas um dos pares de modelos análogos. O modelo que apresentou o melhor desempenho foi com pL e, em relação ao seu análogo (sL), o valor do R² diminuiu de 0,3402 para 0,2329. Da mesma forma, o modelo com o maior R² (0,3937) diminuiu em relação ao seu análogo sL, que foi de 0,2933. No APÊNDICE 3 e APÊNDICE 4 é possível observar correlograma, com método de Pearson, entre a AGB e as bandas espectrais do sensor hiperespectral com as reflectâncias obtidas de todos os pixels (pL) e apenas dos pixels iluminados (sL), respectivamente.

TABELA 20 – Indicadores de ajuste dos modelos de biomassa acima do solo através de dados hiperespectrais.
(continua)

Algoritmo	Y	X'	X''	RMSE%	R ²	MAE	Bias%	RMSE% sd	R ² sd	MAE sd	Bias% sd
ENET	lnAGB	pL	Todas	8,4562	0,3402	0,4763	-0,1213	3,2964	0,2357	0,137	2,7141
ENET	lnAGB	pL	Imp.	8,557	0,2253	0,4686	0,0073	3,0211	0,2015	0,1228	2,4589
SVR	lnAGB	sL	Todas	8,5165	0,2797	0,4606	1,3701	3,3288	0,2409	0,1191	2,1305
ENET	sqrtAGB	pL	Todas	25,6165	0,3937	8,7287	-0,2005	7,3577	0,2674	2,1858	7,3365
ENET	lnAGB	sL	Imp.	9,1798	0,1204	0,5171	0,0519	2,95	0,1542	0,116	1,9804
ENET	lnAGB	sL	Todas	9,3082	0,2329	0,5217	0,3987	3,4146	0,2175	0,1305	2,4707
SVR	lnAGB	pL	Todas	8,6584	0,2537	0,4698	1,8188	3,4993	0,2162	0,133	2,2165
SVR	lnAGB	sL	Imp.	8,8207	0,2075	0,4927	1,3686	2,0394	0,2345	0,1005	1,6613
RF	lnAGB	sL	Todas	9,398	0,1563	0,5365	-0,3795	2,9908	0,1799	0,129	2,3107
RF	lnAGB	pL	Todas	9,9388	0,1282	0,5672	0,175	3,1215	0,1768	0,1444	2,624
SVR	sqrtAGB	sL	Todas	27,1233	0,2953	9,0516	0,5093	6,7073	0,23	1,8317	6,5318
SVR	lnAGB	pL	Imp.	8,8283	0,1899	0,4802	1,5259	3,0649	0,16	0,1247	2,1578
RF	lnAGB	pL	Imp.	9,9187	0,1037	0,5636	0,2661	3,0197	0,1507	0,1423	2,7367
SVR	sqrtAGB	pL	Todas	27,396	0,3044	9,1147	1,3736	7,7173	0,2465	2,2093	7,579
ENET	sqrtAGB	pL	Imp.	28,4183	0,2677	9,2921	0,5439	7,1636	0,2105	2,1805	8,013
RF	sqrtAGB	sL	Imp.	27,6639	0,2476	9,6904	-0,444	5,3773	0,1956	1,7404	6,683
ENET	sqrtAGB	sL	Todas	28,8154	0,2933	9,674	0,7383	7,448	0,2426	2,057	7,0784
RF	lnAGB	sL	Imp.	10,4097	0,0797	0,6115	0,7666	3,2938	0,0979	0,1428	2,8778
RF	sqrtAGB	sL	Todas	30,0806	0,1392	10,201	-0,2776	6,2723	0,1999	2,0191	5,7592
ENET	sqrtAGB	sL	Imp.	30,0936	0,0996	9,9686	0,2993	6,139	0,1335	1,8258	5,2685
SVR	sqrtAGB	sL	Imp.	29,1363	0,2045	9,8158	1,806	5,0405	0,1848	1,5699	5,4872

TABELA 20 – Indicadores de ajuste dos modelos de biomassa acima do solo através de dados hiperespectrais.

(conclusão)											
Algoritmo	Y	X'	X''	RMSE%	R ²	MAE	Bias%	RMSE% sd	R ² sd	MAE sd	Bias% sd
RF	sqrtAGB	pL	Todas	32,6097	0,1214	10,9803	1,312	6,9027	0,1422	2,2342	7,6702
SVR	sqrtAGB	pL	Imp.	30,0498	0,1175	10,0332	1,4501	6,6679	0,1246	1,9858	5,2521
RF	sqrtAGB	pL	Imp.	33,4119	0,0878	11,2509	1,6088	6,9416	0,115	2,3889	8,6225

FONTE: O autor (2023).

LEGENDA: SVR = *Support Vector Regression*, RF = *Random Forest*, ENET = *Elastic net*, Y = variável resposta, X' = variável preditora quanto à natureza dos dados, X'' = variável preditora quanto à importância, RMSE% = raiz do erro médio quadrático percentual, R² = coeficiente de determinação, MAE = erro médio absoluto, Bias% = viés percentual, sd = desvio padrão, lnAGB = logaritmo neperiano da AGB, sqrtAGB, raiz quadrada da AGB, pL = bandas com as reflectâncias de todos os pixels, sL = bandas com as reflectâncias dos pixels iluminados (*sunlit*), Imp. = variáveis mais importantes.

O modelo com o melhor desempenho foi o obtido com o algoritmo ENET, variável resposta com transformação logarítmica (*lnAGB*) e com todas as variáveis predictoras, isto é, as 270 bandas espectrais. As reflectâncias utilizadas foram as obtidas a partir de todos os píxeis (pL). Contudo, o R² de 0,3402 não foi o maior valor encontrado nos ajustes. O maior R² foi de 0,3937, também com ENET e as mesmas variáveis predictoras, diferenciando-se apenas na variável resposta que utilizou a transformação raiz quadrada (*sqrtAGB*). Já o menor R² foi de 0,0797, oriundo do ajuste com RF, transformação logarítmica e utilizando as variáveis mais importantes e as reflectâncias obtidas apenas dos píxeis iluminados (*sunlit*). O RMSE% variou de 8,4562 % a 33,4119 %, o MAE ficou entre 0,4686 e 11,2509 e o Bias% entre -0,2005 % e 1,8188 % para o pL, enquanto que para o sL o RMSE% variou de 8,5165 a 30,0936, o MAE ficou entre 0,4606 e 10,201 e o Bias% entre -0,444 % e 1,806 %.

Laurin et al. (2014) também encontraram um ajuste fraco para a biomassa predita a partir de bandas hiperespectrais, obtendo um R² de 0,36 em uma floresta mista em Serra Leoa, África. Foody et al. (2003) usaram dados do sensor TM (multiespectral) dos satélites Landsat 4 e 5 para prever a biomassa acima do solo em três países diferentes, Brasil, Malásia e Tailândia. A partir da aplicação de análise de regressão, os autores obtiveram um R² inferior a 0,32. O trabalho realizado por Jacon et al. (2021) nas fisionomias de savana no cerrado do Brasil, apresentou valores do RMSE% variando entre 24,85 % e 35,04 %, apesar disso, quando comparado aos sensores multiespectrais, os hiperespectrais produzem um grande conjunto de métricas para a abordagem de aprendizado de máquina, o que pode reduzir as incertezas na modelagem de dados.

4.4.4 Integração dos dados LiDAR e hiperespectrais para prever a AGB

A integração dos dados hiperespectrais aos dados LiDAR se estabeleceu partindo da hipótese que os modelos poderiam ter um maior desempenho, baseando-se no aumento do valor do indicador estatístico R^2 . Por serem sensores de diferentes naturezas, os dados obtidos por eles apresentam diferentes características da vegetação. Enquanto que o LiDAR nos traz características físicas e estruturais da árvore, o hiperespectral nos traz características bioquímicas e fisiológicas. Assim, esse é o primeiro trabalho a realizar essa integração para a modelagem da biomassa acima do solo para a espécie *Araucaria angustifolia*.

A primeira integração entre esses dois dados foi com as 270 bandas espectrais, cujas reflectâncias foram obtidas a partir de todos os pixels (pL), às duas nuvens de pontos LiDAR (As e Aa). Dessa forma, criaram-se dois conjuntos de dados: um com pL adicionado à nuvem contendo a árvore de Araucaria com o sub-bosque (pLAs) e outro com a nuvem de pontos contendo apenas a Araucaria (pLAa).

Analizou-se os pares análogos de modelos As-pLAs, cujos modelos possuem o mesmo algoritmo, variável resposta e mesmo critério de seleção de variáveis preditoras (Tabela 21). No algoritmo ENET percebeu-se um aumento no R^2 quando utilizadas todas as variáveis preditoras e variável resposta com transformação logarítmica, e quando utilizadas apenas as variáveis mais importantes e variável resposta com transformação raiz quadrada. Já no RF, houve aumento no R^2 apenas quando foram utilizadas as variáveis preditoras mais importantes e variável resposta com transformação raiz quadrada. No SVR houve decréscimo em todas as combinações. Nos pares de modelos Aa-pLAa, o ENET teve um aumento no R^2 em todas as combinações de variáveis. O RF teve aumento no R^2 quando foram utilizadas apenas as variáveis preditoras mais importantes, enquanto que o SVR apresentou decréscimo no R^2 em todas as combinações de variáveis.

TABELA 21 – Comparativo entre a modelagem da biomassa com apenas nuvens de pontos LiDAR e as nuvens integradas com dados hiperespectrais utilizando todos os pixels.

Algoritmo	Y	Variaveis	R ² As	R ² pLAs	R ² Aa	R ² pLAa
ENET	lnAGB	Todas	0,4791	0,4808	0,5332	0,5372
ENET	lnAGB	Imp.	0,5536	0,5399	0,5236	0,5305
ENET	sqrtAGB	Todas	0,5879	0,5628	0,6297	0,6423
ENET	sqrtAGB	Imp.	0,6302	0,6313	0,6131	0,6219
RF	lnAGB	Todas	0,535	0,5175	0,5542	0,5446
RF	lnAGB	Imp.	0,5389	0,5358	0,5636	0,5646
RF	sqrtAGB	Todas	0,5766	0,5582	0,6049	0,5802
RF	sqrtAGB	Imp.	0,5608	0,5654	0,6235	0,6311
SVR	lnAGB	Todas	0,5368	0,5053	0,6263	0,6105
SVR	lnAGB	Imp.	0,6356	0,6034	0,6614	0,661
SVR	sqrtAGB	Todas	0,6004	0,5839	0,6774	0,6638
SVR	sqrtAGB	Imp.	0,6654	0,6487	0,7008	0,6964

FONTE: O autor (2023).

LEGENDA: Y = variável resposta, R^2 = coeficiente de determinação, As = nuvem com pontos da árvore de Araucária e o sub-bosque sob ela, pLAs = integração das bandas com as reflectâncias de todos os pixels e a nuvem com pontos da árvore de Araucária e o sub-bosque sob ela, Aa = nuvem com somente os pontos da árvore de Araucária, pLAa = integração das bandas com as reflectâncias de todos os pixels e a nuvem com somente os pontos da árvore de Araucária, $\ln AGB$ = logaritmo neperiano da AGB, \sqrt{AGB} , raiz quadrada da AGB, Imp. = variáveis mais importantes.

A nuvem de pontos As combinada com pL apresentou um decréscimo no valor da média do R^2 , partindo de 0,5750 para 0,5611. Os valores mínimos e máximos ficaram, respectivamente, em 0,4791 e 0,6654 (As) e em 0,4808 e 0,6487 (pLAs). Já a nuvem Aa combinada com pL apresentou valor da média do R^2 próximo da nuvem Aa, 0,6070 e 0,6093, respectivamente. Os valores mínimo e máximo ficaram, respectivamente, em 0,5236 e 0,7008 (Aa) e em 0,5305 e 0,6964 (pLAa).

O modelo com o melhor desempenho, em que foram integradas as reflectâncias de todos os pixels (pL), foi o obtido com o algoritmo SVR (Tabela 22), variável resposta com transformação logarítmica ($\ln AGB$) e variáveis preditoras mais importantes (*'Return 2 count above 1.30', 'crown_area_m2', 'Total return count', 'Total all returns', 'All returns above 1.30', 'Total return count above 1.30', 'All returns above mean', 'First returns above mean', "404", "406", "408", "410", "413", "417", "419", "771", "773", "775", "777", "780", "782", "784", "786", "788", "865", "867", "869", "871", "873", "876", "878", "880", "882", "885", "956", "959"*). A nuvem de pontos utilizada foi a que apresentou apenas os pontos das árvores de Araucária combinada com pL (pLAa). Contudo, o R^2 de 0,661 do melhor modelo não foi o maior valor encontrado nos ajustes. O maior R^2 foi de 0,6964, também com SVR e as mesmas variáveis preditoras, diferenciando-se apenas na variável resposta que utilizou a transformação raiz quadrada (\sqrt{AGB}). Já o menor R^2 foi de 0,4808, oriundo do ajuste com ENET, transformação logarítmica e utilizando todas as variáveis obtidas com a nuvem de pontos composta pelos pontos das Araucárias e o sub-bosque sob ela. O RMSE% variou de 6,2975 % a 21,5176 %, o MAE ficou entre 0,3355 e 7,2724 e o Bias% entre -1,0074 % e 0,6691 % para a integração pLAs. Já para a integração pLAa, o RMSE% variou de 5,7969 a 21,6437, o MAE ficou entre 0,3056 e 6,9476 e o Bias% entre -0,9356 e 0,8476.

TABELA 22 – Métricas de ajuste dos modelos de biomassa com a integração dos dados LiDAR com os dados hiperspectrais utilizando todos os pixels.

Algoritmo	Y	X'	X''	RMSE %	R ²	MAE	Bias %	RMSE% sd	R ² sd	MAE sd	Bias% sd
SVR	lnAGB	pLAa	Imp.	5,7969	0,661	0,3056	0,4462	2,8962	0,1808	0,108	2,0912
ENET	lnAGB	pLAa	Todas	6,7868	0,5372	0,3576	0,0568	2,9265	0,2197	0,1144	1,9716
RF	lnAGB	pLAa	Imp.	6,6795	0,5646	0,3596	-0,2019	2,8236	0,21	0,1115	2,5464
SVR	lnAGB	pLAa	Todas	6,2481	0,6105	0,3349	0,6318	3,0561	0,1961	0,1246	2,2145
SVR	lnAGB	pLAs	Imp.	6,2975	0,6034	0,3355	0,5489	2,8315	0,188	0,1044	2,198
ENET	lnAGB	pLAs	Imp.	6,9604	0,5399	0,3798	-0,0159	2,7855	0,1834	0,1101	2,4772
RF	lnAGB	pLAs	Imp.	6,8257	0,5358	0,3779	-0,0771	2,5448	0,2385	0,1091	2,5424
RF	lnAGB	pLAa	Todas	6,788	0,5446	0,3719	-0,2829	3,0804	0,218	0,1224	2,4236
ENET	lnAGB	pLAs	Todas	7,0384	0,4808	0,3729	-0,0079	2,8575	0,2033	0,1058	1,8763
ENET	sqrtAGB	pLAa	Todas	18,6205	0,6423	5,8474	0,1638	6,1995	0,2479	1,786	5,8538
SVR	sqrtAGB	pLAa	Todas	18,4202	0,6638	6,2006	-0,3406	5,6162	0,1776	1,6621	6,4708
ENET	sqrtAGB	pLAs	Imp.	19,7785	0,6313	6,3758	0,1589	5,6203	0,1865	1,564	6,4082
SVR	sqrtAGB	pLAa	Imp.	17,2657	0,6964	5,6377	-0,9356	5,6636	0,1718	1,4919	5,9269
RF	lnAGB	pLAs	Todas	6,969	0,5175	0,388	-0,2415	3,0534	0,232	0,1189	2,4781
ENET	lnAGB	pLAa	Imp.	7,3848	0,5305	0,3944	0,219	3,4164	0,1926	0,144	2,9085
RF	sqrtAGB	pLAa	Imp.	19,3317	0,6311	6,3241	-0,392	6,2044	0,1887	1,7135	6,8613
ENET	sqrtAGB	pLAs	Todas	20,3993	0,5628	6,6184	0,127	5,7711	0,2284	1,637	5,6279
SVR	sqrtAGB	pLAs	Imp.	18,5942	0,6487	6,1517	-1,0074	5,7933	0,1982	1,6098	6,1814
SVR	lnAGB	pLAs	Todas	6,9165	0,5053	0,3793	0,6531	3,0834	0,2034	0,1221	2,421
RF	sqrtAGB	pLAs	Imp.	20,8006	0,5654	7,0728	0,1547	5,6719	0,2237	1,7586	7,3035
RF	sqrtAGB	pLAa	Todas	20,9305	0,5802	6,9476	-0,333	6,0647	0,1969	1,8153	6,5318
SVR	sqrtAGB	pLAs	Todas	20,4466	0,5839	7,0119	0,6691	5,5312	0,1947	1,5879	7,0886
ENET	sqrtAGB	pLAa	Imp.	21,6437	0,6219	6,8083	0,8476	8,5506	0,1863	2,1285	7,9838
RF	sqrtAGB	pLAs	Todas	21,5176	0,5582	7,2724	-0,4365	5,795	0,1926	1,7712	6,5452

FONTE: O autor (2023).

LEGENDA: SVR = *Support Vector Regression*, RF = *Random Forest*, ENET = *Elastic net*, Y = variável resposta, X' = variável preditora quanto à natureza dos dados, X'' = variável preditora quanto à importância, RMSE% = raiz do erro médio quadrático percentual, R² = coeficiente de determinação, MAE = erro médio absoluto, Bias% = viés percentual, sd = desvio padrão, lnAGB = logaritmo neperiano da AGB, sqrtAGB, raiz quadrada da AGB, pLAa = integração das bandas com as reflectâncias de todos os pixels e a nuvem com somente os pontos da árvore de Araucária, pLAs = integração das bandas com as reflectâncias de todos os pixels e a nuvem com pontos da árvore de Araucária e o sub-bosque sob ela, Imp. = variáveis mais importantes.

A segunda integração entre esses dois dados foi com as 270 bandas espectrais, cujas reflectâncias foram obtidas a partir dos píxeis iluminados apenas (sL), às duas nuvens de pontos LiDAR (As e Aa). Dessa forma, os dois conjuntos de dados foram: um com sL adicionado à nuvem contendo a árvore de Araucária com o sub-bosque (sLAs) e outro com a nuvem de pontos contendo apenas a Araucária (sLAa).

Analisou-se os pares análogos de modelos As-sLAs, cujos modelos possuem o mesmo algoritmo, variável resposta e mesmo critério de seleção de variáveis preditoras (Tabela 23). No algoritmo ENET percebeu-se um decréscimo no R² quando utilizadas apenas as variáveis mais importantes e um aumento quando foram utilizadas todas as variáveis preditoras. Já no RF, houve aumento no R² quando utilizadas apenas as variáveis mais importantes e decréscimo quando foram utilizadas todas as variáveis. No SVR houve decréscimo do R² em todas as

combinações de variáveis. Nos pares de modelos Aa-sLAa, o ENET teve um aumento no R^2 em todas as combinações de variáveis. O RF teve aumento no R^2 quando foram utilizadas apenas as variáveis predictoras mais importantes e decréscimo quando todas as variáveis foram utilizadas. Já no SVR, houve decréscimo apenas quando utilizadas todas as variáveis predictoras e a variável resposta com transformação logarítmica.

TABELA 23 - Comparativo entre a modelagem da biomassa com apenas nuvens de pontos LiDAR e as nuvens integradas com dados hiperespectrais utilizando apenas os pixels iluminados (*sunlit*).

Algoritmo	Y	Variáveis	R ² As	R ² sLAs	R ² Aa	R ² sLAa
ENET	lnAGB	Todas	0,4791	0,4998	0,5332	0,5753
ENET	lnAGB	Imp.	0,5536	0,548	0,5236	0,5576
ENET	sqrtAGB	Todas	0,5879	0,5907	0,6297	0,6596
ENET	sqrtAGB	Imp.	0,6302	0,628	0,6131	0,6357
RF	lnAGB	Todas	0,535	0,5024	0,5542	0,5221
RF	lnAGB	Imp.	0,5389	0,5451	0,5636	0,6018
RF	sqrtAGB	Todas	0,5766	0,5494	0,6049	0,575
RF	sqrtAGB	Imp.	0,5608	0,5717	0,6235	0,644
SVR	lnAGB	Todas	0,5368	0,5016	0,6263	0,6155
SVR	lnAGB	Imp.	0,6356	0,6275	0,6614	0,6889
SVR	sqrtAGB	Todas	0,6004	0,5858	0,6774	0,6859
SVR	sqrtAGB	Imp.	0,6654	0,6476	0,7008	0,7032

FONTE: O autor (2023).

LEGENDA: Y = variável resposta, R² = coeficiente de determinação, As = nuvem com pontos da árvore de Araucária e o sub-bosque sob ela, sLAs = integração das bandas com as reflectâncias dos pixels iluminados (*sunlit*) e a nuvem com pontos da árvore de Araucária e o sub-bosque sob ela, Aa = nuvem com somente os pontos da árvore de Araucária, sLAa = integração das bandas com as reflectâncias dos pixels iluminados (*sunlit*) e a nuvem com somente os pontos da árvore de Araucária, lnAGB = logaritmo neperiano da AGB, sqrtAGB, raiz quadrada da AGB, Imp. = variáveis mais importantes.

A nuvem de pontos As combinada com sL apresentou um decréscimo no valor da média do R², partindo de 0,5750 (As) para 0,5665 (sLAs) (Tabela 17). Os valores mínimo e máximo ficaram, respectivamente, em 0,4791 e 0,6654 (As) e em 0,4998 e 0,6476 (sLAs). Já a nuvem integrada sLAa apresentou um aumento no valor da média do R² em relação à nuvem Aa, 0,6220 e 0,6093, respectivamente. Os valores mínimo e máximo ficaram, respectivamente, em 0,5236 e 0,7008 (Aa) e em 0,5221 e 0,7032 (sLAa).

O modelo com o melhor desempenho, em que foram integradas as reflectâncias apenas dos pixels iluminados (sL), foi o obtido com o algoritmo SVR, variável resposta com transformação logarítmica (lnAGB) e variáveis predictoras mais importantes (*'Return 2 count above 1.30', 'crown_area_m2', 'Total return count', 'Total all returns', 'All returns above 1.30', 'Total return count above 1.30', 'All returns above mean', 'First returns above mean', "1000"*), conforme a Tabela 24. A nuvem de pontos utilizada foi a que apresentou apenas os pontos das árvores de Araucária combinada com sL (sLAa). Em relação ao seu modelo análogo (Aa), o valor do R² aumentou de 0,6614 para 0,6889. Da mesma forma, o modelo que apresentou o

maior R^2 (0,7032) teve um aumento em relação ao seu análogo Aa, que foi de 0,7008. Esse modelo também foi obtido com SVR e as mesmas variáveis preditoras, diferenciando-se apenas na variável resposta que utilizou a transformação raiz quadrada (sqrtAGB). Já o menor R^2 foi de 0,4998 da combinação sLAs, oriundo do ajuste com ENET, transformação logarítmica e utilizando todas as variáveis preditoras. Entre os demais indicadores estatísticos, o RMSE% variou de 6,0669 a 21,5358, o MAE ficou entre 0,322 e 7,3622 e o Bias% entre -1,0827 e 0,61 para a combinação sLAs. Já para a combinação sLAa, o RMSE% variou de 5,3154 a 21,2967, o MAE ficou entre 0,2863 e 7,0514 e o Bias% entre -1,0984 e 1,1405.

TABELA 24 - Métricas de ajuste dos modelos de biomassa com a integração dos dados LiDAR com os dados hiperespectrais utilizando apenas os pixels iluminados (*sunlit*).

Algoritmo	Y	X'	X''	RMSE%	R ²	MAE	Bias%	RMSE% sd	R ² sd	MAE sd	Bias% sd
SVR	lnAGB	sLAa	Imp.	5,3154	0,6889	0,2863	-0,0324	2,0795	0,1804	0,0897	1,7449
RF	lnAGB	sLAa	Imp.	6,271	0,6018	0,3272	0,0186	3,0267	0,2074	0,1076	2,3433
ENET	lnAGB	sLAa	Todas	6,563	0,5753	0,3512	0,1304	2,8899	0,2228	0,1144	1,972
SVR	lnAGB	sLAs	Imp.	6,0669	0,6275	0,322	0,4241	2,7273	0,1928	0,102	2,1192
RF	lnAGB	sLAs	Imp.	6,6793	0,5451	0,3537	0,0245	2,639	0,242	0,1222	2,5204
SVR	lnAGB	sLAa	Todas	6,1479	0,6155	0,3285	0,7606	2,9503	0,1908	0,1161	2,2064
SVR	sqrtAGB	sLAa	Todas	17,618	0,6859	5,9468	0,1497	5,0392	0,1634	1,5942	6,3846
ENET	lnAGB	sLAs	Imp.	6,9076	0,548	0,3751	0,0707	2,7074	0,1847	0,1018	2,3772
ENET	sqrtAGB	sLAa	Todas	18,4032	0,6596	5,8003	0,2158	6,2952	0,2482	1,8004	6,2468
ENET	lnAGB	sLAs	Todas	6,9256	0,4998	0,3728	0,0337	2,7992	0,2106	0,1082	1,9577
SVR	sqrtAGB	sLAa	Imp.	16,7502	0,7032	5,4637	-1,0984	5,6515	0,1735	1,5726	5,6096
RF	sqrtAGB	sLAa	Imp.	18,8104	0,644	6,1496	-0,2135	5,9527	0,1823	1,6903	6,3942
ENET	lnAGB	sLAa	Imp.	7,0943	0,5576	0,3815	0,2234	3,0717	0,1802	0,124	2,6149
RF	lnAGB	sLAa	Todas	6,8673	0,5221	0,3779	-0,3747	3,0924	0,225	0,1236	2,3742
ENET	sqrtAGB	sLAs	Todas	19,9823	0,5907	6,2916	0,1431	6,0094	0,2324	1,6703	5,021
ENET	sqrtAGB	sLAs	Imp.	19,5989	0,628	6,375	0,2527	5,5358	0,1915	1,5513	6,2726
SVR	sqrtAGB	sLAs	Imp.	18,5423	0,6476	6,1334	-1,0827	5,9968	0,2026	1,6772	6,1738
RF	lnAGB	sLAs	Todas	7,0066	0,5024	0,3934	-0,3741	2,9807	0,2192	0,116	2,4052
SVR	lnAGB	sLAs	Todas	6,8566	0,5016	0,3786	0,61	3,0693	0,211	0,1119	2,4188
SVR	sqrtAGB	sLAs	Todas	19,9373	0,5858	6,8925	0,2202	5,1301	0,1901	1,4434	6,6113
RF	sqrtAGB	sLAs	Imp.	20,4652	0,5717	6,799	0,2074	6,0617	0,2134	1,9759	7,2987
ENET	sqrtAGB	sLAa	Imp.	21,2967	0,6357	6,6387	1,1405	8,3917	0,1949	2,0582	7,4842
RF	sqrtAGB	sLAa	Todas	20,9885	0,575	7,0514	-0,4233	5,9616	0,1978	1,7249	6,1229
RF	sqrtAGB	sLAs	Todas	21,5358	0,5494	7,3622	-0,4747	5,7092	0,1999	1,697	6,3484

FONTE: O autor (2023).

LEGENDA: SVR = *Support Vector Regression*, RF = *Random Forest*, ENET = *Elastic net*, Y = variável resposta, X' = variável preditora quanto à natureza dos dados, X'' = variável preditora quanto à importância, RMSE% = raiz do erro médio quadrático percentual, R² = coeficiente de determinação, MAE = erro médio absoluto, Bias% = viés percentual, sd = desvio padrão, lnAGB = logaritmo neperiano da AGB, sqrtAGB, raiz quadrada da AGB, sLAa = integração das bandas com as reflectâncias dos pixels iluminados (*sunlit*) e a nuvem com somente os pontos da árvore de Araucária, sLAs = integração das bandas com as reflectâncias dos pixels iluminados (*sunlit*) e a nuvem com pontos da árvore de Araucária e o sub-bosque sob ela.

Semelhante a este trabalho, Laurin et al. (2014) encontraram um aumento no R² quando integraram dados hiperespectrais aos dados LiDAR em floresta tropical em Serra Leoa.

Conforme os autores, o modelo que usou apenas os dados LiDAR teve um R^2 de 0,64, e após a integração, o valor do R^2 passou para 0,70. Além disso, consideraram a acurácia do R^2 de 0,70 relativamente baixa, podendo estar associada a erros de medidas de campo, erros de locação de parcelas e erros introduzidos pelo modelo alométrico utilizado. Em Sierra Nevada, Califórnia, em uma floresta com coníferas, Swatantran et al. (2011) obtiveram um ganho similar, saindo de 0,77 para 0,88 de R^2 , respectivamente, ajustados com dados LiDAR e integração. Conforme os autores, a fusão de ambos os sensores é muito importante para a biodiversidade, já que o LiDAR proporciona medidas da estrutura da floresta e dados hiperespectrais proporcionam informações sobre a composição de espécies e stress da vegetação. Apesar de ajustes similares, a origem dos dados difere deste trabalho, pois, enquanto aqueles trabalhos utilizaram dados de sensores em plataformas orbitais distintas, este utilizou uma mesma plataforma, RPA, com ambos os sensores coletando dados simultaneamente.

4.4.5 Síntese das modelagens da biomassa

Na Tabela 25 são mostrados os melhores modelos selecionados nas três modelagens da biomassa acima do solo. Com dados oriundos do LiDAR (As, Aa), dados hiperespectrais (pL, sL) e a integração de ambos (pLAs, pLAa, sLAs, sLAa). Apesar de terem sido ajustados modelos com o R^2 superiores aos apresentados na Tabela 25, foram considerados quatro indicadores estatísticos para estabelecer os melhores modelos.

TABELA 25 – Resumo das modelagens com apenas os modelos selecionados.

Algoritmo	Y	X	Variáveis	RMSE%	R^2	MAE	Bias%	RMSE% sd	R^2 sd	MAE sd	Bias% sd
SVR	lnAGB	sLAa	Imp.	5,3154	0,6889	0,2863	-0,0324	2,0795	0,1804	0,0897	1,7449
SVR	lnAGB	Aa	Imp.	5,7356	0,6614	0,2928	0,1238	2,9113	0,1955	0,1099	2,1113
SVR	lnAGB	pLAa	Imp.	5,7969	0,661	0,3056	0,4462	2,8962	0,1808	0,108	2,0912
SVR	lnAGB	As	Imp.	6,0993	0,6356	0,3186	-0,0468	2,6398	0,1987	0,1055	2,289
SVR	lnAGB	sLAs	Imp.	6,0669	0,6275	0,322	0,4241	2,7273	0,1928	0,102	2,1192
SVR	lnAGB	pLAs	Imp.	6,2975	0,6034	0,3355	0,5489	2,8315	0,188	0,1044	2,198
ENET	lnAGB	pL	Todas	8,4562	0,3402	0,4763	-0,1213	3,2964	0,2357	0,137	2,7141
SVR	lnAGB	sL	Todas	8,5165	0,2797	0,4606	1,3701	3,3288	0,2409	0,1191	2,1305

FONTE: O autor (2023).

LEGENDA: SVR = *Support Vector Regression*, ENET = *Elastic net*, Y = variável resposta, X' = variável preditora quanto à natureza dos dados, X'' = variável preditora quanto à importância, RMSE% = raiz do erro médio quadrático percentual, R^2 = coeficiente de determinação, MAE = erro médio absoluto, Bias% = viés percentual, sd = desvio padrão, lnAGB = logaritmo neperiano da AGB, Aa = nuvem com somente os pontos da árvore de Araucária, As = nuvem com pontos da árvore de Araucária e o sub-bosque sob ela, pL = bandas com as reflectâncias de todos os pixels, sL = bandas com as reflectâncias dos pixels iluminados (*sunlit*), pLAa = integração das bandas com as reflectâncias de todos os pixels e a nuvem com somente os pontos da árvore de Araucária, pLAs = integração das bandas com as reflectâncias de todos os pixels e a nuvem com pontos da árvore de Araucária e o sub-bosque sob ela, sLAa = integração das bandas com as reflectâncias dos pixels iluminados (*sunlit*) e a nuvem

com somente os pontos da árvore de Araucária, sLAs = integração das bandas com as reflectâncias dos pixels iluminados (*sunlit*) e a nuvem com pontos da árvore de Araucária e o sub-bosque sob ela.

Ao aplicar os modelos nos conjuntos de teste, obteve-se os seguintes valores para o R^2 : 0,3184 (sLAa), 0,2887 (Aa), 0,3777 (pLAa), 0,2737 (As), 0,3182 (sLAs), 0,3347 (pLAs), 0,0744 (pL) e 0,0112 (sL). Comparando, percebeu-se que houve diminuição nos valores de R^2 dos modelos, o que poderia evidenciar um sobreajuste. No entanto, como foi adotado o método de controle de validação cruzada, essa diferença pode ser devido à heterogeneidade dos dados, com os conjuntos de dados selecionados para treino e teste não representado o conjunto global dos dados. Conforme Gao et al. (2022), a razão para o desvio entre a precisão do treinamento e a precisão do teste pode ser por causa da desigualdade dos dois conjuntos.

A modelagem com os dados hiperespectrais foi a que apresentou os modelos com os piores ajustes, o que também foi constatado em outros trabalhos. No entanto, quando integrado aos dados do sensor LiDAR, proporcionou uma melhora nos ajustes. O que também se percebeu foi que a nuvem Aa esteve presente nos modelos selecionados que apresentaram os 3 maiores valores de R^2 . Apenas os modelos com os dados hiperespectrais utilizaram todas as variáveis na modelagem e apenas o pL utilizou o algoritmo ENET. Os demais foram ajustados com o algoritmo SVR. Assim, pode-se afirmar que, nas condições apresentadas neste trabalho, é melhor utilizar o algoritmo SVR e as variáveis mais importantes para a modelagem da biomassa.

Apesar dos trabalhos trazidos para esta discussão a fim de corroborar ou refutar os resultados obtidos, a comparação é dificultada por ser o primeiro trabalho desse tipo com a espécie Araucária e os demais trabalhos serem com outras espécies e também a níveis de parcela e regionais. Além disso, os sensores utilizados variaram em termos de resolução e plataforma utilizada, o que afeta os dados obtidos.

Devido à importância da espécie Araucária nos fragmentos florestais nativos e, em função da impossibilidade de corte desta espécie nestas condições naturais, devem ser estimulados trabalhos que viabilizem boas previsões de suas variáveis biofísicas nestes ambientes, especialmente com o uso do sensoriamento remoto. No entanto, o que se observa é que ainda são poucos os trabalhos em que são aplicadas novas tecnologias e métodos, principalmente geotecnológicos, como o uso do sensor LiDAR e hiperespectrais para tais finalidades.

4.5 MODELAGEM DOS ÍNDICES DE VEGETAÇÃO COM DADOS LIDAR

Este é o primeiro trabalho a propor a predição de índices de vegetação a partir das métricas derivadas de nuvem de pontos oriundas do LiDAR. Não foi objetivo deste trabalho abordar custos de aquisição de sensores, no entanto, vale ressaltar que a aquisição de dois sensores requer recursos financeiros mais robustos. Assim, a possibilidade de ter um sensor, cujos dados poderiam prever variáveis que só seriam possíveis com outro, geraria uma economia de recursos.

Na Tabela 26 estão apresentados os modelos com o melhor desempenho de cada índice. O RMSE% variou de -17,3773% a 38,1561%, para os IVs PRI e PSRI, respectivamente. A variação do R² ficou entre 0,2034 e 0,549, RVSI e PSRI, respectivamente. O MAE, entre 0,0021 e 3,3423, para o RVSI e CRI 2, respectivamente, e o Bias% variou de 0,0016 % a 1,8083 % para o NDVI e o VARI, respectivamente.

TABELA 26 – Métricas de ajuste do modelo com melhor desempenho de cada índice de vegetação a partir de dados do sensor LiDAR.

IV	ml	Nuvem	rho	Variáveis	RMSE%	R ²	MAE	Bias%
ACI	SVR	Aa	pL	Imp.	7,7906	0,4624	0,0117	0,0043
ARI	SVR	As	sL	Todas	12,5528	0,4553	1,671	0,3674
CIG	ENET	As	pL	Imp.	11,8259	0,3866	0,4983	0,0049
CIRE	ENET	As	pL	Imp.	7,4955	0,4533	0,0194	0,0682
CRI	SVR	As	sL	Todas	14,9914	0,3797	1,9423	0,1897
CRI2	SVR	As	sL	Todas	12,9755	0,4357	3,3423	0,5908
EVI	SVR	Aa	sL	Todas	2,4109	0,4942	0,0105	0,2726
MARI	SVR	As	sL	Imp.	11,9916	0,4214	0,4921	0,0211
MCARI	SVR	As	sL	Todas	13,9904	0,3877	0,2125	0,1269
NDVI	RF	Aa	sL	Todas	2,2845	0,478	0,0161	0,0016
PRI	RF	Aa	pL	Todas	-17,3773	0,3632	0,0058	0,1215
PSND	RF	Aa	sL	Todas	2,7806	0,4708	0,0184	0,0319
PSRI	RF	As	pL	Todas	38,1561	0,549	0,0033	0,0276
RENDVI	SVR	Aa	sL	Imp.	4,1507	0,4933	0,023	0,0459
RVSI	ENET	Aa	sL	Imp.	-5,2448	0,2034	0,0021	0,0018
SIPI	ENET	Aa	sL	Imp.	0,482	0,4692	0,0039	0,003
SR_NIR_RED	SVR	As	pL	Imp.	14,3239	0,4604	1,3285	1,0958
VARI	RF	As	sL	Todas	6,3103	0,5065	0,0235	1,8083
VIG	SVR	Aa	pL	Todas	8,9286	0,4499	0,0216	0,2171
WBI	RF	As	pL	Todas	2,8324	0,4274	0,031	0,0821

FONTE: O autor (2023).

LEGENDA: IV = índice de vegetação, ml = algoritmo de aprendizado de máquina, rho = forma de obtenção das reflectâncias, RMSE% = raiz do erro médio quadrático percentual, R² = coeficiente de determinação, MAE = erro médio absoluto, Bias% = viés percentual, sd = desvio padrão, lnAGB = logaritmo neperiano da AGB, Aa = nuvem com somente os pontos da árvore de Araucária, As = nuvem com pontos da árvore de Araucária e o sub-bosque sob ela, pL = bandas com as reflectâncias de todos os pixels, sL = bandas com as reflectâncias dos pixels iluminados (*sunlit*).

Os índices que tiveram os melhores ajustes, considerando o R^2 , foram o PSRI (0,549), o VARI (0,5065), o EVI (0,4942) e o RENDVI (0,4933). O algoritmo de aprendizado de máquina que mais figurou nos ajustes dos modelos foi o SVR com 10 modelos. Em seguida o RF com 6 e o ENET com 4 modelos. Em relação às nuvens de pontos do LiDAR utilizadas, não houve grande diferença entre a presença delas nos modelos. Enquanto que a nuvem de pontos As esteve presente em 11 modelos, a nuvem Aa esteve em 9. Quanto à forma de obtenção das reflectâncias, 12 modelos tiveram índices calculados com apenas os pixels iluminados. Da mesma forma, quanto ao número de métricas oriundas da nuvem de pontos do LiDAR utilizadas, 12 modelos foram ajustados a partir de todas as métricas.

Analisando as métricas mais importantes em cada combinação para o ajuste dos índices, percebeu-se que as métricas mais importantes não variaram entre os algoritmos de aprendizado de máquina. Isso permite inferir que os índices de vegetação podem ser sensíveis a métricas específicas. Como este trabalho utilizou apenas 3 algoritmos de aprendizado de máquina e 20 índices de vegetação, é necessário que se investigue esse padrão com outros algoritmos e índices de vegetação.

Utilizando todos os pixels com a nuvem de pontos As foram selecionadas 13 métricas diferentes como as mais importantes. Apenas o índice CIRE selecionou uma métrica de elevação (*Elev.L3*), as demais métricas nesse índice e nos demais, foram de intensidade. Já com a nuvem Aa, foram selecionadas 21 métricas diferentes. Entre as de elevação foram *Elev.P05* (CIRE e MCARI), *Elev.P10* (VARI), *Elev.P20* (CIRE e VARI), *Elev.P25* (VARI e VIG) e *Elev.P30* (VIG), as demais foram de intensidade. Quando se utilizou apenas os pixels iluminados com a nuvem de pontos As, foram selecionadas 29 métricas, e com a nuvem Aa, 33 métricas. Em ambas o índice EVI foi o único a ter selecionado apenas métricas de elevação, 15 com a nuvem de pontos As e 20 com a nuvem Aa. Ao todo foram 36 métricas diferentes, as quais estão dispostas no Tabela 27.

TABELA 27 – Métricas LiDAR com importância maior ou igual a 90 %.

Métricas LiDAR	Pixel		Nuvem		Índices de Vegetação
<i>Elev.mean</i>		sL	As	Aa	EVI
<i>Elev.mode</i>		sL	As	Aa	EVI
<i>Elev.maximum</i>		sL	As	Aa	EVI
<i>Elev.L1</i>		sL	As	Aa	EVI
<i>Elev.L3</i>	pL		As		CIRE
<i>Elev.SQRT.mean.SQ</i>		sL	As	Aa	EVI
<i>Elev.CURT.mean.CUBE</i>		sL	As	Aa	EVI
<i>Elev.P05</i>	pL			Aa	CIRE, EVI, MCARI
<i>Elev.P10</i>	pL			Aa	EVI, PRI, VARI
<i>Elev.P20</i>	pL			Aa	CIRE, EVI, PRI, VARI
<i>Elev.P25</i>	pL	sL	As	Aa	EVI, PRI, VARI, VIG
<i>Elev.P30</i>	pL			Aa	EVI, VARI
<i>Elev.P50</i>		sL	As	Aa	EVI
<i>Elev.P60</i>		sL	As	Aa	EVI
<i>Elev.P70</i>		sL	As	Aa	EVI
<i>Elev.P75</i>		sL	As	Aa	EVI
<i>Elev.P80</i>		sL	As	Aa	EVI
<i>Elev.P90</i>		sL	As	Aa	EVI
<i>Elev.P95</i>		sL	As	Aa	EVI
<i>Elev.P99</i>		sL	As	Aa	EVI
<i>Int.mean</i>	pL	sL	As	Aa	ACI, ARI, CIG, CRI, CRI2, EVI, MARI, NDVI, PSND, RENDVI, RVSI, SR.
<i>Int.stddev</i>	pL	sL	As	Aa	MCARI, NDVI, PRI, PSRI, RVSI, SIPI, VARI, VIG.
<i>Int.variance</i>	pL	sL	As	Aa	MCARI, NDVI, PRI, PSRI, RVSI, SIPI, VARI.
<i>Int.CV</i>	pL	sL	As	Aa	ACI, CIG, CIRE, CRI, CRI2, MARI, NDVI, PRI, PSND, PSRI, RENDVI, RVSI, SIPI, SR, WBI.
<i>Int.kurtosis</i>	pL			Aa	VARI
<i>Int.skewness</i>	pL	sL	As	Aa	ACI, CIG, CIRE, CRI, MARI, MCARI, NDVI, PSND, PSRI, RENDVI, SIPI, SR, VARI, VIG, WBI.
<i>Int.L1</i>	pL	sL	As	Aa	ACI, ARI, CIG, CRI, CRI2, EVI, MARI, NDVI, PSND, RENDVI, RVSI, SR.
<i>Int.L2</i>	pL	sL	As	Aa	CIRE, PRI, PSRI, RVSI, SIPI.
<i>Int.L3</i>	pL	sL	As	Aa	CIRE, WBI.
<i>Int.L4</i>	pL	sL	As	Aa	ACI, CIG, CIRE, MARI, MCARI, NDVI, PRI, PSND, PSRI, RENDVI, SIPI, SR, VARI, VIG, WBI.
<i>Int.L.CV</i>	pL	sL	As	Aa	ACI, ARI, CIG, CIRE, CRI, CRI2, MARI, NDVI, PRI, PSND, PSRI, RENDVI, RVSI, SR, WBI.
<i>Int.L.kurtosis</i>	pL	sL	As	Aa	ACI, CIG, MARI, MCARI, NDVI, PRI, PSND, PSRI, RENDVI, SIPI, SR, VARI, VIG, WBI.
<i>Int.L.skewness</i>	pL	sL	As	Aa	ACI, CIG, CIRE, CRI, MARI, MCARI, NDVI, PSND, PSRI, RENDVI, SIPI, SR, VARI, VIG, WBI.
<i>Int.P10</i>	pL	sL	As	Aa	ARI, CIG, CIRE, CRI, CRI2, MARI, NDVI, PSND, RENDVI, WBI.
<i>Int.P60</i>	pL	sL	As	Aa	CIG, CIRE, CRI, CRI2, MARI, NDVI, PSND, PSRI, RENDVI, SIPI, WBI.
<i>Int.P99</i>	pL		As	Aa	MCARI, RVSI.

FONTE: O autor (2023).

LEGENDA: Aa = nuvem com somente os pontos da árvore de Araucária, As = nuvem com pontos da árvore de Araucária e o sub-bosque sob ela, pL = bandas com as reflectâncias de todos os pixels, sL = bandas com as reflectâncias dos pixels iluminados (*sunlit*).

Devido ao pioneirismo deste trabalho, encontrar trabalhos semelhantes, a fim de se comparar os resultados obtidos, não foi uma tarefa exitosa. Dessa forma, por existir essa lacuna, faz-se necessário o aprofundamento dessa pesquisa. Uma vez que esses resultados são relativos a uma única espécie, pesquisas com outras espécies, assim como a nível de floresta (de diferentes fitofisionomias) podem apresentar resultados que corroboram ou refutam os encontrados aqui.

Os resultados encontrados indicaram que predizer índices de vegetação a partir de métricas oriundas da nuvem de pontos do LiDAR é um método promissor. Não foi objetivo deste trabalho avaliar se índices de diferentes naturezas (pigmentos, estrutura, fisiologia) possuem maior ou menor correlação com as métricas oriundas da nuvem de pontos do LiDAR, portanto, devido à quantidade de índices existentes, é algo que pode ser investigado em trabalhos futuros.

5 CONCLUSÃO

A análise bibliométrica mostrou que há uma lacuna na pesquisa com a biomassa da *Araucaria angustifolia*. No período da busca apenas 2 trabalhos com o uso do Sensoriamento Remoto e nenhum utilizando técnicas de aprendizado de máquina.

A caracterização espectral a partir de dados hiperespectrais permitiu a identificação de comprimentos de onda que indicaram o comportamento da curva espectral da espécie *Araucaria angustifolia*. Isso permite que se adote esses comprimentos de onda na adaptação de índices de vegetação que venham a ser usados para essa espécie. Não houve diferença significativa ao se analisar o comportamento espectral da espécie *Araucaria angustifolia* por classes de diâmetro. Além disso, poderá ser criada uma biblioteca espectral onde outras espécies também poderão ter seu comportamento espectral definido dentro do espectro eletromagnético.

A predição da biomassa acima do solo com o uso de algoritmos de aprendizado de máquina mostrou-se satisfatório, com todos os modelos apresentando um R^2 acima de 0,90.

A predição da biomassa a partir de dados hiperespectrais, através das bandas espectrais, não apresentou bons resultados. Os modelos ajustados apresentaram pouca correlação com a biomassa e R^2 abaixo de 0,3.

Ao contrário dos dados hiperespectrais, os ajustes com as métricas derivadas dos dados oriundos do LiDAR apresentaram desempenho melhor. Embora aquém do esperado, com os melhores ajustes apresentando R^2 maior que 0,6, poderá ser feito ajustes nos parâmetros dos algoritmos buscando um desempenho superior a esse.

A integração dos dados hiperespectrais com os dados oriundos do LiDAR confirmou a hipótese de melhora do R^2 . Apesar de não ter sido um aumento expressivo, a integração permitiu que se chegasse a um modelo com R^2 próximo a 0,70.

A predição dos Índices de Vegetação a partir dos dados oriundos do LiDAR não apresentou bom desempenho. No entanto, pode-se constatar que as métricas relacionadas à intensidade do LiDAR foram as mais importantes nos modelos de predição, exceto o índice EVI, cujos modelos selecionaram métricas de elevação como as mais importantes. Como esse é o primeiro trabalho a propor essa predição, ajustes poderão ser feitos, inclusive a adoção de outros métodos de predição.

Esse trabalho utilizou apenas uma espécie, por isso, embora os resultados tenham sido abaixo do esperado, pode haver diferentes resultados com outras espécies e também a nível de parcela.

6 RECOMENDAÇÕES

Os parâmetros utilizados nos algoritmos de aprendizado de máquina foram os mesmos para todas as predições. Assim, recomenda-se o teste de outros algoritmos de aprendizado de máquina para a realização das modelagens, assim como diferentes configurações dos hiperparâmetros, inclusive dos adotados nesta tese;

Recomenda-se a inclusão de outros índices de vegetação para realizar a modelagem a partir das métricas do sensor LiDAR. Visto que há uma grande variedade de índices e relacionados à diversas variáveis biofísicas da vegetação, pode-se encontrar algum que seja mais sensível às métricas obtidas do LiDAR. Além disso, como as métricas relacionadas à intensidade foram as selecionadas como as mais importantes, com exceção do EVI, recomenda-se que próximas modelagens partam desse conjunto de métricas;

Recomenda-se que quando for realizada a caracterização espectral de espécies florestais a partir de dados obtidos com sensores hiperespectrais, seja feita também com as reflectâncias obtidas apenas dos pixels iluminados (*sunlit*). Assim, será possível ter, em uma biblioteca espectral, o comportamento espectral da espécie quando sombreada por outras árvores e sem sombreamento.

REFERÊNCIAS

- ALABARCE, F. DA S.; DILLENBURG, L. R. Resprouting ability and intensity after damage in seedlings of the large-seeded species *Araucaria angustifolia*. **Brazilian Journal of Plant Physiology**, v. 24, n. 2, p. 131–140, 2012.
- ALABARCE, F. S.; DILLENBURG, L. R. A possible ontogenetic trade-off between defense and tolerance in response to simulated herbivory in seedlings and saplings of *Araucaria angustifolia*. **Theor. Exp. Plant Physiol.** v.26, p.147–156, 2014.
- AL-JAWARNEH, A. S.; ISMAIL, M. T.; AWAJAN, A. M. Elastic Net Regression and Empirical Mode Decomposition for Enhancing the Accuracy of the Model Selection. **International Journal of Mathematical, Engineering and Management Sciences**, v.6. n.2. p.564-583. 2021. <https://doi.org/10.33889/IJMEMS.2021.6.2.034>.
- ALMEIDA, C. T. et al. Combining LiDAR and hyperspectral data for aboveground biomass modeling in the Brazilian Amazon using different regression algorithms. **Remote Sensing of Environment**. n. 232, 2019.
- ALMEIDA, D. R. A. et al. Monitoring restored tropical forest diversity and structure through UAV-borne hyperspectral and lidar fusion. **Remote Sensing of Environment**. V.264, n. 112582, 2021.
- ALONZO, M.; McFADDEN, J. P.; NOWAK, D. J.; ROBERTS, D. A. Mapping urban forest structure and function using hyperspectral imagery and lidar data. **Urban Forestry & Urban Greening**. v.17, p.135–147, 2016.
- ALVES, J. L. F.; Da SILVA, J. C. G.; SILVA FILHO, V. F.; ALVES, R. F.; GALDINO, W. V. A.; ANDERSEN, S. L. F.; De SENA, R. F. Determination of the Bioenergy Potential of Brazilian Pine-Fruit Shell via Pyrolysis Kinetics, Thermodynamic Study, and Evolved Gas Analysis. **BioEnergy Research**. <https://doi.org/10.1007/s12155-019-9964-1>. 2019.
- AMARAL, S. S.; CARVALHO JUNIOR, J. A.; COSTA, M. A. M.; SOARES NETO, T. G.; DELLANI, R.; LEITE, L. H. S. Comparative study for hardwood and softwood forest biomass: Chemical characterization, combustion phases and gas and particulate matter emissions. **Bioresource Technology**. v.164, p.55–63, 2014.
- ANAND, A.; MALHI, R. K. M.; SRIVASTAVA, P. K.; SINGH, P.; MUDALIAR, A. N.; PETROPOULOS, G. P.; KIRAN, G. S. Optimal band characterization in reformation of hyperspectral indices for species diversity estimation. **Physics and Chemistry of the Earth**, v. 126, 2022.
- ANDERSEN, H. E.; STRUNK, J.; TEMESGEN, H.; ATWOOD, D.; WINTERBERGER, K. Using multilevel remote sensing and ground data to estimate forest biomass resources in remote regions: a case study in the boreal forests of interior Alaska, **Canadian Journal of Remote Sensing: Journal canadien de télédétection**, v. 37, n. 6, p. 596-611, 2012. DOI: 10.5589/m12-003

ANDERSON, J. E. Integrating waveform lidar with hyperspectral imagery for inventory of a northern temperate forest. **Remote Sensing of Environment**. V.112, p. 1856-1870, 2008.

ANWAR, M. A. et al. Global perspectives on environmental kuznets curve: A bibliometric review. **Gondwana Research**, v. 103, p. 135–145, 2022.

AO, Z. et al. Automatic segmentation of stem and leaf components and individual maize plants in field terrestrial LiDAR data using convolutional neural networks. **The Crop Journal**. V.10, 2021.

ASNER, G. P. et al. Selective Logging in the Brazilian Amazon. **Science**. v. 310, n. 5747, p. 480 – 482, 2005.

ATANAZIO, K. A.; HESS, A. F.; KREFTA, S. M.; SCHORR, L. P. B.; SOUZA, I. A.; DOMICIANO, C. A. R.; CUHI, T.; MORAES, G. C. Modelagem das relações morfométricas com a produção de pinhas de *Araucaria angustifolia* (Bertol.) Kuntze no sul do Brasil. **Ciência Florestal**, Santa Maria, v. 32, n. 3, p. 1247-1267, jul./set. 2022. <https://doi.org/10.5902/1980509847843>

BABBAR, N.; KUMAR, A.; VERMA, V. K. Chapter 11 - Crop management: Wheat yield prediction and disease detection using an intelligent predictive algorithms and metrological parameters. In: POONIA, R. C.; SINGH, V.; NAYAK, S. R. **Cognitive Data Science in Sustainable Computing, Deep Learning for Sustainable Agriculture**. Academic Press. 2022. pp. 273-295. <https://doi.org/10.1016/B978-0-323-85214-2.00006-9>.

BACCINI, A.; ASNER, G. P. Improving pantropical forest carbono maps with airborne LiDAR sampling. **Carbon Manag**. V.4, p.591-600, 2013.

BALBINOT, R. **Implantação de florestas geradoras de créditos de carbono: estudo de viabilidade no sul do Estado do Paraná, Brasil**. (Mestrado), Universidade Federal do Paraná, Curitiba. 2004.

BAO, S; CAO, C; CHEN, W; YANG, T.; WU, C. Towards a subtropical forest spectral library: spectra consistency and spectral separability, **Geocarto International**, 2019, DOI: 10.1080/10106049.2019.1608589.

BARBOSA, L. O.; Costa, E.A.; Schons, C.T.; Finger, C.A.G.; Liesenberg, V.; Bispo, P.d.C. Individual Tree Basal Area Increment Models for Brazilian Pine (*Araucaria angustifolia*) Using Artificial Neural Networks. **Forests** 2022, 13, 1108. <https://doi.org/10.3390/f13071108>

BERG, A. K. VAN DEN.; PERKINS, T. D. Evaluation of a portable chlorophyll meter to estimate chlorophyll and nitrogen contents in sugar maple (*Acer saccharum* Marsh.) leaves. **Forest Ecology and Management**, v.200, p. 113–117, 2004.

BERG, A. K. VAN DEN.; PERKINS, T. D. Nondestructive estimation of anthocyanin content in autumn sugar maple leaves. **Hortscience**, v. 40, n. 3, p. 685-686, 2005.

BLACKBURN, G. A. Quantifying Chlorophylls and Carotenoids at Leaf and Canopy Scales: An Evaluation of Some Hyperspectral Approaches. **Remote Sensing of Environment**, v. 66, p. 273–285, 1998a.

BLACKBURN, G. A. Spectral indices for estimating photosynthetic pigment concentrations: A test using senescent tree Leaves. **International Journal of Remote Sensing**, v.19, n.4, p. 657-675, 1998b. DOI: 10.1080/014311698215919.

BOUDREAU, J.; NELSON, R. F.; MARGOLIS, H. A.; BEAUDOIN, A.; GUINDON, L.; KIMES, D. S. Regional aboveground forest biomass using airborne and spaceborne LiDAR in Québec. **Remote Sensing of Environment**, v. 112, p. 3876–3890, 2008. DOI:10.1016/j.rse.2008.06.003.

BRASIL. Lei nº 11,428 de 22 dez. 2006. Dispõe sobre a utilização e proteção da vegetação nativa do Bioma Mata Atlântica, e dá outras providências. Access: mar. 2022. Available: http://www.planalto.gov.br/ccivil_03/_ato2004-2006/2006/lei/111428.htm. 2006.

BRASIL. Comando da Aeronáutica. Departamento de Controle do Espaço Aéreo. **Sistemas de Aeronaves Remotamente Pilotadas e o Acesso ao Espaço Aéreo Brasileiro – ICA 100-40**. Rio de Janeiro, 2015a. Disponível em: <http://publicacoes.decea.gov.br/?i=publicacao&id=4262>. Acessado em: <21 out. 2022>.

BRASIL. Agência Nacional de Aviação Civil. **RPAS – Sistemas de Aeronaves Remotamente Pilotadas**. Brasília, 2015b. Disponível em: <http://www2.anac.gov.br/rpas/>. Acessado em: <21 out. 2023>.

BRASIL. Resolução Conabio nº 8, de 8 de dez. de 2021 do Ministério do Meio Ambiente. **Lista Nacional Oficial de Espécies da Flora Ameaçadas de Extinção**. Access: mar. 2022. Available: https://www.gov.br/mma/pt-br/assuntos/biodiversidade/comissao-nacional-da-biodiversidade/SEI_MMA0855123Resoluo.pdf. 2021

BREIDENBACH, J. et al. Prediction of species specific forest inventory attributes using a nonparametric semi-individual tree crown approach based on fused airborne laser scanning and multispectral data. **Remote Sensing of Environment**. V.114, p.911-924, 2010.

BREIMAN, L. Random Forests. **Machine Learning**. v. 45, n. 1, p. 5–32. 2001.

BUBB, K. A.; XU, Z. H.; SIMPSON, J. A.; SAFLIGNA, P. G. Growth response to fertilisation and recovery of ¹⁵N-labelled fertiliser by young hoop pine plantations of subtropical Australia. **Nutrient Cycling in Agroecosystems**. v.54, p.81–92, 1999.

BULL, V. N.; PILATTI, F. K.; SCHWARTZ, E.; CASSANA, F. F. Sludge from rice parboiling wastewater treatment plant as alternative substrate for the production of araucaria *Angustifolia* seedlings. **Revista Arvore**, v. 45, p. 1–9, 2021.

CALDEIRA, M. V. W.; WATZLAWICK, L. F.; VIERA, M.; BALBINOT, R.; CASTRO, K. C. Biomassa e carbono orgânico em povoamentos de *araucaria angustifolia* (bertol.) kuntze. **Ciência Florestal**, Santa Maria, v. 25, n. 4, p. 1027-1034, 2015.

CALEGARO, R. M.; LONGHI, S. J.; ANDRZEJEWSKI, C. VARIAÇÕES ESTRUTURAIS ENTRE GRUPOS FLORÍSTICOS DE UM REMANESCENTE DE FLORESTA OMBRÓFILA MISTA MONTANA EM NOVA PRATA - RS. **Ciência Florestal**, Santa Maria, v. 25, n. 2, p. 337-349, 2015.

CANADELL, J. G.; RAUPACH, M. R. Managing forests for climate change mitigation. **Science**. V. 320, n. 1456, 2008.

CARVALHO, P. E. R. **Espécies Arbóreas Brasileiras**. Brasília : Embrapa Informação Tecnológica ; Colombo, PR : Embrapa Florestas, 2003.

ČEPL, J.; STEJSKAL, J.; LHOTÁKOVÁ, Z.; HOLÁ, D.; KORECKÝ, J.; LSTIBŮREK, M.; TOMÁŠKOVÁ, I.; KOČOVÁ, M.; ROTHOVÁ, O.; PALOVSKÁ, M.; HEJTMÁNEK, J.; KREJZKOVÁ, A.; GEZAN, S.; WHETTEN, R.; ALBRECHTOVÁ, J. Heritable variation in needle spectral reflectance of Scots pine (*Pinus sylvestris* L.) peaks in red edge. **Remote Sensing of Environment**, v. 219, p. 89-98, 2018.

CHAVE, J.; ANDAL, C.; BROWN, S.; CAIRNS, M.A.; CHAMBERS, J.Q.; EAMUS, D.; FÖLSTER, H.; FROMARD, F.; HIGUCHI, N.; KIRA, T.; LESCURE, J.P.; NELSON, B.W.; OGAWA, H.; PUIG, H.; RIÉRA, B.; YAMAKURA, T. Tree allometry and improved estimation of carbon stocks and balance in tropical forests. **Oecology**, v. 145, p. 87-99, 2005.
CHAVE, J.; RÉJOU-MÉCHAIN, M.; BŪRQUEZ, A.; CHIDUMAYO, E.; COLGAN, M.S.; DELITTI, W. B. C., et al. Improved allometric models to estimate the aboveground biomass of tropical trees. **Global Change Biology**. v.20, p.3177–3190, 2014.

CHEN, Q.; LU, D.; KELLER, M.; SANTOS, M. Z. dos; BOLFE, E. L.; FENG, Y.; WANG, C. Modeling and Mapping Agroforestry Aboveground Biomass in the Brazilian Amazon Using Airborne Lidar Data. **Remote Sens**. v. 8, n. 21, 17 p. 2016.

CLARK, R. N. Spectroscopy of rocks and minerals, and principles of spectroscopy. In: RENCZ, A.N. (Ed.), Manual of Remote Sensing, **Remote Sensing for the Earth Sciences**. John Wiley and Sons, New York, pp. 3–58. 1999.

COOMES, D. A.; DALPONTE, M.; TOMMASO JUCKER, T.; ASNER, G. P.; BANIN, L. FL.; BURSLEM, D. F. R. P.; LEWIS, S. L.; NILUS, R.; PHILLIPS, O. L.; PHUA, M. H.; QIE, L. Area-based vs tree-centric approaches to mapping forest carbon in Southeast Asian forests from airborne laser scanning data. **Remote Sensing of Environment**, v. 194, p. 77–88, 2017.

COOPER, S.; OKUJENI, A.; JÄNICKE, C.; CLARK, M.; LINDEN, S. van der; HOSTERT, P. Disentangling fractional vegetation cover: Regression-based unmixing of simulated spaceborne imaging spectroscopy data. **Remote Sensing of Environment**, v. 246, n. 111856, 2020.

CORRÊA, T. et al. Mapeamento da fitomassa da caatinga do núcleo de desertificação do Seridó, pelo índice de área de planta (IAP) e o índice de vegetação da diferença normalizada (NDVI), obtido com dados do sensor Landsat 7 TM. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 10. 2001. **Anais...** Foz do Iguaçu: INPE, 2001.

CORTE, A.P.D.; DA CUNHA NETO, E.M.; REX, F.E.; SOUZA, D.; BEHLING, A.; MOHAN, M.; SANQUETTA, M.N.I.; SILVA, C.A.; KLAUBERG, C.; SANQUETTA, C.R.; et al. High-Density UAV-LiDAR in an Integrated Crop-Livestock-Forest System: Sampling Forest Inventory or Forest Inventory Based on Individual Tree Detection (ITD). **Drones**. V.6, n.48. 2022. <https://doi.org/10.3390/drones6020048>

CUNHA NETO, E. M.; REX, F. E.; VERAS, H. F. P.; MOURA, M. M.; SANQUETTA, C. R.; KAUFER, P. S.; SANQUETTA, M. N. I.; ZAMBRANO, A. M. A.; BROADBENT, E. N.; CORTE, A. P. D. Using high-density UAV-Lidar for deriving tree height of *Araucaria Angustifolia* in an Urban Atlantic Rain Forest. **Urban Forestry & Urban Greening**. v.63, n. 127197. 2021.

DALLA LANA, M. **Dinamica e prognose do crescimento em um fragment de Floresta Ombrófila Mista no Sul do Paraná**. Tese de Doutorado. Doutorado em Engenharia Florestal. Universidade Federal do Paraná. Curitiba. 190f. 2013.

DAUGHTRY, C. S. T.; WALTHALL, C. L.; KIM, M. S.; BROWN, E. de colstoun.; MCMURTREY, J. E. Estimating Corn Leaf Chlorophyll Concentration from Leaf and Canopy Reflectance. **Remote Sensing of Environment**, v. 74, p. 229–239, 2000.

DEGERICKX, J. et al. Urban tree health assessment using airborne hyperspectral and LiDAR imagery. **Int J Appl Earth Obs Geoinformation**. V.73, p.26-38, 2018.

DELLA-SILVA, J. L.; JUNIOR, C. A. da silva.; LIMA, M.; RIBEIRO, R. DA SILVA.; SHOZO, L. S.; ROSSI, F. S.; TEODORO, L. P. R.; TEODORO, P. T. Amazonian species evaluation using leaf-based spectroscopy data and dimensionality reduction approaches. **Remote Sensing Applications: Society and Environment**. v 26, n. 100742, 2022.

DEO, R.K.; RUSSELL, M.B.; DOMKE, G.M.; ANDERSEN, H.-E.; COHEN, W.B.; WOODALL, C.W. Evaluating Site-Specific and Generic Spatial Models of Aboveground Forest Biomass Based on Landsat Time-Series and LiDAR Strip Samples in the Eastern USA. **Remote Sens.**, v.9, p. 598, 2017. DOI: [10.3390/rs9060598](https://doi.org/10.3390/rs9060598).

DILSHAD, A.; ANWER, H.; SHAH, F.; et al. Biosorptive Removal of Cr(VI) from Aqueous Solution by *Araucaria Cunninghamii* Linn: A Multivariate Study. **Analytical Letters**, v. 54, n. 8, p. 1243–1268, 2021. Taylor & Francis. Disponível em: <https://doi.org/10.1080/00032719.2020.1799225>.

D'OLIVEIRA, M. V. N. Aboveground Biomass Estimation in Amazonian Tropical Forests: a Comparison of Aircraft- and GatorEye UAV-borne LiDAR Data in the Chico Mendes Extractive Reserve in Acre, Brazil. **Remote Sensing**. v.12, n. 1754, 2020.

DONOGHUE, D. N. M.; WATT, P. J. Using LiDAR to compare forest height estimates from IKONOS and Landsat ETM+ data in Sitka spruce plantation forests. **International Journal of Remote Sensing**, v. 27, n. 11, p. 2161–2175, 2006. DOI: [10.1080/01431160500396493](https://doi.org/10.1080/01431160500396493)

DRAKE, J. B. et al. Estimation of tropical forest structural characteristics using large-footprint lidar. **Remote Sensing of Environment**. V.79, p.305-319, 2002.

DUARTE, L. D. S.; DILLENBURG, L. R. Ecophysiological responses of *Araucaria angustifolia* (Araucariaceae) seedlings to different irradiance levels. **Australian Journal of Botany**, v. 48, n. 4, p. 531–537, 2000.

DUNCANSON, L. et al. Aboveground biomass density models for NASA's Global Ecosystem Dynamics Investigation (GEDI) lidar mission. **Remote Sensing of Environment**. V.270, n.112845, 2022.

DURIGAN, M. E. **Florística, dinâmica e análise protéica de uma Floresta Ombrófila Mista em São João do Triunfo – PR**. 125f. Dissertação (Mestrado em Engenharia Florestal) – Universidade Federal do Paraná, Curitiba, 1999.

ENE, L. T.; NÆSSET, E.; GOBAKKEN, T.; MAUYA, E. W.; BOLLANDSAS, O. M.; GREGOIRE, T. G.; STÅHL, G.; ZAHABU, E. Large-scale estimation of aboveground biomass in miombo woodlands using airborne laser scanning and national forest inventory data. **Remote Sensing of Environment**, v. 186, p. 626–636, 2016.

ENRIGHT, N. J. The ecology of Araucaria species in New Guinea. II. Pattern in the distribution of young and mature individuals and light requirements of seedlings. **Australian Journal of Ecology**, v. 7, n. 1, p. 39–48, 1982.

FALAGAS, M. E. et al. Comparison of PubMed, Scopus, Web of Science, and Google Scholar: strengths and weaknesses. **The FASEB Journal**, v. 22, n. 2, p. 338–342, 2008.

FERNANDEZ-LANDA, A. et al. High resolution biomass mapping in tropical forests with LiDAR-derived Digital Models: Poás Volcano National Park (Costa Rica). **IForest**. V.10, p.259-266, 2017.

FERRAZ, A.; SAATCHI, S.; MALLET, C.; JACQUEMOUD, S.; GONÇALVES, G.; SILVA, C. A.; SOARES, P.; TOMÉ, M.; PEREIRA, L. Airborne Lidar Estimation of Aboveground Forest Biomass in the Absence of Field Inventory. **Remote Sensing**, v8, n. 8, p. 653, 2016. DOI: 10.3390/rs808065.

Ferreira, M. P.; Grondona, A. E. B.; Rolim, S. B. A.; Shimabukuroa, Y. E. Analyzing the spectral variability of tropical tree species using hyperspectral feature selection and leaf optical modeling. **Journal of Applied Remote Sensing** 073502-1 Vol. 7, 2013.

FERREIRA, M. P. et al. Mapping tree species in tropical seasonal semi-deciduous forests with hyperspectral and multispectral data. **Remote Sensing of Environment**. V.179, p.66-78, 2016.

FERREIRA, M. P. **Detecção de espécies arbóreas em floresta estacional semidecidual por sensoriamento remoto hiperespectral e modelagem de transferência radiativa**. 2017. 150 f. Tese (Doutorado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2017.

FIGUEIREDO, E. O.; d'OLIVEIRA, M. V. N.; BRAZ, E. M.; PAPA, D. A.; FEARNSIDE, P. M. LIDAR-based estimation of bole biomass for precision management of na Amazonian forest: Comparisons of ground-based and remotely sensed estimates. **Remote Sensing of Environment**. N. 187, p. 281-298. 2016.

FLORENZANO, T. G. **Imagens de satélite para estudos ambientais**. 3ed. São Paulo: Oficina de Textos, 2011.

FOODYA, G. M.; BOYDB, D. S.; CUTLER, E. J. M. Predictive relations of tropical forest biomass from Landsat TM data and their transferability between regions. **Remote Sensing of Environment**, v.85, p. 463–474, 2003. DOI:10.1016/S0034-4257(03)00039-7.

FORMAGGIO, A. R.; SANCHES, I. D. **Sensoriamento remoto em agricultura**. São Paulo: Oficina de textos. 285p. 2017.

FORSSTROM, P. R.; HOVI, A.; GHIEMMETTI, G.; SCHAEPMAN, M. E.; RAUTIAINEN, M. Multi-angular reflectance spectra of small single trees. **Remote Sensing of Environment**, v 255, n. 112302 , 2021.

Fundação SOS Mata Atlântica; INPE. **Atlas dos remanescentes florestais da Mata Atlântica: período 2019/2020**, relatório técnico. São Paulo: Fundação SOS Mata Atlântica. 73p. 2021.

GALLIA, M.; SARTO, J. E. D.; BONGIOVANNI, G. A. Sustainable and efficient protocols for in vitro germination and antioxidants production from seeds of the endangered species *Araucaria araucana*. **Journal of Genetic Engineering and Biotechnology**. v.19, n.181, 2021.

GALVÃO, L.S.; BREUNIG, F. M.; SANTOS, J.R.; MOURA, Y. M. View-illumination effects on hyperspectral vegetation indices in the Amazonian tropical forest. **International Journal of Applied Earth Observation and Geoinformation**, v. 21, p. 291-300, 2013.

GAMON, J. A.; SERRANO, L.; SURFUS, J. S. The photochemical reflectance index: an optical indicator of photosynthetic radiation use efficiency across species, functional types, and nutrient levels. **Oecologia**, v. 112, p. 492-501, 1997.

GAMON, J. A.; SURFUS, J. S. Assessing leaf pigment content and activity with a reflectometer. **New Phytol.** V.143, p.105–117. 1999.

GAO, B. NDWI—A normalized difference water index for remote sensing of vegetation liquid water from space, *Remote Sensing of Environment*, Volume 58, Issue 3, 1996, Pages 257-266. 1996. [https://doi.org/10.1016/S0034-4257\(96\)00067-3](https://doi.org/10.1016/S0034-4257(96)00067-3).

GAO, L.; ZHANG, X. Above-Ground Biomass Estimation of Plantation with Complex Forest Stand Structure Using Multiple Features from Airborne Laser Scanning Point Cloud Data. **Forests**. V.12, n.1713. 2021. <https://doi.org/10.3390/f12121713>

GAO, L.; CHAI, G.; ZHANG, X. Above-Ground Biomass Estimation of Plantation with Different Tree Species Using Airborne LiDAR and Hyperspectral Data. **Remote Sens.** V.14, n. 2568. 2022. <https://doi.org/10.3390/rs14112568>

GARCIA, R.J.F. Araucariaceae. In WANDERLEY, M.G.L.; SHEPHERD, G.J.; GIULIETTI, A.M.; MELHEM, T.S.; BITTRICH, V. & KAMEYAMA, C. (eds.). *Flora Fanerogâmica do Estado de São Paulo*. vol.2. **FAPESP / Hucitec**, São Paulo, pp. 1-2. 2002.

GARCIA, M. L.; WATZLAWICK, L. F.; SILVA, R. A. R. Florística e dinâmica da biomassa em dois sistemas de manejo na Floresta Ombrófila Mista. **Scientia Forestalis**, v. 47, n. 124, p. 754–765, 2019.

GASTAUER, M.; NASCIMENTO JR, W. R.; CALDEIRA, C. F.; RAMOS, S. J.; FILHO, P. W. M. S.; F'ERET, J. B. Spectral diversity allows remote detection of the rehabilitation status in an Amazonian iron mining complex. **International Journal of Applied Earth Observations and Geoinformation**, v.106, n. 102653, 2022.

GIFFORD, R.M.. Carbon Content of Woody Roots: Revised Analysis and a Comparison with Woody Shoot Components. National Carbon Accounting System Technical Report No. 7 (Revision 1), **Australian Greenhouse Office**, Canberra. 2000a.

GIFFORD, R.M. Carbon contents of above-ground tissues of forest and woodland trees. National Carbon Accounting System Technical Report No. 22, **Australian Greenhouse Office**, Canberra. 2000b.

GIONGO, M. et al. LiDAR: princípios e aplicações florestais. **Pesquisa Florestal Brasileira**. V.30, n. 63, p. 231-244. 2010.

GITELSON, A. A.; MERZLYAK, M. N. Signature Analysis of Leaf Reflectance Spectra: Algorithm Development for Remote Sensing of Chlorophyll. **Plant Physiol**, v. 148, p. 494-500, 1996.

GITELSON, A. A.; MERZLYAK, M. N.; LICHTENTHALER, H.K.. Detection of Red Edge Position and Chlorophyll Content by Reflectance Measurements Near 700 nm. **Plant Physiol**, v. 148, p. 501-508, 1996.

GITELSON, A. A.; MERZLYAK, M. N.; CHIVKUNOVA, O. B. Optical Properties and Nondestructive Estimation of Anthocyanin Content in Plant Leaves. **American Society for Photobiology**, v. 74, p. 38–45 , 2001.

GITELSON, A. A.; MERZLYAK, M. N.; CHIVKUNOVA, O. B.; ZUR, Y. Assessing Carotenoid Content in Plant Leaves with Reflectance Spectroscopy. **Photochemistry and Photobiology**, v. 75(3), p. 272–281, 2002a.

GITELSON, A. A.; KAUFMANB, Y. J.; STARKC, R.; RUNDQUIST, D. Novel algorithms for remote estimation of vegetation fraction. **Remote Sensing of Environment**, v. 80, p. 76 – 87, 2002b.

GITELSON, A. A.; KEYDAN, G. P.; MERZLYAK, M. N. Three-band model for noninvasive estimation of chlorophyll, carotenoids, and anthocyanin contents in higher plant leaves. **GEOPHYSICAL RESEARCH LETTERS**, v. 33, 2006. DOI:10.1029/2006GL026457.

GITELSON, A.; SOLOVCHENKO, A. Noninvasive Quantification of Foliar Pigments: Principles and Implementations. In: THENKABAIL, P. S. et al. **Hyperspectral indices and image classifications for agriculture and vegetation**. Boca Raton: CRC Press. 2019.

GOETZ, A. Three decades of hyperspectral remote sensing of the Earth: a personal view. **Remote Sens. Environ.** V.113, S5–S16. 2009. <https://doi.org/10.1016/j.rse.2007.12.014>.

GONÇALVES, J. L. M. et al. An evaluation of minimum and intensive soil preparation regarding fertility and tree nutrition. In: GONÇALVES, J. L. M. e BENEDETTI, V. (eds.). **Forest nutrition and fertilization**. Piracicaba: IPEF, cap. 2, p. 13-64. 2004.

GRACE, P. R.; BASSO, B. Offsetting greenhouse gas emissions through biological carbon sequestration in North Eastern Australia. **Agricultural Systems**, v. 105, n. 1, p. 1–6, 2012. Elsevier Ltd. Disponível em: <<http://dx.doi.org/10.1016/j.agsy.2011.08.006>>. .

GUANGLONG, O.; LI, C.; YANYU L.; WEI, A.; XIONG, H.; XU, H.; WANG, G. Improving Aboveground Biomass Estimation of *Pinus densata* Forests in Yunnan Using Landsat 8 Imagery by Incorporating Age Dummy Variable and Method Comparison. **Remote Sens.**, v. 11, p. 738, 2019. DOI:10.3390/rs11070738.

GUOA, Q.; SUB, Y.; HUA, T.; ZHAOA, X.; WUA, F.; LIA, Y.; LIUA, J.; CHENA, L.; XUA, G.; LIND, G.; ZHENG D, Y.; LIND, Y.; MIA, X.; WANG, L. F. X. An integrated UAV-borne lidar system for 3D habitatmapping in three forest ecosystems across China. **INTERNATIONAL JOURNAL OF REMOTE SENSING**,v. 38, n. 8–10, p. 2954–2957, 2017. DOI:org/10.1080/01431161.2017.1285083

HANEDA, L. E.; BRANCALION, P. H. S.; MOLIN, P. G.; FERREIRA, M. P; SILVA, C. A.; ALMEIDA, C. T.; RESENDE, A. F.; SANTORO, G. B.; ROSA, M.; GUILLEMOT, J.; LE MAIRE, G.; FERET, J. B.; ALMEIDA, D. R. A. Forest landscape restoration: Spectral behavior and diversity of tropical tree cover classes. **Remote Sensing Applications: Society and Environment**, v. 29, n. 100882, 2023.

HANSEN, E.H.; GOBAKKEN, T.; BOLLANDSÅS, O.M.; ZAHABU, E.; NÆSSET, E. Modeling Aboveground Biomass in Dense Tropical Submontane Rainforest Using Airborne Laser Scanner Data. **Remote Sensing**, v. 7, n. 1, p.788-807, 2015. DOI.org/10.3390/rs70100788.

HASMADI, I. M.; KAMARUZAMAN, J.; HIDAYAH, M. A. N. Analysis of crown spectral characteristic and tree species mapping of tropical forest using hyperspectral imaging. **Journal of Tropical Forest Science** v.22, n.1, p.67–73. 2010.

HEISKANEN, J. et al. Use of airborne lidar for estimating canopy gap fraction and leaf area index of tropical montane forests. **International Journal of Remote Sensing**. v. 36, n. 10, p. 2569 – 2583, 2015.

HERNANDO, A.; PUERTO L.; MOLA-YUDEGO, B.; MANZANERA, J. A.; GARCÍA-ABRIL, A.; MALTAMO M.; VALBUENA, R. Estimation of forest biomass components using airborne LiDAR and multispectral sensors. **iForest**, v. 12, p. 207-213, 2019. DOI: 10.3832/ifor2735-012.

HIGUCHI, P.; SILVA, A. C.; FERREIRA, T. S.; SOUZA, S. T.; GOMES, J. P.; SILVA, K. M.; SANTOS, K. F.; LINKE, C.; PAULINO, P. S. Influência de variáveis ambientais sobre o padrão estrutural e florístico do componente arbóreo, em um fragmento de floresta ombrófila mista montana em lages, SC. **Ciência Florestal**, Santa Maria, v. 22, n. 1, p. 79-90. 2012.

HORLER, D. N. H.; DOCKRAY, M; BARBER, J. The red edge of plant leaf reflectance, **International Journal of Remote Sensing**, v.4, n.2, p.273-288. 1983.

HOUGHTON, R. A. Balancing the Global Carbon Budget. **Annual Review of Earth and Planetary Sciences**. v.35, n.1, p.313-347. 2007.

HUNT, E. R.; ROCK, B. N. Detection of changes in leaf-water content using nearinfrared and middle-infrared reflectances. **Remote Sensing of Environment**, v. 30, n. 1, p. 43–54, 1989.

IAPAR - Instituto Agrônomo do Paraná. CAVIGLIONE, J. H.; KIIHL, L. R. B.; CARAMORI, P. H.; OLIVEIRA, D. **Cartas climáticas do Paraná**. Londrina : IAPAR, 2000. CD Londrina, PR. Cartas Climáticas. 2000.

ROUSE, W.; HAAS, R. H.; WELL, J. A.; DEERING, D. W. Monitoring vegetation systems in the great plains with erts. **Remote Sensingcenter**, Texas A&M hivemity, Colfegp Station, Texas. Paper A 20. 309-317.

HUDAK, A. T. et al. Quantifying aboveground forest carbono pools and fluxes from repeat LiDAR surveys. **Remote Sensing of Enironment**. V.123, p.25-40, 2012.

HUETE, A.; DIDAN, K.;MIURA, T.; RODRIGUEZ, E.P.; GAO, X.; FERREIRA, L. G. Overview of the radiometric and biophysical performance of the MODIS vegetation indices. **Remote Sensing of Environment**, v.83, p. 195 – 213, 2002.

IBGE. Instituto Brasileiro de Geografia e Estatística. Manual Técnico da Vegetação Brasileira. 2 ed. Resvista e ampliada. 2012. IGANCI, J.R.V.; DORNELES, M.P. Araucariaceae. in: **Flora e Funga do Brasil**. Jardim Botânico do Rio de Janeiro. Access: mar. 2022. Available: <<https://floradobrasil.jbrj.gov.br/FB33970>>. Acesso em: 31 mar. 2020

INKOTTE, J.; MAFRA, Á. L.; RIOS, P. D. Â.; BARETTA, D.; VIEIRA, H. C. Litter fall deposition in eucalyptus plantations and native forests in the highland and west regions of Santa Catarina, Southern Brazil. **Scientia Forestalis/Forest Sciences**, v. 43, n. 106, p. 261–270, 2015.

IPCC. **Good practice guidance for land use, land-use change and forestry**. Hayama: Institute for Global Environmental Strategies, 590 p. 2003.

International Union for Conservation of Nature and Natural Resources - IUCN. **The Red List of Threatened Species**. Access: mar. 2021. Available: <http://www.iucnredlist.org/>. 2018

JAAFAR, W. S. W. M.; WOODHOUSE, I. H.; SILVA, C. A.; OMAR, H.; HUDAK, A. T. Modelling individual tree aboveground biomass using discrete return lidar in lowland dipterocarp forest of malaysia. **Journal of Tropical Forest Science** 29(4): 465–484 (2017). <https://doi.org/10.26525/jtfs2017.29.4.465484>

JACON, A. D.; GALVÃO, L. S.; SANTOS, J. R.; SANO, E. E. Seasonal characterization and discrimination of savannah physiognomies in Brazil using hyperspectral metrics from Hyperion/EO-1, **International Journal of Remote Sensing**, 38:15, 4494-4516, 2017. DOI: 10.1080/01431161.2017.1320443

JACON, A. D.; GALVÃO, L. S.; DALAGNOL, R.; SANTOS, J. R. Aboveground biomass estimates over Brazilian savannas using hyperspectral metrics and machine learning models: experiences with Hyperion/EO-1, **GIScience & Remote Sensing**, 58:7, 1112-1129, 2021. DOI: 10.1080/15481603.2021.1969630

JAIN, R.; SINGH, M. K.; VANLALRUATI. Evaluation of foliage potted plants for Northern plains. **Indian Journal of Agricultural Sciences**, v. 89, n. 10, p. 1638–1642, 2019.

JENSEN, J. R. **Sensoriamento Remoto do Ambiente: uma perspectiva em recursos terrestres**. Tradução de: EPIPHANIO, J. C. N. (coordenador)... [et al.]. 2ed. São José dos Campos, SP: Parêntese, 2011. Original em inglês.

JENSEN, J. R. **Introductory digital image processing : a remote sensing perspective**. Glenview: Pearson Education. 659p. 2015.

JI, C.; MA, F.; WANG, J.; SUN, W. Early Identification of Abnormal Deviations in Nonstationary Processes by Removing Non-Stationarity. In: YAMASHITA, Y.; KANO, M. **Computer Aided Chemical Engineering**. Elsevier. v. 49. 2022. pp. 1393-1398. <https://doi.org/10.1016/B978-0-323-85159-6.50232-3>.

JORDAN, C. F. Derivation of Leaf-Area Index from Quality of Light on the Forest Floor. **Ecological Society of America**, v. 50, n. 4, p. 663-666, 1969.

JUOLA, J.; HOVI, A.; RAUTIAINEN, M. A spectral analysis of stem bark for boreal and temperate tree species. **Ecology and Evolution**, 2022. DOI: 10.1002/ece3.8718

KAIGUANG, Z.; POPESCU, S.; NELSON, R. Lidar remote sensing of forest biomass: A scale-invariant estimation approach using airborne lasers. **Remote Sensing of Environment**, v. 113, n. 1, p. 182-196, 2009. DOI: 10.1016/j.rse.2008.09.009.

KALACSKA, M.; AZOFEIFA, G. A. S.; RIVARD, B.; T. CAELLI, T.; WHITE, H. P.; ALVARADO, J. C. C. Ecological fingerprinting of ecosystem succession: Estimating secondary tropical dry forest structure and diversity using imaging spectroscopy. **Remote Sensing of Environment**, v. 108, p. 82-96, 2007.

KAMARUZAMAN, J.; MALEK, M. Y. New approaches in estimating rubberwood standing timber volume using airborne hyperspectral sensing. **Journal of Modern Applied Science** 3: 62-70. 2009.

KEYVANPOUR, M. R.; SHIRZAD, M. B. Chapter 14 - Machine learning techniques for agricultural image recognition. In: Khan, M. A.; Khan, R.; Ansari, M. A. **Application of Machine Learning in Agriculture**. Academic Press. 2022. pp. 283-305. <https://doi.org/10.1016/B978-0-323-90550-3.00011-4>.

KHUDZARI, J. M. et al. Bibliometric analysis of global research trends on microbial fuel cells using Scopus database. **Biochemical Engineering Journal**, v. 136, p. 51-60, 2018.

KIM, M. S. **The use of narrow spectral bands for improving remote Sensing estimations of fractionally absorbed Photosynthetically active radiation**. Thesis submitted to the Faculty of the Graduate School of The University of Maryland in partial fulfillment of the requirements for the degree of Advisory Committee: Master of Arts, 1994. 75f.

KUTCHARTT, E.; GAYOSO, J.; PIROTTI, F.; BUCAREY, Á.; GUERRA, J.; HERNÁNDEZ, J.; CORVALÁN, P.; DRÁPELA, K.; OLSON, M.; ZWANZIG, M. Aboveground tree biomass of *Araucaria araucana* in southern Chile: measurements and multi-objective optimization of biomass models. **iForest**, v. 14, p. 61-70, 2021. DOI: 10.3832/ifor3492-013.

LANTZ, B. **Machine Learning with R**. 2.ed. Birmingham, UK: Pack Publishing. 2015.

LASSALLE, G.; FERREIRA, M. P.; LA ROSA, L. E. C.; FILHO, C. R. S. Deep learning-based individual tree crown delineation in mangrove forests using very-high-resolution satellite imagery. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 189, p. 220–235, 2022.

LARY, D. J.; ALAVI, A. H.; GANDOMI, A. H.; WALKER, A. L. Machine learning in geosciences and remote sensing. **Geoscience Frontiers**. v. 7, n. 1, p. 3-10. 2016.

LATIFI, H.; FASSNACHT, F. E.; HARTIG, F.; BERGER, C.; HERNÁNDEZ, J.; CORVALÁN, P.; KOCH, B. Stratified aboveground forest biomass estimation by remote sensing data. **International Journal of Applied Earth Observation and Geoinformation**, v. 38, p. 229–241, 2015.

LAUBENFELS, D.J. Coniferales. **Flora Malesiana** v.10, p.419-442, 1988.

LAURIN, G. V.; PULETTI, N.; HAWTHORNE, W.; LIESENBERG, V.; CORONA, P.; PAPALE, D.; CHEN, Q.; VALENTINI, R. Discrimination of tropical forest types, dominant species, and mapping of functional guilds by hyperspectral and simulated multispectral Sentinel-2 data. **Remote Sensing of Environment**, v. 176, p. 163–176, 2016.

LAURIN, G. V.; QI CHEN, Q.; LINDSELL, J. A.; COOMES, D. A.; DEL FRATE, F.; GUERRIERO, L.; PIROTTI, F.; VALENTINI, R. Above ground biomass estimation in an African tropical forest with lidar and hyperspectral data. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 89, p. 49-58, 2014. DOI: 10.1016/j.isprsjprs.2014.01.001.

LEI, C. L.; JU, C. Y.; CAI, T. J.; JING, X.; WEI, X. H.; DI, X. Y. Estimating canopy closure density and above-ground tree biomass using partial least square methods in chinese boreal forests. **Journal of Forestry Research**, v. 23, p. 191–196, 2012.

LEITOLD, V. et al. Airborne lidar-based estimates of tropical forest structure in complex terrain: opportunities and trade-offs for REDD+. **Carbon Balance and Management**. v. 10, n. 3, 2015.

LI, M. et al. Forest biomass and carbon stock quantification using airborne lidar data: a case study over Huntington Wildlife Forest in the Adirondack Park. **Biogeosciences**. V.7, p.3143-3156, 2014.

LI, Q. et al. Mapping multi-layered mangroves from multispectral, hyperspectral and LiDAR data. **Remote Sensing of Environment**. V.258, n.112403, 2021.

LINGNER, D. V.; OLIVEIRA, Y. M. M.; ROSOT, N. C.; DLUGOSZ, F. L. Caracterização da estrutura e da dinâmica de um remanescente de Floresta com Araucária no Planalto Catarinense. **Pesq. Flor. bras.**, Colombo, n.55, p. 55-66, 2007.

LIPINSKI, E. T.; CORTE, A. P. D.; SANQUETTA, C. R.; et al. Dinâmica da biomassa e carbono arbóreo entre 1995-2012 em Floresta ombrófila mista Montana. **Floresta**, v. 47, n. 2, p. 197–206, 2017.

LIU, W.; LI, Q. An efficient elastic net with regression coefficients method for variable selection of spectrum data. **PloS one**. v.12. n.2. 2017. e0171122.

LONGHI, S. J. **A estrutura de uma floresta natural de *Araucaria angustifolia* (Bert.) O. Ktze, no sul do Brasil.** 81 f. Dissertação (Mestrado em Engenharia Florestal) – Setor de Ciências Agrárias, Universidade Federal do Paraná, Curitiba. 1980.

LONGHI, S.J. **Agrupamento e análise fitossociológica de comunidades florestais na sub-bacia hidrográfica do rio Passo Fundo-RS.** Curitiba, 1997. 198f. Tese (Doutorado em Ciências Florestais) – Setor de Ciências Agrárias, Universidade Federal do Paraná.

LU, D. et al. Aboveground forest biomass estimation with Landsat and LiDAR data and uncertainty analysis of the estimates. **International Journal of Forestry Research**, v.2012, 16 p., 2012.

LU, X.; GUO, Q.; LI, W.; FLANAGAN, J. A bottom-up approach to segment individual deciduous trees using leaf-off lidar point cloud data. **ISPRS Journal of Photogrammetry and Remote Sensing**. V.94, p. 1-12. 2014.

LUCAS, M. R.; LEE, A. C.; BUNTING, P. J. Retrieving forest biomass through integration of CASI and LiDAR data. **International Journal of Remote Sensing**, v. 29, n. 5, p. 1553–1577, 2008. DOI: 10.1080/01431160701736497.

LUSK, C. H.; FALSTER, D. S.; PÉREZ-MILLAQUEO, M.; SALDAÑA, A. Ontogenetic variation in light interception, self-shading and biomass distribution of seedlings of the conifer *Araucaria araucana* (Molina) K. Koch. **Revista Chilena de Historia Natural**, v. 79, n. 3, p. 321–328, 2006.

MA, N.; SUN, L.; ZHOU, C.; HE, Y. Cloud Detection Algorithm for Multi-Satellite Remote Sensing Imagery Based on a Spectral Library and 1D Convolutional Neural Network. **Remote Sens.** 13, 3319. 2021. <https://doi.org/10.3390/rs13163319>

MAACK, R. **Geografia física do Estado do Paraná.** Curitiba: José Olympio, 1968, 438 p.

MAESANO M.; SANTOPUOLI G.; MORESI, F.V.; MATTEUCCI G.; LASSERRE B.; MUGNOZZA G. S. Above ground biomass estimation from UAV high resolution RGB images and LiDAR data in a pine forest in Southern Italy. **iForest**, v. 15, p. 451-457, 2022. DOI: 10.3832/ifor3781-015.

MAGURRAN, A. E. **Medindo a diversidade biológica.** Tradução: VIANNA, D. M. Curitiba: Ed. UFPR, 261p. 2013.

MALTAMO, M.; NAESSET, E.; VAUHKONEN. **Forestry Applications of Airborne Laser Scanning: Concepts and Case Studies.** London: Springer. 2014.

MARCHESAN, J. et al. Aboveground biomass estimation in a tropical forest with selective logging using random forest and lidar data. **Floresta**. V.50, n.4, p.1873-1882, out-dez, 2020.

MARTINELLI, L. A.; MOREIRA, M. Z.; BROWN, I. F.; VICTORIA, R. L. Incertezas associadas às estimativas de biomassa em florestas tropicais. In: SEMINÁRIO EMISSÃO X SEQUESTRO DE CO₂ – UMA NOVA OPORTUNIDADE DE NEGÓCIOS PARA O BRASIL. 1994. Rio De Janeiro. **Anais...** Rio de Janeiro: CURD, 1994, p. 197-221.

MCGAUGHEY, R. J. **FUSION/LDV: Software for LIDAR Data Analysis and Visualization**. Washington D. C: USDA Forest Service. 2016.

MEDEIROS, F. A. **Desenvolvimento de um Veículo Aéreo Não Tripulado para aplicação em agricultura de precisão**. 2007. 122 f. Dissertação (Mestrado em Engenharia Agrícola) – Universidade Federal de Santa Maria, Santa Maria, 2007.

MERTON, R. Monitoring Community Hysteresis Using Spectral Shift Analysis and the Red-Edge Vegetation Stress Index. **Department of Geography**. Auckland. 10p. 1998.

MERZLYAK, M. N.; GITELSON, A. A.; CHIVKUNOVA, O. B.; RAKITIN, V. Y. Non-destructive optical detection of pigment changes during leaf senescence and fruit ripening. **PHYSIOLOGIA PLANTARUM**, v. 106, p. 135–141, 1999.

MEYER, V. et al. Detecting tropical forest biomass dynamics from repeated airborne lidar measurements. **Biogeosciences**. V.10, p.5421-5438, 2013.

MONTAÑO, R. A. N. R. **Aplicação de Técnicas de Aprendizado de Máquina na Mensuração Florestal**. Universidade Federal do Paraná. Tese de Doutorado. Programa de Pós-Graduação em Informática. Curitiba, PR, 102 f. 2016.

MOURA, Y. M.; GALVÃO, L. S.; HILKER, T.; WU, J.; SALESKA, S.; AMARAL, C. H.; NELSON, B. W.; LOPES, A. P.; WIEDEMAN, K. K.; PROHASKA, N.; OLIVEIRA, R. C.; MACHADO, C. B.; ARAGÃO, L. E. O. C. Spectral analysis of amazon canopy phenology during the dry season using a tower hyperspectral camera and modis observations. **ISPRS Journal of Photogrammetry and Remote Sensing** 131, 52–64. 2017.

MUNYATI, C.; ECONOMON, E. B.; MALAHLELA, O. E. Effect of canopy cover and canopy background variables on spectral profiles of savanna rangeland bush encroachment species based on selected *Acacia* species (*mellifera*, *tortilis*, *karroo*) and *Dichrostachys cinerea* at Mokopane, South Africa. **Journal of Arid Environments**, v. 94, p. 121-126, 2013.

MUSTHAFA, M.; SINGH, G. Forest above-ground woody biomass estimation using multi-temporal space-borne LiDAR data in a managed forest at Haldwani, India. **Advances in Space Research**. 2022.

NAVARRO-CERRILLO, R. M.; DUQUE-LAZO, J.; RODRÍGUEZ-VALLEJO, C.; VARO-MARTÍNEZ, M. Á.; PALACIOS-RODRÍGUEZ, G. Airborne Laser Scanning Cartography of On-Site Carbon Stocks as a Basis for the Silviculture of *Pinus Halepensis* Plantations. **Remote Sensing**. 10(10):1660. 2018. <https://doi.org/10.3390/rs10101660>

NEVALAINEN, O. et al. Individual Tree Detection and Classification with UAV-based Photogrammetric Point Clouds and Hyperspectral Imaging. **Remote Sensing**. v.9, n.185, 2017.

OKUJENI, A.; JANICKE, C.; COOPER, S.; FRANTZ, D.; HOSTERT, P.; CLARK, M.; SEGL, K.; LINDEN, S. van der. Multi-season unmixing of vegetation class fractions across diverse Californian ecoregions using simulated spaceborne imaging spectroscopy data. **Remote Sensing of Environment**, v. 264, n. 112558, 2021.

OLIVEIRA-FILHO, A. T.; BUDKE, J. C.; JARENKOW, J. A.; EISENLOHR, P. V.; NEVES, D. R. M. Delving into the variations in tree species composition and richness across South American subtropical Atlantic and Pampean forests. **Journal of Plant Ecology**. Volume 8, Number 3, Pages 242–260 June 2015 doi:10.1093/jpe/rtt058

ORELLANA, E.; FILHO, A. F.; NETTO, S. P.; VANCLAY, J. K. A distance-independent individual-tree growth model to simulate management regimes in native Araucaria forests. **Journal of Forest Research**, v. 22, n. 1, p. 30–35, 2017. Taylor & Francis. Disponível em: <<http://dx.doi.org/10.1080/13416979.2016.1258961>>. .

ORELLANA, E.; VANCLAY, J. K. Competition and dominance between angiosperms and Araucaria angustifolia (Bert.) O. Kuntze in the Atlantic Forest in southern Brazil. **Forest Ecology and Management**, v. 425, n. March, p. 119–125, 2018. Elsevier. Disponível em: <<https://doi.org/10.1016/j.foreco.2018.05.022>>. .

ORIKIRIZA, L. J. B.; AGABA, H.; TWEHEYO, M.; et al. Amending soils with hydrogels increases the biomass of nine tree species under non-water stress conditions. **Clean - Soil, Air, Water**, v. 37, n. 8, p. 615–620, 2009.

PAL, M. Random forest classifier for remote sensing classification. **International Journal of Remote Sensing**. v. 26, n. 1, p. 217–222. 2005.

PAPÚ, S.; BERLI, F.; PICCOLI, P.; et al. Physiological, biochemical, and anatomical responses of Araucaria araucana seedlings to controlled water restriction. **Plant Physiology and Biochemistry**, v. 165, n. May, p. 47–56, 2021.

PEGORARO, A. J.; PHILIPS, J. W. Quadrirotores/Microdrone como Portadores de Geosensores aplicados ao Cadastro Territorial. In: XV Simpósio Brasileiro de Sensoriamento Remoto – SBSR. 2011, Curitiba. **Anais...** Instituto Nacional de Pesquisas Espaciais, 2011, p.8461.

PEÑUELAS, J.; FILELLA, I.; BARET, F. Semi-empirical indices to assess carotenoids/chlorophyll a ratio from leaf spectral reflectance. **Photosynthetica**, v. 31, n. 2, p. 221-230, 1995.

PEÑUELAS, J.; PINOL, J.; OGAYA, I. FILELLA. (1997): Estimation of plant water concentration by the reflectance Water Index WI (R900/R970). **International Journal of Remote Sensing**, v. 18, n. 13, p. 2869-2875, 1997.

PIROTTI, F.; KUTCHARTT, E.; CSAPLOVICS, E. Assessment of volume and above-ground biomass in araucaria Forest through satellite images, comparing different methods in The south of chile. **LAGIRS**. 2020.

PONZONI, F. J. et al. **Calibração absoluta de sensores orbitais: conceituação, principais procedimentos e aplicação**. São José dos Campos, SP: Parentese. 2007, 72p.

PONZONI, F. J.; SHIMABUKURO, Y. E. **Sensoriamento remoto no estudo da vegetação**. São José dos Campos: Parentese. 2009.

PONZONI, F. J.; GALVÃO, L. S.; LIESENBERG, V.; SANTOS, J.R. Impact of multi-angular CHRIS/PROBA data on their empirical relationships with tropical forest biomass. **International Journal of Remote Sensing**, v. 31, n. 19, p. 5257-5273, 2010.

PONZONI, F. J., Y. E. SHIMABUKURO, AND T. M. KUPLICH. **Sensoriamento Remoto Da Vegetação**. 2 ed. São Paulo: Oficina de Textos. 2012.

POPESCU, S. C. Estimating biomass of individual pine trees using airborne lidar. **Biomass & Bioenergy**, v. 31, p. 646–655. 2007.

POPESCU, S. C. et al. Satellite lidar vs. Small footprint airborne lidar: comparing the accuracy of aboveground biomass estimates and forest structure metrics at footprint level. **Remote Sensing of Environment**. V.115, p.2786-2797, 2011.

PRASAD, A. M.; IVERSON, L. R.; LIAW, A. Newer Classification and Regression Tree Techniques: Bagging and Random Forests for Ecological Prediction. **Ecosystems**. v. 9, n. 2, p. 181–199. 2006.

PRASAD, K. A. et al. Developing a spectral library of mangrove species of Indian east coast using field spectrascopy. **Geocarto International**. V.30, n.5, p.580-599, 2015.

QIAO, Y.; ZHENG, G.; DU, Z.; MA, X.; LI, J.; MOSKAL, L.M. Tree-Species Classification and Individual-Tree-Biomass Model Construction Based on Hyperspectral and LiDAR Data. **Remote Sens**. 15, 1341. 2023. <https://doi.org/10.3390/rs15051341>

RATUCHNE, L. C.; BRUSTOLIM, J. C.; KOEHLER, H. S.; WATZLAWICK, L. F.; SANQUETTA, C. R.; SCHAMNE, P. A. Quantificação de carbono florestal em povoamentos de *Araucaria angustifolia* no sudoeste do estado do Paraná. **Ambiência Guarapuava**, v.2, n.2, p. 321 - 335, 2015. DOI:10.5935/ambiencia.2015.02.04.

RAVINDRANATH, N. H.; OSTWALD, M. **Carbon Inventory Methods. Handbook for Greenhouse Gas Inventory, Carbon Mitigation and Roundwood Production Projects**. Advances in Global Change Research. Springer Science + Business Media B.V., 2008. 304 p.

REITZ, R; KLEIN, R. M.; REIS, A. **Wood project from Rio Grande do Sul, Herbário Barbosa Rodrigues**, Government of the State of Rio Grande do Sul, 1988, p. 525p.

REX, F. E.; CORTE, A. P. D.; DO AMARAL MACHADO, S.; SILVA, C. A.; SANQUETTA, C. R. Estimating above-ground biomass of *araucaria angustifolia* (Bertol.) Kuntze using LiDAR Data. **Floresta e Ambiente**, v. 26, n. 4, 2019.

REX, F. E. et al. Comparison of Statistical Modeling Approaches for Estimating Tropical Forest Aboveground Biomass Stock and Reporting Their Changes in Low-intensity Logging Areas Using Multi-temporal LiDAR data. **Remote Sensing**. v.12, n.1498, 2020.

ROBERTS, D. A. et al. Hyperspectral vegetation Indices. In: THENKABAIL, P. S. et al. **Hyperspectral indices and image classifications for agriculture and vegetation**. Boca Raton: CRC Press. 2019.

RODRIGUES, T. M.; RECH, T. D.; BALDISSERA, T. C.; PINTO, C. E.; GARAGORY, F. C.; BRAMD, M. A. Impact of weather conditions on the energetic quality of aciculated dry branches of *Araucaria angustifolia* (Bertol.) Kuntze produced throughout a year. **Floresta**, v.51, n.3, p.785-793, 2021.

ROIK, M.; FILHO, S. A. M. A. F.; SANQUETTA, C. R.; RUIZ, E. C. Z. Aboveground Biomass and Organic Carbon of Native *Araucaria Angustifolia*. **Forest Management**, v. 27, n. 3, 2020. DOI: [10.1590/2179-8087.010318](https://doi.org/10.1590/2179-8087.010318).

ROSENFELD, M. F.; SOUZA, A. F. Forest biomass variation in Southernmost Brazil: The impact of Araucaria trees. **Revista de Biologia Tropical**, v. 62, n. 1, p. 359–372, 2014.

ROSETTE, J. et al. Lidar Remote Sensing for Biomass Assessment. In: FATOYINBO, L. (Ed.) **Remote Sensing of Biomass – Principles and Applications**. Rijeka, Croatia: Intech. 2012. p. 322.

ROSSA, Ü. B. et al. Fertilizante de liberação lenta no crescimento de mudas de Araucaria angustifolia e Ocotea odorifera. **Floresta**, v. 41, n. 3, p. 491–500, 2011.

RUIZ, E. C. Z.; FIGUEIREDO FILHO, A.; BEHLING, A.; RETSLAFF GUIMARÃES, F. A.; DE ABREU NETO, R. Bioenergetic use of Araucaria angustifolia branches. **Biomass and Bioenergy**, v. 153, n. August, p. 1–6, 2021.

RUSSO, R. O. **Mediciones de biomassa em sistemas agroflorestales**. Turrialba: CATIE, 1983. 27 p.

SALATI, E. Sumário Executivo. In: EMISSÃO × sequestro de CO₂: uma nova oportunidade de negócios para o Brasil. Rio de Janeiro: **Anais...** p. 13-37, 1994.

SALUNKHE, O.; KHARE, P. K.; KUMARI, R.; KHAN, M. L. et al. A systematic review on the aboveground biomass and carbon stocks of Indian forest ecosystems. **Ecological Processes**, v. 7, n. 1, p. 1–12, 2018.

SANQUETTA, C. R. Métodos de determinação de biomassa florestal. In: SANQUETTA, C. R. et al. (Ed.). **As florestas e o carbono**. Curitiba, 2002. p.119- 140.

SANQUETTA, C. R.; WATZLAWICK, L. F.; SCHUMACHER, M. V.; MELLO, A. A. Relações individuais de biomassa e conteúdo de carbono em plantações de *Araucaria angustifolia* e *Pinus taeda* no sul do Estado do Paraná, Brasil. **Ciências agrárias e ambientais**, Curitiba, v.1, n.3, p. 33-40, 2003.

SANQUETTA, C. R.; MATTEI, E. **Perspectiva de Recuperação e manejo sustentável das Florestas de Araucária**. Curitiba: Multi-Graphic Gráfica e Editora, 2006. 264 p.

SANQUETTA, C. R.; WOJCIECHOWSKI, J.; CORTE, A. P. D.; RODRIGUES, A. L.; MAAS, G. C. B. On the use of data mining for estimating carbon storage in the trees. **Carbon Balance and Management**, v. 8, n. 1, p. 1–9, 2013.

SANQUETTA, C. R.; CORTE, A. P. D.; PINTO, C.; MELO, L. A. N. Biomass and carbon in non-woody vegetation, dead wood and litter in iguaçu national park. **Floresta**, v. 44, n. 2, p. 185–194, 2014.

SANQUETTA, C. R.; CORTE, A. P. D.; MOGNON, F.; MAAS, G. C. B.; RODRIGUES, A. L. Estimativa de carbono individual para *Araucaria angustifolia* **Pesq. Agropec. Trop.**, Goiânia, v. 44, n. 1, p. 1-8, 2014.

SANQUETTA, C. R., BASTOS, A. S.; FERRONATO, M. L.; SANQUETTA, M. N. I.; DALLA CORTE, A. P. Fatores de expansão e de conversão de biomassa e razão de raízes em povoamentos de restauração florestal em rondônia. **Enciclopédia Biosfera**. v.16, n.29, p.871. 2019.

SANTOS, J.R. **Biomassa aérea da vegetação de cerrado: estimativa e correlação com dados do sensor “Thematic Mapper” do satélite LANDSAT**. Curitiba, 1988. 156f. Tese (Doutorado em Ciências Florestais) – Setor de Ciências Agrárias, Universidade Federal do Paraná. 1988.

SATO, L. Y. et al. Post-Fire Changes in Forest Biomass Retrieved by Airborne LiDAR in Amazonia. **Remote Sens**. v. 8, n. 839, 2016.

SCHMITT, M.; ZHU, X. X. Data Fusion and Remote Sensing: An ever-growing relationship. **IEEE Geoscience and Remote Sensing Magazine**, v. 4, n. 4, p. 6-23, 2016. DOI: 10.1109/MGRS.2016.2561021.

SCHUH, M. S. et al. Machine learning and generalized linear model techniques to predict aboveground biomass in Amazon rainforest using LiDAR data. **Journal of Applied Remote Sensing**. v.14, n.3, 2020.

SCHUMACHER, M.V. et al. Produção de biomassa no corte raso em plantio de *Araucaria angustifolia* (Bertol.) Kuntze de 27 anos de idade em Quedas do Iguaçu, PR. **Ciência Florestal**, v.21, n.1, p.53-62, 2011.

SERRANO, L.; PEÑUELAS, J.; USTIN, S.L. Remote sensing of nitrogen and lignin in Mediterranean vegetation from AVIRIS data: Decomposing biochemical from structural signals, **Remote Sensing of Environment**, v. 81, n. 2, p. 355-364, 2002.

SEVEGNANI, L.; GASPER, A. L.; RODRIGUES, A. V.; LINGNER, D. V.; MEYER, L., UHLMANN, A.; OLIVEIRA, L. Z.; VIBRANS, A. Structure and diversity of the *Araucaria* forest in southern Brazil: biotic homogenisation hinders the recognition of floristic assemblages related to altitude. **Southern Forests: a Journal of Forest Science**, DOI: 10.2989/20702620.2019.1636193. 2019.

SHI, Y. et al. Tree species classification using plant functional traits from LiDAR and hyperspectral data. **Int J Appl Earth Obs Geoinformation**. V.73, p.207-219, 2018.

SHAO, Z.; ZHANG, L. Estimating Forest Aboveground Biomass by Combining Optical and SAR Data: A Case Study in Genhe, Inner Mongolia, China. **Sensors** , v. 16, p. 834, 2016. DOI: 10.3390/s16060834.

SINGH, M.; EVANS, D.; TAN, B. S.; NIN, C. S. Mapping and Characterizing Selected Canopy Tree Species at the Angkor World Heritage Site in Cambodia Using Aerial Data. **PLoS ONE**. 10(4): e0121558. 2015. doi:10.1371/journal.pone.0121558

SILVA, T. C. et al. Non-timber forest products in brazil: A bibliometric and a state of the art review. **Sustainability (Switzerland)**, v. 12, n. 17, 2020.

SILVEIRA, P.; KOEHLER, H. S.; SANQUETTA, C. R.; ARCE, J. E. O estado da arte na estimativa de biomassa e Carbono em formações florestais. **FLORESTA**, Curitiba, PR, v. 38, n. 1, 2008.

SMERECEK, R. et al. Determining basic forest stand characteristics using airborne laser scanning in mixed forest stands of Central Europe. **IForest**. V.11, p.181-188, 2018.

SOMOGYI, Z.; CIENCIALA, E.; MÄKIPÄÄ, R.; MUUKKONEN, P.; LEHTONEN, A.; WEISS, P. Indirect methods of large-scale forest biomass estimation. **European Journal of Forest Research**, v. 126, p. 197-207, 2006.

Sonobe, R.; Hirono, Y.; Oi, A. Quantifying chlorophyll-a and b content in tea leaves using hyperspectral reflectance and deep learning, **Remote Sensing Letters**, 11:10, 933-942, 2020. DOI: 10.1080/2150704X.2020.1795294

SOTHE, C.; DALPONTE, M.; ALMEIDA, C. M.; SCHIMALSKI, M. B.; LIMA, C. L.; LIESENBERG, V.; MIYOSHI, G. T.; TOMMASELLI, A. M. G. Tree Species Classification in a Highly Diverse Subtropical Forest Integrating UAV-Based Photogrammetric Point Cloud and Hyperspectral Data. **Remote Sens.**, v. 11, p. 1338, 2019. DOI:10.3390/rs11111338

SOTHE, C.; DE ALMEIDA, C. M.; SCHIMALSKI, M. B.; LA ROSA, L. E. C.; CASTRO, J. D.; FEITOSA, R. Q.; DALPONTE, M.; LIMA, C. L.; LIESENBERG, V.; MIYOSHI, G. T.; TOMMASELLI, A. M. G. Comparative performance of convolutional neural network, weighted and conventional support vector machine and random forest for classifying tree species using hyperspectral and photogrammetric data. **GIScience & Remote Sensing**, v.57:3, p. 369-394, 2020. DOI: 10.1080/15481603.2020.1712102.

SOUZA, A. A.; GALVÃO, L. S.; SANTOS, J. R. Relationships between Hyperion-derived vegetation indices, biophysical parameters, and elevation data in a Brazilian savannah environment. **Remote Sensing Letters**, v. 1:1, p. 55-6, 2010. DOI: 10.1080/01431160903329364.

SOUZA, A. F.; LONGHI, S. J. Disturbance history mediates climate change effects on subtropical forest biomass and dynamics. **Ecology and Evolution**, v. 9, n. 12, p. 7184–7199, 2019.

SOUZA, A. F. A review of the structure and dynamics of araucaria mixed forests in southern Brazil and northern Argentina, **New Zealand Journal of Botany**, 2020. DOI: 10.1080/0028825X.2020.1810712

SOUZA, D. V. **Aprendizado de máquina para predição de biomassa e volume comercial de árvores em florestas tropicais**. 2020. 172 f. Tese (Doutorado em Engenharia Florestal) – Universidade Federal do Paraná, Curitiba. 2020.

SWATANTRAN, A.; DUBAYAH, R.; ROBERTS, D.; HOFTON, M.; BLAIR, J. B. Mapping biomass and stress in the Sierra Nevada using lidar and hyperspectral data fusion. **Remote Sensing of Environment**, v. 115, n. 11, p. 2917-2930, 2011. DOI: 10.1016/j.rse.2010.08.027

TAHMASBIAN, I.; XU, Z.; ABDULLAH, K.; ZHOU, J.; ESMAEILANI, R.; NGUYEN, T. T. N.; BAI, S. H. The potential of hyperspectral images and partial least square regression for predicting total carbon, total nitrogen and their isotope composition in forest litterfall samples. **J Soils Sediments** DOI 10.1007/s11368-017-1751-z.

TEIXEIRA, L. M. **Influência da Intensidade de Exploração Seletiva de Madeira no Crescimento e Respiração do Tecido Lenhoso das Árvores em uma Floresta Tropical de Terra-Firme na Região de Manaus**. 2003. 61 f. Dissertação (Mestrado em Ciências de Florestas Tropicais) – Instituto Nacional de Pesquisas da Amazônia, Universidade Federal do Amazonas, Manaus, 2003. TSEGAY; MENG 2021

THANKABAIL, P. S. et al. Hyperespectral remote sensing of vegetation and agricultural crops. **Photogrammetric Engineering and Remote Sensing**. v.8, n.4, p.697-709, 2014.

TOJAL, L.-T.; BASTARRIKA, A.; BARRETT, B.; SANCHEZ ESPESO, J.M.; LOPEZ-GUEDE, J.M.; GRAÑA, M. Prediction of Aboveground Biomass from Low-Density LiDAR Data: Validation over *P. radiata* Data from a Region North of Spain. **Forests**, 10, 819. 2019. <https://doi.org/10.3390/f10090819>

TONIOL, A. C.; GALVÃO, L. S.; PONZONI, F. J.; SANO, E. E.; AMORE, D. A. de Jesus. Potential of hyperspectral metrics and classifiers for mapping Brazilian savannas in the rainy and dry seasons. **Remote Sensing Applications: Society and Environment**, v.8, p. 20–29, 2017.

TRIER, O. D. et al. Tree species classification in Norway from airborne hyperspectral and airborne laser scanning data. **European Journal of Remote Sensing**. v.51, n.1, p.336-351, 2018.

United Nations - UM. Após COP 18, ONU diz que mundo deve intensificar redução de CO2. **Perspectiva Global Reportagens Humanas**. Access: mar. 2022. Available: <https://news.un.org/pt/audio/2012/12/1050311>. 2012

VALBUENA, R.; HERNANDO, A.; MANZANERA, J. A.; GÖRGENS, E. B.; ALMEIDA, D. R. A.; MAURO, F.; GARCÍA-ABRIL, A.; COOMES, D. A. Enhancing of accuracy assessment for forest above-ground biomass estimates obtained from remote sensing via hypothesis testing and overfitting evaluation. **Ecological Modelling**, v. 366 , p. 15-26, 2017.

VAN DEN BERG, A. K.; PERKINS, T. D. Nondestructive Estimation of Anthocyanin Content in Autumn Sugar Maple Leaves. **Hort Science**. V.40, n.3, p.685-696. 2005.

VANGI, E.; D'AMICO, G.; FRANCINI, S.; GIANNETTI, F.; LASSERRE, B.; MARCHETTI, M.; CHIRICI, G. The New Hyperspectral Satellite PRISMA: Imagery for Forest Types Discrimination. **Sensors**. 21, 1182. 2021. <https://doi.org/10.3390/s21041182>

WAN-MOHD-JAAFAR, W. S.; WOODHOUSE, I. H.; SILVA, C. A.; OMAR, H.; HUDAK, A. T. Modelling individual tree aboveground biomass using discrete return Lidar in lowland

Dipterocarp forest of Malaysia. **Journal of Tropical Forest Science**, v. 29, n. 4, p. 465–484, 2017.

VELOSO, H. P.; RANGEL FILHO, A. L. R.; LIMA, J. C. A. **Classificação da vegetação brasileira, adaptada a um sistema universal**. Rio de Janeiro: IBGE, 1991. 124 p.

VOGELMANN, J. E.; ROCK, B. N.; MOSS, D. M. Red edge spectral measurements from sugar maple leaves, **International Journal of Remote Sensing**, 14:8, 1563-1575, 1993. DOI: 10.1080/01431169308953986

WATZLAWICK, L. F. **Estimativa de biomassa e carbono em floresta ombrófila mista e plantações florestais a partir de dados de imagens do satélite ikonos ii**. Tese. 2003. 138f.

WATZLAWICK, L. F.; SANQUETTA, C. R.; ARCE, J. E.; BALBINOT, R. Quantificação de biomassa total e carbono orgânico em povoamentos de Araucaria angustifolia (Bert.) O. Kuntze no sul do estado do Paraná, Brasil. **Revista Acadêmica: ciências agrárias e ambientais**, Curitiba, v.1, n.2, p.63-18. 2003.

WATZLAWICK, L. F.; KIRCHNER, F. F.; SANQUETA, C. R. Estimativa de biomassa e carbono em floresta com araucária utilizando imagens do satélite Ikonos II. **Ciência Florestal**. Santa Maria, v.19, n.2, p.169-181. 2009.

WATZLAWICK, L. F.; CALDEIRA, M. V. W.; VIERA, M.; et al. Estoque de biomassa e carbono na Floresta Ombrófila Mista Montana Paraná. **Scientia Forestalis/Forest Sciences**, v. 40, n. 95, p. 353–362, 2012.

WATZLAWICK, L. F.; MARTINS, P. J.; RODRIGUES, A. L.; et al. Carbon concentration in species of the Araucaria Forest and effect of the ecological group. **Cerne**, v. 20, n. 4, p. 613–620, 2014.

ZANETTE, V. H.; WATZLAWICK, L. F.; SILVA, R. A. R.; MAZON, J. A. Identidade de modelos para estimativa de biomassa aérea na Floresta Ombrófila Mista. **Scientia Forestalis**, v. 49(131), n. e3472, 2021. DOI: [10.18671/scifor.v49n131.09](https://doi.org/10.18671/scifor.v49n131.09).

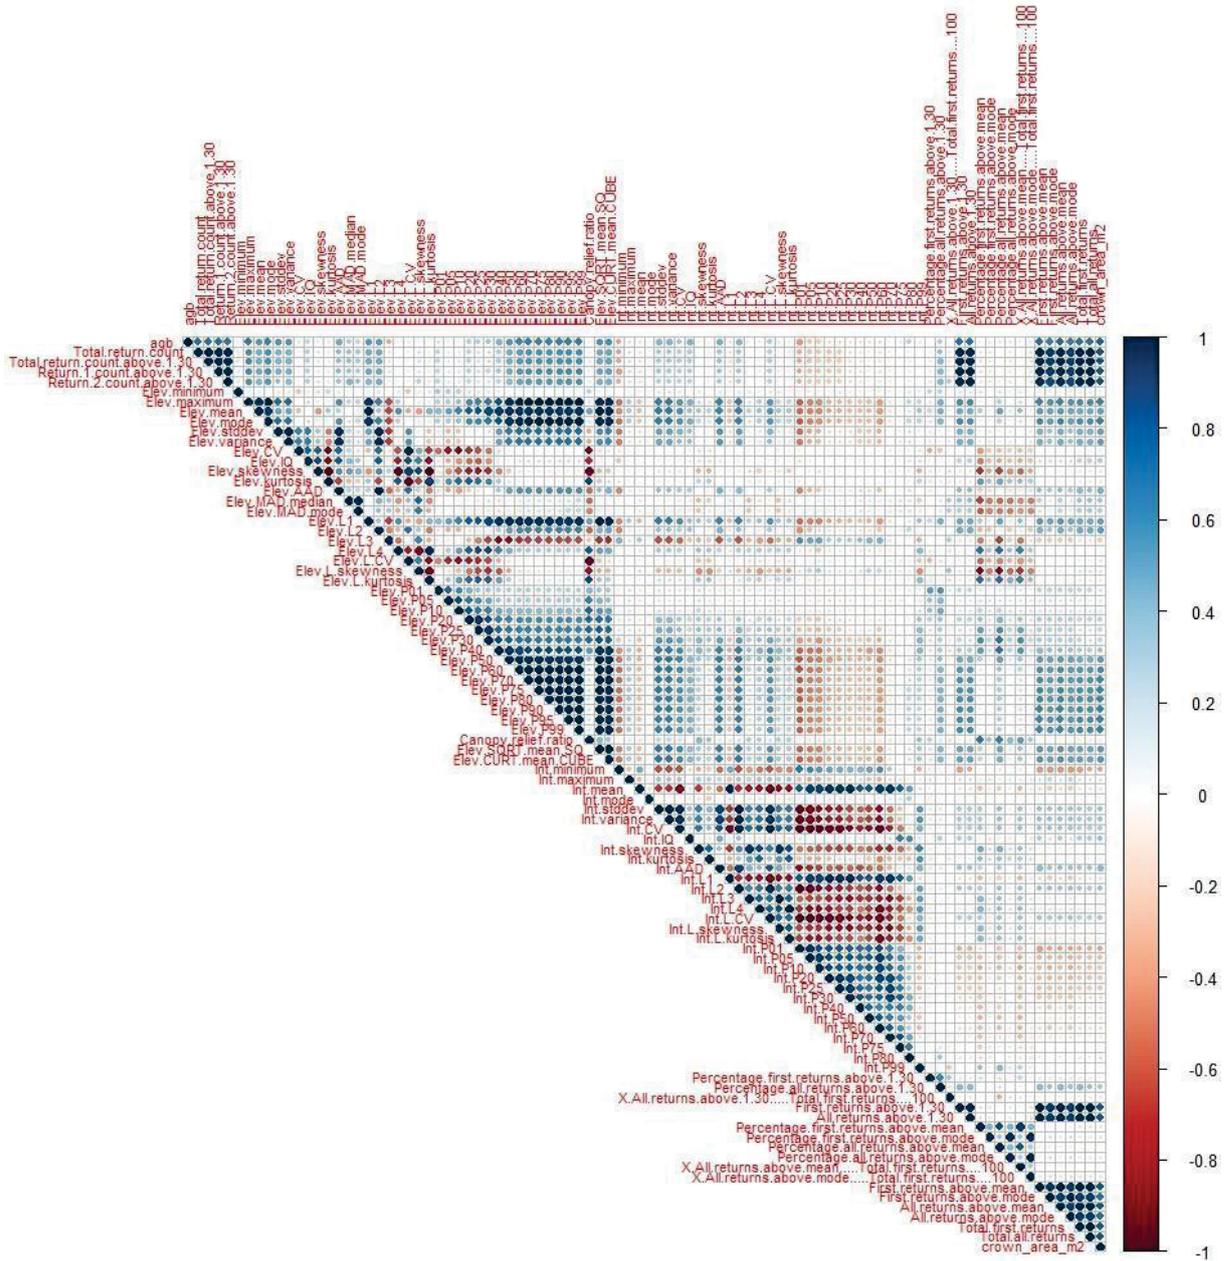
ZANOTTA, D. C.; FERREIRA, M. P.; ZORTEA, M. **Processamento de imagens de satélite**. São Paulo: Oficina de textos. 320p. 2019.

ZHANG, Z. et al. Object-based tree species classification in urban ecosystems using LiDAR and hyperspectral data. **Forests**. V.7, n.122, 2016.

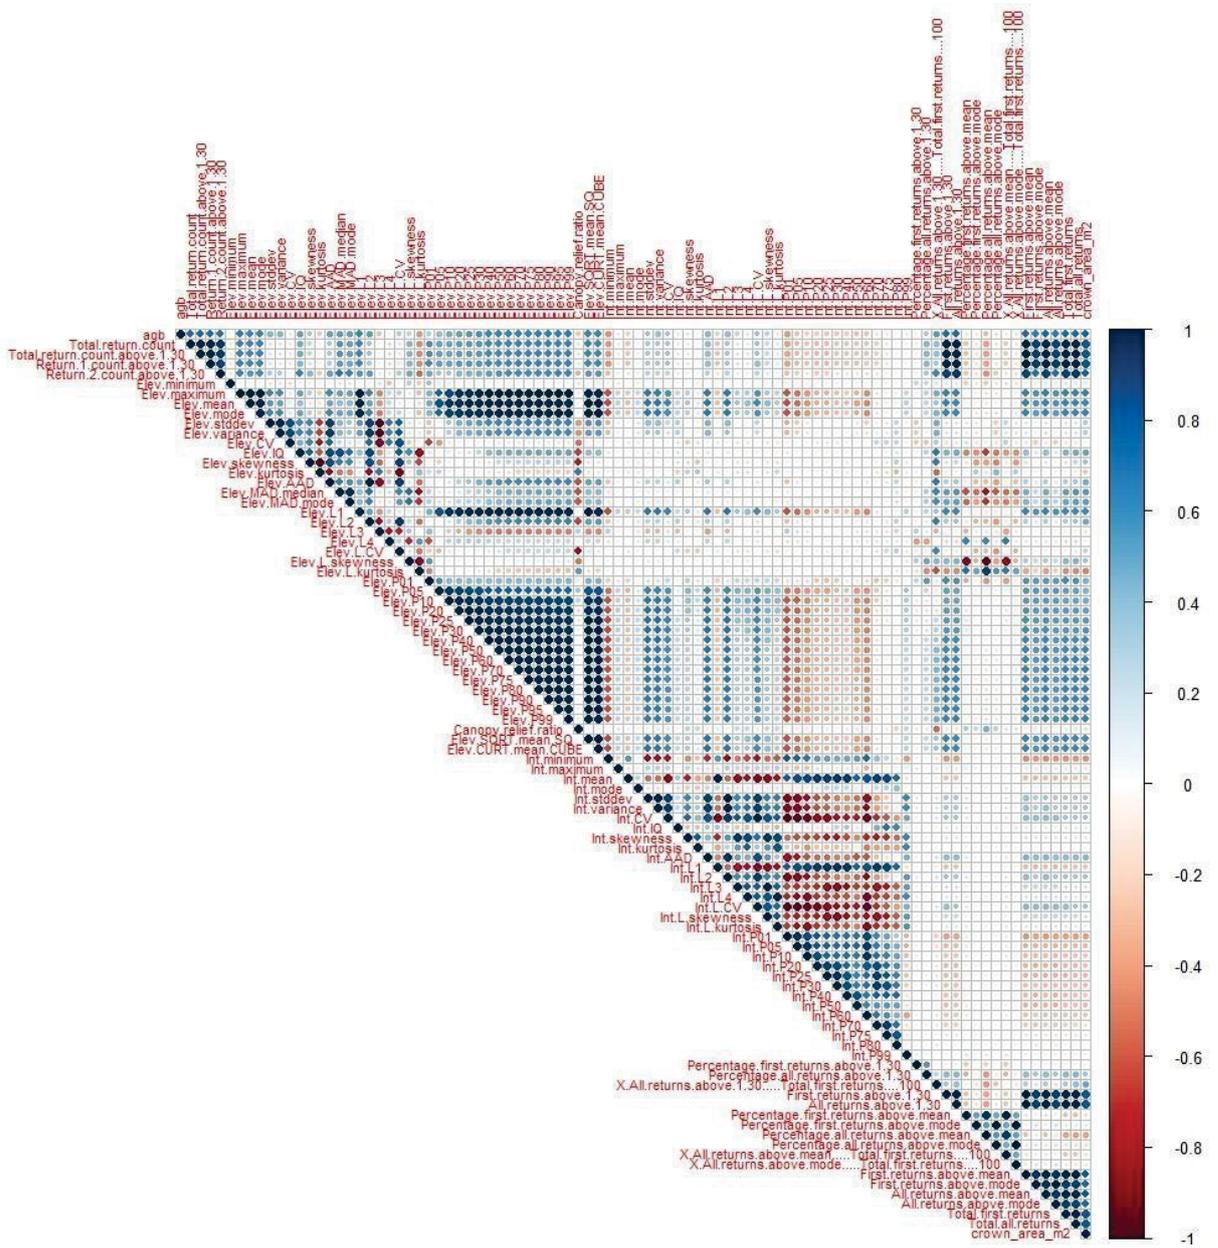
ZHAO, K.; POPESCU, S.; NELSON, R. Lidar remote sensing of forest biomass: A scaleinvariant estimation approach using airborne lasers. **Remote Sensing of Environment**. v. 133, p. 182–196, 2009.

ZHU, X.; LIU, D. Improving forest aboveground biomass estimation using seasonal Landsat NDVI time series. **ISPRS J Photogramm Remote Sens**. V.102, p.222-231, 2015.

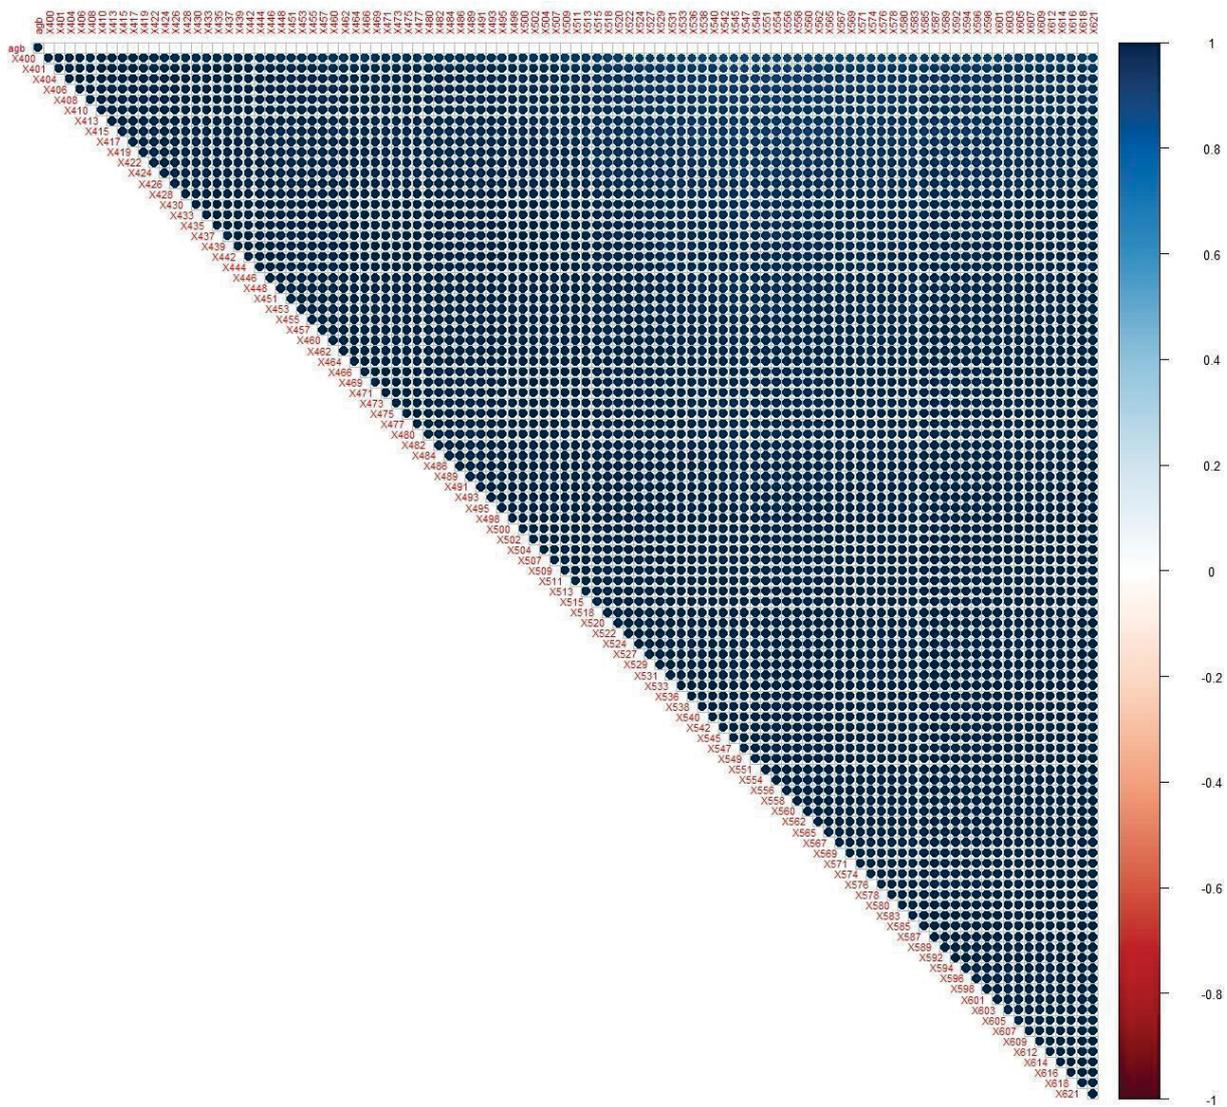
APÊNDICE 1 – CORRELOGRAMA COM MÉTODO DE PEARSON ENTRE A AGB E AS MÉTRICAS OBTIDAS A PARTIR NUVEM DE PONTOS LIDAR CONTENDO OS PONTOS DA ARAUCÁRIA E O SUB-BOSQUE (AS).



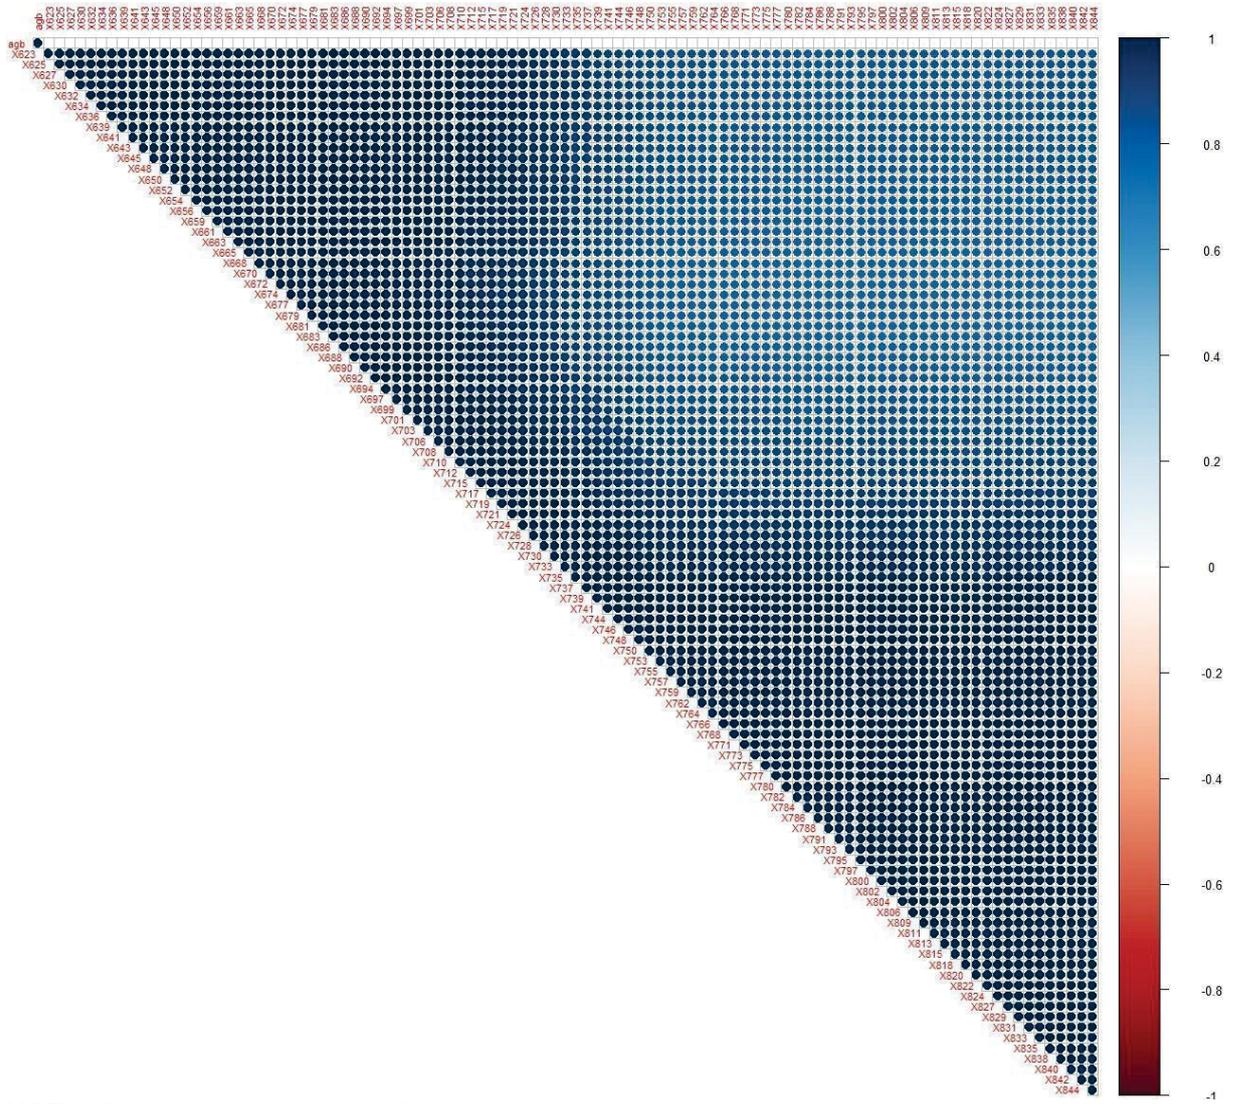
APÊNDICE 2 – CORRELOGRAMA COM MÉTODO DE PEARSON ENTRE A AGB E AS MÉTRICAS OBTIDAS A PARTIR DA NUVEM DE PONTOS LIDAR CONTENDO APENAS OS PONTOS DA ARAUCÁRIA (AA).



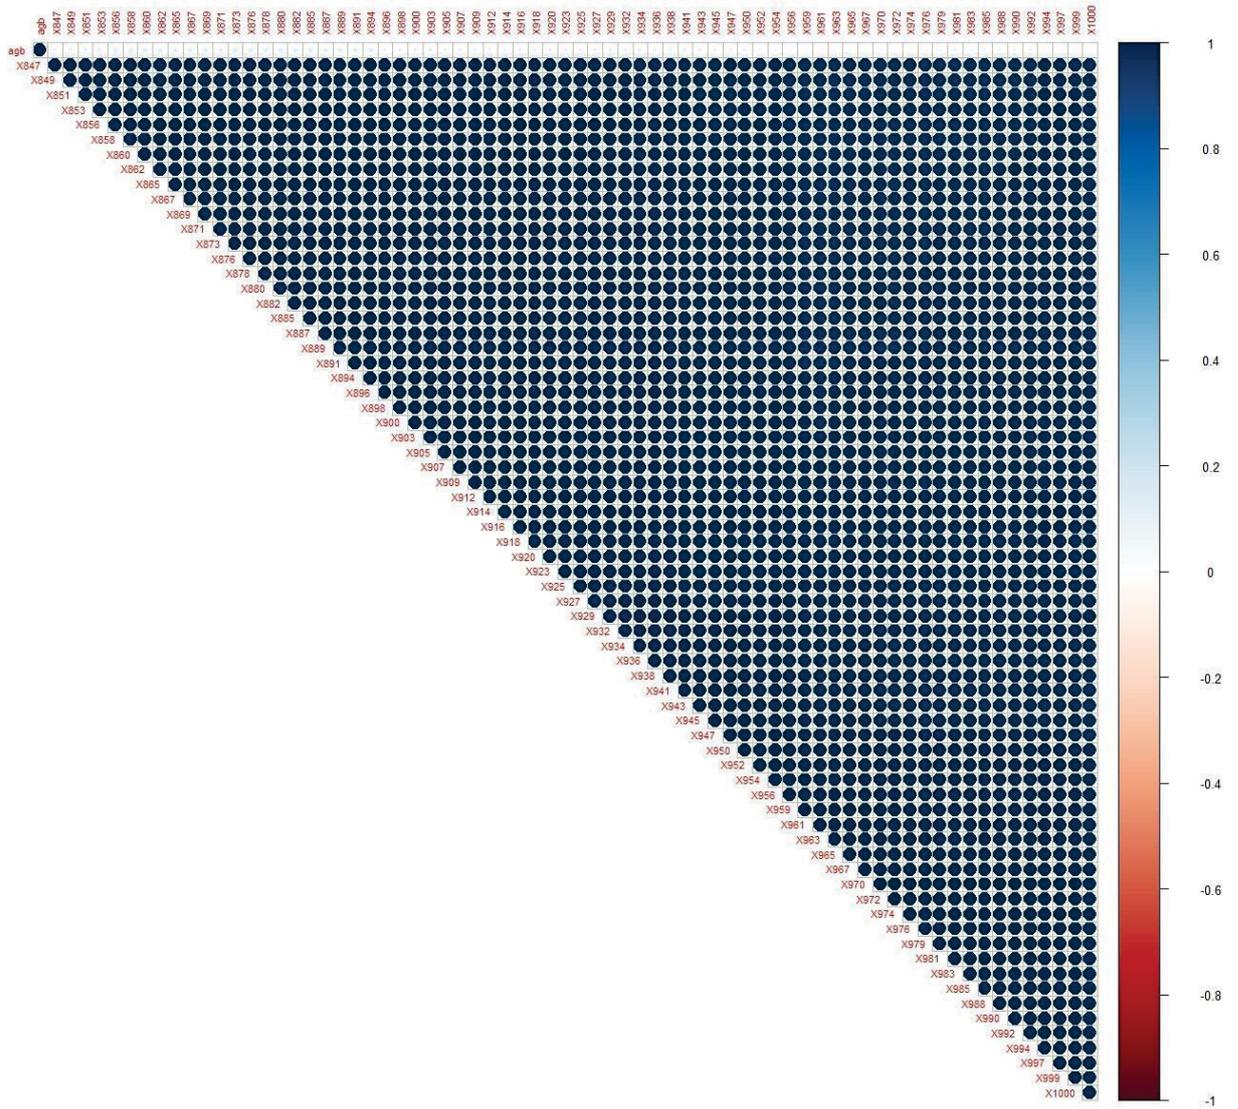
**APÊNDICE 3 – CORRELOGRAMA COM MÉTODO DE PEARSON ENTRE A AGB
E AS BANDAS ESPECTRAIS DO SENSOR HIPERESPECTRAL COM AS
REFLECTÂNCIAS OBTIDAS DE TODOS OS PIXELS.**



NOTA: Comprimentos de onda de 400 a 621 nm.

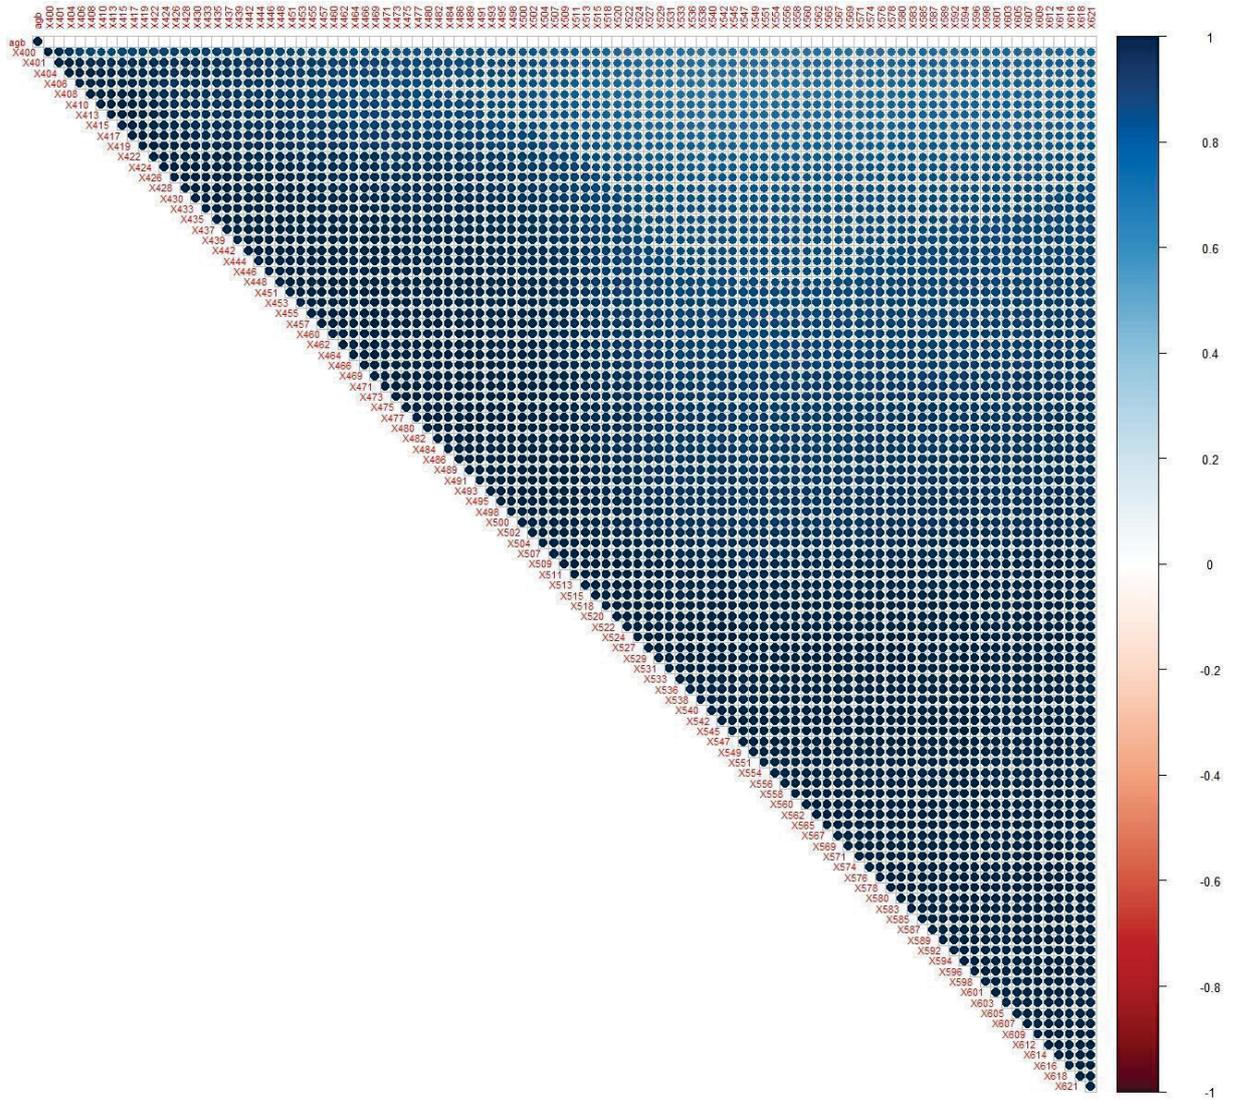


NOTA: Comprimentos de onda de 623 a 844 nm.

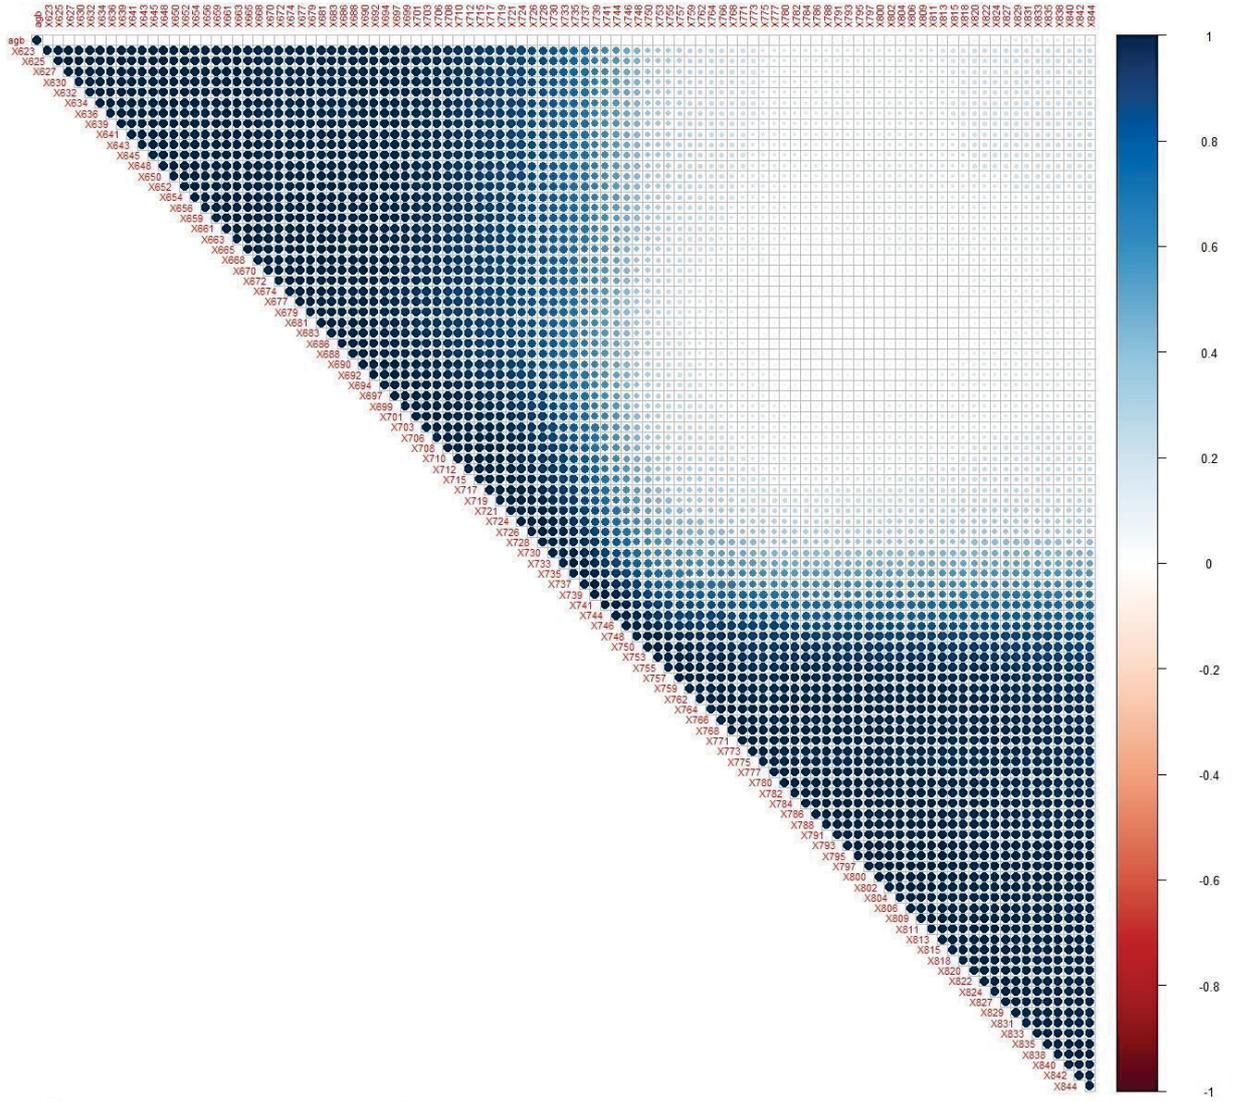


NOTA: Comprimentos de onda de 847 a 1.000 nm.

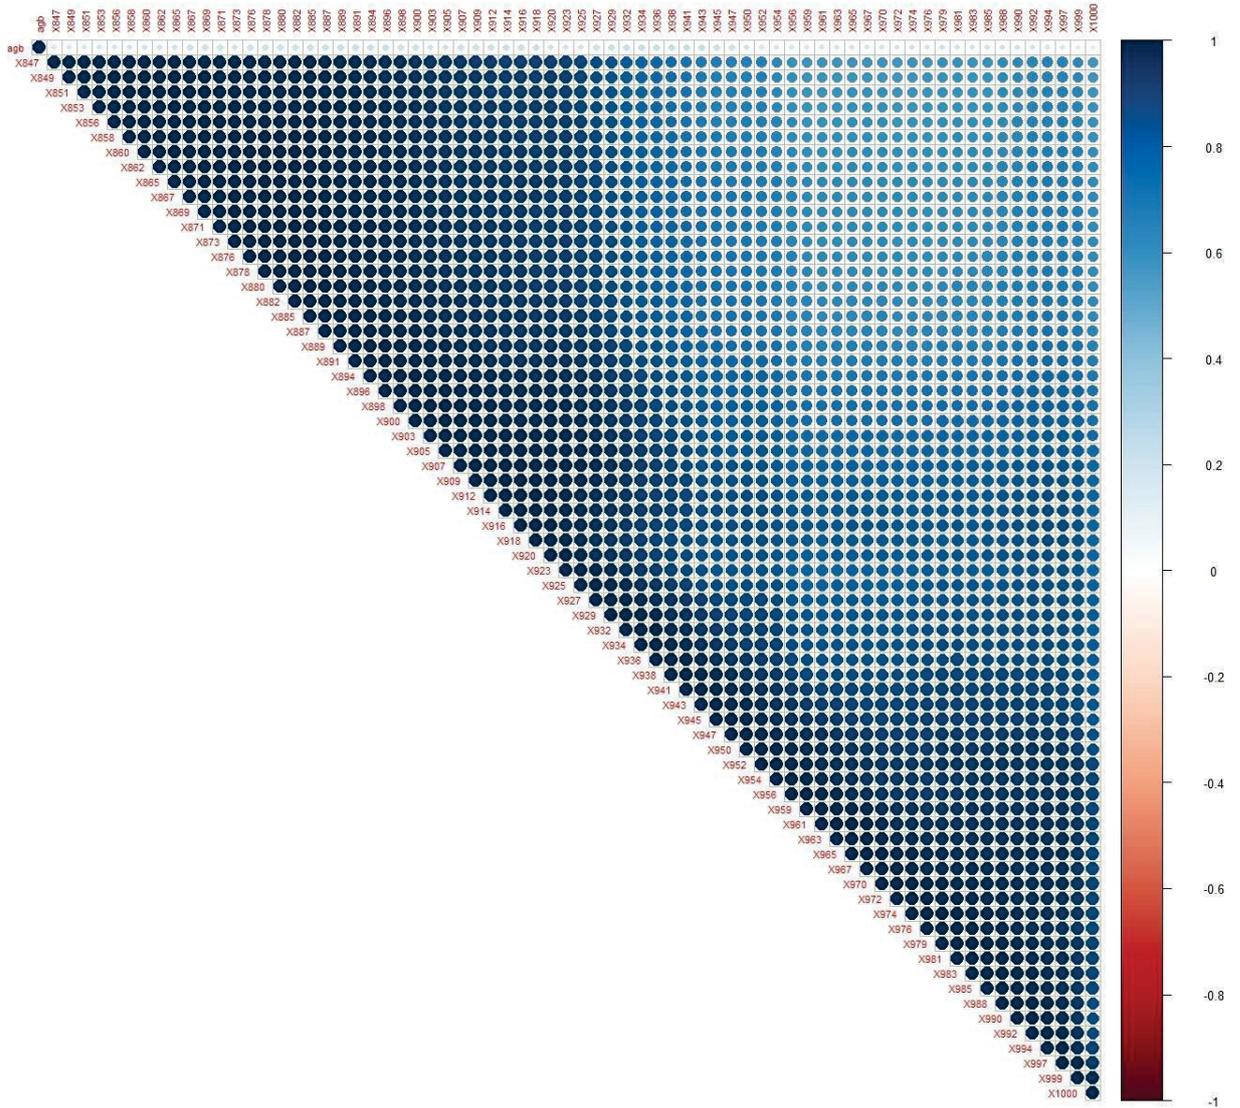
**APÊNDICE 4 – CORRELOGRAMA COM MÉTODO DE PEARSON ENTRE A AGB
E AS BANDAS ESPECTRAIS DO SENSOR HIPERESPECTRAL COM AS
REFLECTÂNCIAS OBTIDAS APENAS DOS PIXELS ILUMINADOS (SUNLIT).**



NOTA: Comprimentos de onda de 400 a 621 nm.



NOTA: Comprimentos de onda de 623 a 844 nm.



NOTA: Comprimentos de onda de 847 a 1.000 nm.

**ANEXO 1 – DADOS DE BIOMASSA ACIMA DO SOLO PARA A ESPÉCIE
ARAUCARIA ANGUSTIFOLIA, ADAPTADO DE WATZLAWICK (2002).**

N	BIOMASSA							
	DAP (cm)	Ht (m)	Fuste (Kg)	Casca (Kg)	Galho Vivo (Kg)	Galho Morto (Kg)	Folhagem (Kg)	Total (Kg)
1	17.70	11.10	59.31	23.90	13.16	5.24	4.49	106.10
2	14.51	12.70	23.22	11.43	13.73	17.62	10.87	76.87
3	41.70	15.70	407.16	279.42	125.72	0.00	57.53	869.83
4	49.56	20.70	703.86	421.33	137.14	7.56	65.70	1335.59
5	24.99	12.77	144.28	38.23	2.04	1.16	2.34	188.05
6	30.56	17.35	131.14	114.57	63.12	7.70	30.54	347.07
7	25.15	15.90	110.28	67.73	30.27	4.01	10.05	222.34
8	47.68	17.95	373.11	288.42	119.85	3.51	38.17	823.06
9	34.06	19.45	271.13	146.60	96.02	4.47	64.49	582.71
10	30.56	21.00	277.07	98.00	77.15	3.22	28.30	483.74
11	32.15	21.52	258.80	112.76	195.70	7.13	34.60	608.99
12	62.07	20.24	1179.83	486.33	608.86	34.42	165.01	2474.45
13	105.68	30.10	3007.56	2119.79	676.24	13.88	86.62	5904.09
14	20.21	14.40	53.62	27.76	33.26	2.16	19.79	136.59
15	33.74	17.60	194.43	73.63	152.31	2.66	49.89	472.92
16	27.34	18.00	141.50	63.55	45.14	6.06	3.09	259.34
17	28.49	17.65	187.35	80.56	41.07	6.90	4.05	319.93
18	29.70	19.45	160.61	85.47	8.89	1.53	0.70	257.20
19	29.16	19.90	132.08	58.63	99.56	4.13	1.78	296.19
20	30.55	19.20	176.45	80.59	39.27	3.18	1.77	301.26
21	33.39	18.50	197.57	114.64	75.08	1.57	0.84	389.70
22	16.81	14.40	37.16	22.10	12.23	1.51	0.69	73.69
23	14.29	12.72	29.21	22.42	9.46	0.90	0.44	62.43
24	15.25	13.60	30.59	14.77	8.72	1.64	0.72	56.44
25	20.75	14.83	71.35	33.12	43.80	5.01	2.51	155.79
26	30.18	16.20	107.38	72.25	51.16	5.39	2.52	238.70
27	30.81	18.31	180.88	109.31	46.42	6.40	3.91	346.93
28	30.56	18.00	172.87	149.93	55.38	5.44	3.04	386.67
29	32.79	19.00	258.03	144.37	68.17	4.78	2.41	477.75
30	20.05	15.56	65.09	23.44	15.98	1.75	0.82	107.08
31	26.99	18.40	149.39	72.88	28.00	6.52	4.57	261.36
32	29.79	19.60	209.64	103.50	21.14	4.17	3.82	342.27
33	24.86	19.00	115.73	82.35	24.68	6.18	2.89	231.82
34	29.67	17.48	191.70	112.26	125.60	0.19	0.23	429.98
35	21.01	17.48	95.11	54.47	29.45	5.41	2.71	187.14
36	17.67	15.30	69.27	15.30	10.39	21.28	21.50	137.74
37	19.89	15.46	73.93	20.66	22.53	46.32	31.31	194.76
38	20.85	14.86	85.86	34.12	19.55	44.92	27.77	212.22
39	21.96	15.50	85.53	24.91	13.06	38.21	20.93	182.64
40	19.10	13.20	53.00	16.75	6.40	14.66	19.92	110.72
41	22.28	14.60	70.31	26.73	11.01	23.91	12.37	144.33
42	22.60	15.00	70.64	23.99	16.82	37.69	20.74	169.88
43	25.15	16.35	84.66	27.05	14.23	33.53	28.04	187.52
44	18.46	15.38	59.03	16.82	8.55	20.28	16.27	120.95