

**UNIVERSIDADE FEDERAL DE SANTA MARIA
CENTRO DE CIÊNCIAS RURAIS
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA FLORESTAL**

Pablo Fernandes

**IMAGENS MULTIESPECTRAIS E INTELIGÊNCIA ARTIFICIAL PARA
PREDIÇÃO DA DENSIDADE DE PLANTAS
ESPONTÂNEAS EM PLANTIO DE *EUCALYPTUS SALIGNA***

Santa Maria, RS
2022

Pablo Fernandes

**IMAGENS MULTIESPECTRAIS E INTELIGÊNCIA ARTIFICIAL PARA PREDIÇÃO
DA DENSIDADE DE PLANTAS
ESPONTÂNEAS EM PLANTIO DE *EUCALYPTUS SALIGNA***

Tese apresentada ao Curso de Doutorado do Programa de Pós-Graduação em Engenharia Florestal, da Universidade Federal de Santa Maria (UFSM), como requisito parcial para obtenção do título de **Doutor em Engenharia Florestal**.

Orientador: Prof. Dr. Rudiney Soares Pereira

Santa Maria, RS
2022

Fernandes, Pablo
Imagens multiespectrais e inteligência artificial
para predição da densidade de plantas espontâneas em
plantio de Eucalyptus saligna / Pablo Fernandes.- 2022.
132 p.; 30 cm

Orientador: Rudiney Soares Pereira
Coorientador: Fernando Coelho Eugenio
Tese (doutorado) - Universidade Federal de Santa
Maria, Centro de Ciências Rurais, Programa de Pós
Graduação em Engenharia Florestal, RS, 2022

1. RPAS 2. Inteligência Artificial 3. Plantas
Espontâneas 4. Eucalyptus I. Soares Pereira, Rudiney II.
Coelho Eugenio, Fernando III. Título.

Sistema de geração automática de ficha catalográfica da UFSM. Dados fornecidos pelo autor(a). Sob supervisão da Direção da Divisão de Processos Técnicos da Biblioteca Central. Bibliotecária responsável Paula Schoenfeldt Patta CRB 10/1728.

Declaro, PABLO FERNANDES, para os devidos fins e sob as penas da lei, que a pesquisa constante neste trabalho de conclusão de curso (Tese) foi por mim elaborada e que as informações necessárias objeto de consulta em literatura e outras fontes estão devidamente referenciadas. Declaro, ainda, que este trabalho ou parte dele não foi apresentado anteriormente para obtenção de qualquer outro grau acadêmico, estando ciente de que a inveracidade da presente declaração poderá resultar na anulação da titulação pela Universidade, entre outras consequências legais.

Pablo Fernandes

**IMAGENS MULTIESPECTRAIS E INTELIGÊNCIA ARTIFICIAL PARA PREDIÇÃO
DA DENSIDADE DE PLANTAS
ESPONTÂNEAS EM PLANTIO DE *EUCALYPTUS SALIGNA***

Tese apresentada ao Curso de Doutorado do Programa de Pós-Graduação em Engenharia Florestal, da Universidade Federal de Santa Maria (UFSM), como requisito parcial para obtenção do título de **Doutor em Engenharia Florestal**.

Aprovada em 31 de 08 de 2022:

Rudiney Soares Pereira, Dr. (UFSM)
(Presidente/Orientador)

Alessandro Carvalho Miola, Dr. (UFSM)

Fernando Coelho Eugenio, Dr. (UFVJM)

Luciano Zucuni Pes, Dr. (UFVJM)

Tiago De Gregori Teixeira, Dr. (POLLI F.)

Santa Maria, RS
2022

AGRADECIMENTOS

A Deus, pelo seu infinito amor em me conceder esta formação, pela intercessão de Santa Catarina, Medianeira de todas as graças, Mãe Rainha Admirável de Schoenstatt. A Jesus e ao Espírito Santo por conceder ciência e sabedoria para que eu pudesse realizar este trabalho, ensinando-me a superar as dificuldades e mostrando-me o caminho a ser seguido.

À minha esposa Cátia e filhas Stella e Catarina, por todo amor, carinho, paciência, dedicação, doação, ajuda, incentivo e confiança, pois são as minhas principais motivações para realizar esta conquista.

Ao meu pai Pedro, à minha mãe Suzana e ao meu irmão Vinicius, pelo amor incondicional, pelo carinho, atenção, empenho, educação, por toda confiança depositada em mim e por acreditarem que este sonho poderia se tornar realidade, o meu muito obrigado, bem como a toda minha família, que de algum modo acreditou e incentivou-me a realizar este sonho.

À empresa Base (Ademir, Charles e colegas de trabalho, de forma especial colega Giovana e Leonardo) pelo apoio, confiança, disponibilidade, contribuição e auxílio.

Ao meu orientador, professor Dr. Rudiney Soares Pereira, por ter depositado a confiança em mim, na construção deste estudo. transmitindo seu conhecimento e me orientando.

Ao meu coorientador professor Dr. Fernando Coelho Eugenio, pela orientação, contribuição na construção do conhecimento, formação e auxílio. Por ter disponibilizado seu RPAS e sensores para realização do estudo.

Aos colegas de laboratório, em especial ao Mateus e a Roberta, por todo auxílio e companheirismo, bem como aos demais colegas que durante a formação me auxiliaram de alguma forma.

A empresa CMPC, por acreditar no projeto, a empresa QUADRA pela disponibilidade de colaboradores e equipamentos GNSS RTK, para auxiliar na coleta de dados.

À Universidade Federal de Santa Maria e aos professores do curso do Pós-Graduação em Engenharia Florestal, por todo conhecimento, ensino e formação.

“Que a tua vida não seja uma vida estéril. - Sê útil. - Deixa rasto. - Ilumina com o
resplendor da tua fé e do teu amor”.

(BALAGUER,1939)

RESUMO

IMAGENS MULTIESPECTRAIS E INTELIGÊNCIA ARTIFICIAL PARA PREDIÇÃO DA DENSIDADE DE PLANTAS ESPONTÂNEAS EM PLANTIO DE *EUCALYPTUS SALIGNA*

AUTOR: Pablo Fernandes
ORIENTADOR: Rudiney Soares Pereira

O manejo da produção do *Eucalyptus* possui seus processos técnicos operacionais bem definidos e consolidados em todo o país. No entanto, o manejo das plantas espontâneas, que competem com as plantas de *Eucalyptus*, diminuem a produtividade final do plantio, esse monitoramento de controle de plantas espontâneas ainda é dependente de uma vistoria técnica *in loco* e sua quantificação não é precisa. Sendo assim, o presente estudo tem como objetivo mapear a densidade de plantas espontâneas em plantios comerciais de *Eucalyptus saligna* por meio de técnicas de inteligência artificial aplicadas a imagens multiespectrais de altíssima resolução espacial. Com isso foi desenvolvido um estudo a partir de uma revisão bibliométrica sobre o estado da arte as pesquisas desenvolvidas com RPAS (*Remotely Piloted Aircraft System*) para o mapeamento das plantas espontâneas em áreas florestais e agrícolas. Em quatro áreas de produção do *Eucalyptus saligna* no estado do Rio Grande do Sul, Brasil, com idade média de 54 dias após o plantio, foram avaliadas oito parcelas amostrais para identificação e obtenção de leituras de refletâncias hiperespectrais de plantas espontâneas e *Eucalyptus saligna* com o espectrorradiômetro FieldSpec® 3. Por meio do algoritmo de inteligência artificial RF (*Random Forest*), com precisão de 95,44% determinou-se que os intervalos de comprimento de onda de maior importância são de 510 a 589 nm, 400 a 423 nm, 674 a 731 nm e 886 a 900 nm foram capazes de distinguir plantas espontâneas de indivíduos de *Eucalyptus saligna* em plantios comerciais. Nessas mesmas áreas também foram obtidas imagens multiespectrais com o sensor Parrot Sequoia embarcado no RPAS Phantom 4 Pro, utilizando a altura do voo de 30 m. A partir dessas imagens, foram utilizados como preditores as quatro bandas do sensor e mais cinco índices de vegetação. O algoritmo *K-Means* foi aplicado para segmentação das imagens e discriminação da vegetação nas classes *Eucalyptus saligna*, plantas espontâneas e rebrota de *Eucalyptus saligna*. Esses dados foram particionados em 70% treino e 30% teste, para serem modelados pelo algoritmo RF, cujo modelo obteve uma precisão de 95,49% de acerto na classificação de plantas espontâneas, o que viabilizou a elaboração do mapa de densidade de plantas espontâneas para as áreas do estudo, compondo o produto final do estudo.

Palavras-chave: RPAS. Inteligência Artificial. Plantas Espontâneas. *Eucalyptus*.

ABSTRACT

MULTISPECTRAL IMAGES AND ARTIFICIAL INTELLIGENCE FOR PREDICTING WEED DENSITY IN PLANTING OF *EUCALYPTUS SALIGNA*

AUTHOR: Pablo Fernandes
ADVISOR: Rudiney Soares Pereira

The management of *Eucalyptus* production has its technical operational processes well defined and consolidated throughout the country. However, the management of weeds, which compete with *Eucalyptus* plants, decrease the final productivity of the plantation, this monitoring of weed control is still dependent on a technical inspection in loco and its quantification is not accurate. Therefore, the present study aims to map the density of weeds in commercial plantations of *Eucalyptus saligna* through artificial intelligence techniques applied to multispectral images of very high spatial resolution. Thus, a study was developed based on a bibliometric review on the state of the art of the research developed with RPAS (Remotely Piloted Aircraft System) for the mapping weeds in forest and agricultural areas. In four *Eucalyptus saligna* production areas in the state of Rio Grande do Sul, Brazil, with an average age of 54 days after planting, eight sample plots were evaluated to identify and obtain hyperspectral reflectances readings of weeds and *Eucalyptus saligna* with the FieldSpec® 3 spectroradiometer. Using the artificial intelligence RF (Random Forest) algorithm with an accuracy of 95.44%, it was determined that the most important wavelength ranges are from 510 to 589 nm, 400 to 423 nm, 674 to 731 nm and 886 at 900 nm were able to distinguish weeds from *Eucalyptus saligna* individuals in commercial plantations. In these same areas, multispectral images were also obtained with the Parrot Sequoia sensor embedded in the RPAS Phantom 4 Pro, using a flight height of 30 m. From these images, the four sensor bands and five more vegetation indices were used as predictors. The K-Means algorithm was applied for image segmentation and vegetation discrimination in the classes *Eucalyptus saligna*, weeds and regrowth of *Eucalyptus saligna*. These data were partitioned into 70% training and 30% testing, to be modeled by the RF algorithm, whose model obtained an accuracy of 95.49% in the classification of weeds, which enabled the elaboration of the weed density map for the study areas, composing the final product of the study.

Keywords: Artificial intelligence. Weeds. Eucalyptus.

LISTA DE FIGURAS

FIGURA 1 - Procedimentos e critérios estabelecidos para executar a análise bibliométrica.....	37
FIGURA 2 - Frequência das publicações ao longo do tempo relacionadas à temática RPAS e plantas espontâneas no contexto agrícola e florestal.....	38
FIGURA 3 - Distribuição mundial das publicações de RPAS presentes em culturas florestais e agrícolas	39
FIGURA 4 - Proporção de publicações quanto às culturas abordadas	40
FIGURA 5 - Modelos e fabricantes das plataformas utilizadas nos artigos analisados	42
FIGURA 6 - Principais sensores e marcas usados pelos autores	43
FIGURA 7 - Altitudes de voo realizada por meio de RPAS	44
FIGURA 8 - Softwares mais difundidos entre as publicações	45
FIGURA 9 - Principais algoritmos utilizados nas pesquisas	46
FIGURA 10 - Mapa com a distribuição das quatro áreas de estudo no estado do Rio Grande do Sul.....	60
FIGURA 11 - Croqui de distribuição amostral das parcelas dentro de cada área do estudo.....	62
FIGURA 12 - Tomada de leitura espectral de planta espontânea utilizando o espectrorradiômetro FieldSpec® 3.....	63
FIGURA 13 - Imagem com vista panorâmica das quatro áreas de <i>Eucalyptus saligna</i> elencadas para o estudo.....	64
FIGURA 14 - Curvas espectrais médias por espécie de planta espontânea e do <i>Eucalyptus saligna</i>	69
FIGURA 15 - Curva espectral média do <i>Eucalyptus saligna</i> por área amostral	70
FIGURA 16 - Imagens de indivíduos de <i>Eucalyptus saligna</i> por área, A – Indivíduo da Área A, B – Indivíduo da Área B, D– Indivíduo da Área D.....	71
FIGURA 17 - Representação gráfica da importância dos comprimentos de onda como preditores segundo o índice de Gini dos modelos RF utilizados na classificação de <i>Eucalyptus saligna</i> x Plantas Espontâneas para as diferentes áreas de estudo	73
FIGURA 18 - Representação gráfica da importância dos comprimentos de onda como preditores segundo o índice de Gini do modelo RF utilizado na	

classificação de <i>Eucalyptus saligna</i> x Plantas Espontâneas para todas as áreas amostrais em conjunto (Área Geral)	74
FIGURA 19 - Representação gráfica da importância dos comprimentos de onda como preditores segundo o índice de Gini dos modelos RF utilizados na classificação do tipo foliar das plantas espontâneas para as diferentes áreas de estudo	78
FIGURA 20 - Representação gráfica da importância dos comprimentos de onda como preditores segundo o índice de Gini dos modelos RF utilizados na classificação do tipo foliar das plantas espontâneas para todas as áreas amostrais em conjunto (Área Geral)	80
FIGURA 21 - Representação gráfica da importância das bandas espectrais como preditores segundo o índice de Gini dos modelos RF utilizados na classificação <i>Eucalyptus saligna</i> x Plantas Espontâneas para cada área de estudo	82
FIGURA 22 - Representação gráfica da importância das bandas espectrais como preditores segundo o índice de Gini dos modelos RF utilizados na classificação <i>Eucalyptus saligna</i> x Plantas Espontâneas para todas as áreas amostrais em conjunto (Área Geral)	83
FIGURA 23 - Representação gráfica da importância das bandas espectrais como preditores segundo o índice de Gini dos modelos RF utilizados na classificação do tipo foliar das plantas espontâneas para cada área de estudo.....	86
FIGURA 24 - Representação gráfica da importância das bandas espectrais como preditores segundo o índice de Gini dos modelos RF utilizados na classificação do tipo foliar das plantas espontâneas para as áreas amostrais reunidas (Área Geral)	86
FIGURA 25 – Fluxograma da metodologia utilizada no estudo.....	98
FIGURA 26 - Mapa com a distribuição das quatro áreas de estudo no estado do Rio Grande do Sul	99
FIGURA 27 - Croqui de distribuição amostral das parcelas dentro de cada área do estudo.....	101
FIGURA 28 - Imagem com vista panorâmica das quatro áreas de <i>Eucalyptus saligna</i> elencadas para o estudo	102

FIGURA 29 - Imagem do RPAS Phantom 4 Pro embarcado com os sensores CMO, Parrot Sequoia e Sunshine, durante levantamento na área do estudo	103
FIGURA 30 - Levantamento GNSS na área de estudo. Base, rover e coletora do GNSS com RTK HIPER V da Topcon	104
FIGURA 31 - Preditores de maior importância encontrados pelo modelo RF na classificação <i>Eucalyptus saligna</i> x Plantas Espontâneas x Rebrotas de <i>Eucalyptus saligna</i>	109
FIGURA 32 - Mapa de classificação observada e estimada da unidade amostral 1 – Área A.....	110
FIGURA 33 - Mapa de classificação observada e estimada da parcela 2 – Área A .	111
FIGURA 34 - Mapa de classificação observada e estimada da parcela 3 – Área B	112
FIGURA 35 - Mapa de classificação observada e estimada da parcela 4 – Área B	113
FIGURA 36 - Mapa de classificação observada e estimada da parcela 5 – Área C	115
FIGURA 37 - Mapa de classificação observada e estimada da parcela 6 - Área C	116
FIGURA 38 - Mapa de classificação observada e estimada da parcela 7 - Área D	117
FIGURA 39 - Mapa de classificação observada e estimada da parcela 8 - Área D	118
FIGURA 40 - Mapa de densidade plantas espontâneas da Área A	121
FIGURA 41 - Mapa de densidade plantas espontâneas da Área B	122
FIGURA 42 - Mapa de densidade plantas espontâneas da Área C	123
FIGURA 43 - Mapa de densidade plantas espontâneas da Área D.....	124

LISTA DE TABELAS

TABELA 1 - Descritores utilizados para as buscas de artigos científicos, nas plataformas Web of Science e Scopus	37
TABELA 2 - Informações de localização de cada área do estudo	60
TABELA 3 - Informações do manejo da cultura e coleta de dados em cada área de estudo	63
TABELA 4 - Quantidade de plantas espontâneas encontradas por área amostral	67
TABELA 5 - Proporção amostral para a classificação do <i>Eucalyptus saligna</i> e plantas espontâneas nas áreas de estudo.....	68
TABELA 6 - Proporção amostral por tipo de folha das plantas espontâneas nas áreas de estudo.....	68
TABELA 7 - Comprimentos de onda de maior importância segundo o índice de Gini dos modelos RF utilizados na classificação de <i>Eucalyptus saligna</i> x Plantas Espontâneas para cada área de estudo.....	72
TABELA 8 - Intervalos de comprimento de onda de maior importância para a classificação de <i>Eucalyptus saligna</i> x Plantas Espontâneas para cada área de estudo	75
TABELA 9 - Matriz de confusão e estimativa do erro para classificação de <i>Eucalyptus saligna</i> x Plantas Espontâneas, utilizando a base de dados hiperespectral	76
TABELA 10 - Comprimentos de onda de maior importância segundo o índice de Gini dos modelos RF utilizados para a classificação do tipo de folha das plantas espontâneas nas diferentes áreas de estudo.....	77
TABELA 11 - Intervalo de comprimento de onda de maior importância para a classificação do tipo folhar das plantas espontâneas para cada área de estudo.	79
TABELA 12 - Matriz de confusão e estimativa do erro para classificação do tipo foliar das plantas espontâneas, utilizando a base de dados hiperespectral .	81
TABELA 13 – Bandas espectrais de maior importância segundo o índice de Gini dos modelos RF utilizados na classificação de <i>Eucalyptus saligna</i> x Plantas Espontâneas para cada área de estudo.....	83

TABELA 14 - Matriz de confusão e estimativa do erro para classificação de <i>Eucalyptus saligna</i> x Plantas Espontâneas, utilizando a base de dados multiespectral	84
TABELA 15 - Bandas espectrais de maior importância segundo o índice de Gini dos modelos RF utilizados na classificação do tipo foliar das plantas espontâneas para cada área de estudo	87
TABELA 16 - Matriz de confusão e estimativa do erro para classificação do tipo foliar das plantas espontâneas, utilizando a base de dados multiespectral..	87
TABELA 17 - Informações de localização de cada área do estudo	99
TABELA 18 - Informações do manejo da cultura e coleta de dados em cada área de estudo.....	102
TABELA 19 – Expressão matemática dos índices de vegetação utilizados no estudo	105
TABELA 20 - Proporção amostral entre as classes usadas considerando o particionamento para modelagem	106
TABELA 21 - Resultado da matriz de confusão e erro total dos dados de treinamento do modelo	108
TABELA 22 – Resultado da matriz de confusão e erro total dos dados de teste do modelo.....	109
TABELA 23 - Análise de diferença de área na comparação da classificação observada e estimada da parcela 1	111
TABELA 24 - Análise de diferença de área na comparação da classificação observada e estimada da parcela 2 – Área A	112
TABELA 25 - Análise de diferença de área na comparação da classificação observada e estimada da unidade amostral 3 – Área B	113
TABELA 26 - Análise de diferença de área na comparação da classificação observada e estimada da unidade amostral 4 – Área B	114
TABELA 27 - Análise de diferença de área na comparação da classificação observada e estimada da unidade amostral 5 – Área C	115
TABELA 28 - Análise de diferença de área na comparação da classificação observada e estimada da unidade amostral 6 – Área C	116
TABELA 29 - Análise de diferença de área na comparação da classificação observada e estimada da unidade amostral 7 – Área D	117

TABELA 30 - Análise de diferença de área na comparação da classificação observada e estimada da unidade amostral 8 – Área D.....	118
TABELA 31 - Análise de densidade de plantas espontâneas observadas e estimadas para todas as parcelas levantadas no estudo.....	119

LISTA DE ABREVIATURAS E SIGLAS

AM	Aprendizado de Máquina
SARP	Sistemas de Aeronaves Remotamente Pilotadas
CNN	<i>Convolutional Neural Network</i>
DL	<i>Deep Learning</i>
ELM	<i>Extreme Learning Machine</i>
ExG	<i>Excess Green Index</i>
G	<i>Green</i>
GCP	<i>Ground Control Points</i>
GNDVI	<i>Green normalized difference vegetation index</i>
GNSS	<i>Global Navigation Satellite System</i>
GRVI	<i>Green-Red Vegetation Index</i>
IA	Inteligência Artificial
INMET	Instituto Nacional de Meteorologia
MCARI	<i>Modified Chlorophyll Absorption in Reflectance Index</i>
NDRE	<i>Red-edge Normalized Difference Vegetation Index</i>
NDVI	<i>Normalized Difference Vegetation Index</i>
NIR	<i>Near Infrared</i>
OBIA	<i>Object-Based Image Analysis</i>
R	<i>Red</i>
RE	<i>Red-Edge</i>
RF	<i>Random Forest</i>
RGB	<i>Red, Green, Blue</i>
RPAS	<i>Remotely Piloted Aircraft System</i>
RTK	<i>Real Time Kinematic</i>
SDCA	<i>Stochastic Dual Coordinate Ascent</i>
SAMS	<i>Spectral Analysis and Management System</i>
SGD	<i>Stochastic Gradient Descent</i>
SLIC	<i>Simple Linear Iterative Clustering</i>
SVM	<i>Support Vector Machine</i>

SUMÁRIO

1	INTRODUÇÃO GERAL	25
2	HIPÓTESE	29
3	OBJETIVOS	31
3.1	OBJETIVO GERAL	31
3.2	OBJETIVOS ESPECÍFICOS	31
4	CAPÍTULO I - REMOTELY PILOTED AIRCRAFT SYSTEMS (RPAS) E PLANTAS ESPONTÂNEAS: UMA ABORDAGEM NO CONTEXTO DA CIÊNCIA FLORESTAL E AGRÍCOLA	33
4.1	INTRODUÇÃO.....	34
4.2	MATERIAIS E MÉTODOS.....	36
4.2.1	Coleta dos dados	36
4.2.2	Processamento e análise de dados	37
4.3	RESULTADOS	37
4.3.1	Número e distribuição global das publicações	37
4.3.2	Culturas agrícolas e florestais citadas nas publicações	39
4.3.3	Plataformas e sensores.....	41
4.3.4	Altura do voo.....	44
4.3.5	Software.....	45
4.3.6	Algoritmos.....	46
4.3.7	Variáveis utilizadas como preditoras	50
4.4	CONCLUSÃO	51
4.5	REFERÊNCIAS	52
5	CAPÍTULO II – IDENTIFICAÇÃO DOS INTERVALOS DE COMPRIMENTO DE ONDA DE MAIOR IMPORTÂNCIA PARA IDENTIFICAÇÃO DE ESPÉCIES ESPONTÂNEAS EM PLANTIO DE EUCALYPTUS SALIGNA...	57
5.1	INTRODUÇÃO.....	58
5.2	MATERIAIS E MÉTODOS	59
5.2.1	Local do Estudo	59
5.2.2	Aquisição de Dados	61
5.2.3	Processamento dos dados espectrorradiométricos	64
5.2.4	Análise de Preditores com Inteligência Artificial	66
5.3	RESULTADOS E DISCUSSÕES.....	67

5.3.1	Espécies encontradas.....	67
5.3.2	Análise hiperespectral da classificação do <i>Eucalyptus saligna</i> x Plantas Espontâneas.....	72
5.3.3	Análise hiperespectral por tipo de folha das Plantas Espontâneas	77
5.3.4	Análise multiespectral para a classificação do <i>Eucalyptus saligna</i> x Plantas Espontâneas.....	81
5.3.5	Análise multiespectral para o tipo de folha das Plantas Espontâneas	85
5.4	CONCLUSÃO.....	88
5.5	REFERÊNCIAS	88
APÊNDICE A - TABELA COM A PROPORÇÃO AMOSTRAL EM RELAÇÃO AS ESPÉCIES LEVANTADAS NA ÁREA DE ESTUDO		93
6	CAPITULO III – MAPEAMENTO DE DENSIDADE DE PLANTAS ESPONTANEAS EM PLANTIO DE <i>EUCALYPTUS SALIGNA</i> UTILIZANDO INTELIGENCIAARTIFICIAL COM IMAGENS MULTIESPECTRAIS PROVENIENTES DE RPAS.....	95
6.1	INTRODUÇÃO.....	96
6.2	MATERIAIS E MÉTODOS.....	98
6.2.1	Local do estudo	98
6.2.2	Aquisição de dados	100
6.2.3	Processamento das Imagens.....	104
6.2.4	Análise das imagens	105
6.3	RESULTADOS E DISCUSSÕES	107
6.4	CONCLUSÃO.....	125
6.5	REFERÊNCIAS	125
7	CONSIDERAÇÕES FINAIS	129
8	REFERÊNCIAS BIBLIOGRÁFICAS GERAL.....	131

1 INTRODUÇÃO GERAL

Amplamente difundido no Brasil, o gênero *Eucalyptus*, cuja ocorrência natural é na Austrália, contempla cerca de 600 espécies, as quais possuem como principal característica uma alta adaptação às mais diversas condições de clima e solo. Tais aspectos ecológicos, silviculturais e de tecnologia permitiram sua consolidação e disseminação como uma das principais matérias-primas para fins madeireiros (BERGER et al., 2002).

De acordo com dados do IPEF (2005), entre as espécies do gênero, em especial no Rio Grande do Sul, a espécie *Eucalyptus saligna* Smith tornou-se, quando comparada a outras, uma das espécies mais cultivadas em virtude da sua tolerância ao frio. Além disso, trata-se de uma espécie versátil de madeira clara com média densidade, sendo apta para a extração de celulose, bem como para outras finalidades (MORA e GARCIA, 2000).

Quanto à produtividade volumétrica do gênero *Eucalyptus* em áreas brasileiras, pode-se dizer que ocupa lugar de destaque no ranking mundial pois, de acordo com a Indústria Brasileira de Árvores (IBÁ), a produtividade média dos plantios de eucalipto no Brasil é em torno de $36 \text{ m}^3 \cdot \text{ha}^{-1} \cdot \text{ano}^{-1}$. Estes valores aumentam a uma taxa de 0,7% ao ano e tem potencial de alcançar valores ainda maiores em razão das condições de sítios e de produção (IBÁ, 2016).

A produção florestal tem um papel importante na economia mundial e brasileira sendo que, em 2019, o Brasil gerou uma receita bruta de R\$ 97,4 bilhões, possuindo um total de 9,0 milhões de hectares com floresta plantada, dois quais 6,97 milhões de hectares plantados são de *Eucaliptus* sp., equivalente a 77% do cultivo. O Brasil é um dos maiores exportadores mundiais de celulose, com o valor total negociado de US\$ 7,5 bilhões no ano de 2019 (IBÁ, 2020).

Contudo, no que tange à produtividade dos plantios florestais existem inúmeros aspectos que condicionam o sucesso dessas culturas. Há os fatores definidores, ou seja, os relacionados ao potencial das culturas florestais, dos quais podemos citar principalmente o genótipo da espécie e as características ambientais dos locais onde a espécie será conduzida, e há também os fatores limitantes, que se resumem na disponibilidade de água e nutrientes, e nos tratos silviculturais empregados. Por fim, existem ainda os fatores reais (ou fatores redutores de produtividade), tais como a ocorrência de plantas espontâneas, a presença de

pragas e doenças, e os incêndios florestais (FISHER; BINKELEY, 2001; ELLI et al., 2019).

A redução de produtividade ocasiona perdas e prejuízos econômicos, sendo que um fator redutor de produtividade muito comum na cultura do eucalipto é a ocorrência de plantas espontâneas. Segundo Resende; Leles (2017), além de afetar a produtividade, a presença destas plantas também acarreta custos mais elevados dos projetos de produção florestal. Em geral, as espécies de plantas espontâneas apresentam maior eficiência no uso da água e recursos disponíveis, além de possuir maior capacidade fotossintética, e por isso se sobressaem às plantas de eucalipto (principalmente na fase inicial de crescimento), afetando assim o desenvolvimento das espécies florestais.

De acordo com Toledo (2003), o período crítico de ocorrência das plantas espontâneas em culturas de eucalipto acontece até o sétimo mês após o plantio, nessa fase é necessário realizar ações de controle das plantas espontâneas, com a utilização de tratamentos silviculturais como as capinas e roçadas, que geralmente são realizadas de maneira mecanizada. Segundo Pereira et al., (2015), há um crescimento do uso de herbicidas em áreas florestais. No entanto, existe um alto custo com mão de obra para a realização dessas ações silviculturais, nesse sentido há uma busca por técnicas mais eficazes e que possam diminuir custos e a aplicação de herbicidas, a fim de subsidiar, complementar e otimizar as técnicas aplicadas atualmente.

No que diz respeito a otimização e eficiência das técnicas de manejo e tratamentos silviculturais, a agricultura e a floresta de precisão consolidam-se como um instrumento importante contribuindo para a concisão das técnicas aplicadas a campo e para a redução da aplicação de herbicidas. Para tanto, se faz necessário detectar as plantas espontâneas nos plantios de forma mais ágil, a partir do mapeamento e diferenciação entre espécies, minimizando dessa forma os custos das ações de manejo.

Entre as mais recentes soluções tecnológicas da área de Sensoriamento Remoto no setor agrícola e florestal, está o uso dos *Remotely Piloted Aircraft Systems* – RPAS, que permitem a aquisição rápida de informações sobre as áreas de plantio, podendo oferecer uma detecção em tempo real das plantas espontâneas. As imagens obtidas por RPAS oferecem alta resolução, o que antes em algumas ocasiões não era possível com as imagens de satélite, limitando o mapeamento de

áreas cultivadas para subsídio de manejo, além disso, é possível abranger uma quantidade maior de área com pouco tempo de operação. Permite ainda trabalhar com subimagens (conjuntos de *pixels*), pois as imagens podem ser capturadas com pouca altitude e com resolução suficiente (BORREGAARD, et al., 2000; RASMUSSEN et al., 2019). Esses dados podem então ser processados para orientar as decisões de manejo das plantas espontâneas, levando a benefícios econômicos significativos em termos de custos das operações de manutenção e redução do uso de herbicidas incidindo em menor impacto ambiental e aumento do rendimento da espécie florestal.

Para maior capacidade de localizar e identificar plantas espontâneas com precisão, são necessários além dos RPAS sistemas mais avançados, como por exemplo, Inteligência Artificial (IA) (*Artificial Intelligence*), Aprendizado de Máquina (AM) (*Machine Learning*) e Aprendizado Profundo (*Deep Learning*), que vem demonstrado resultados satisfatórios para a tarefa de classificação de espécies espontâneas por meio de imagens aéreas, como relatados no estudo de Wang et al. (2018), que propôs um método baseado em rede neural convolucional (*Convolutional Neural Network* - CNN) para classificar ervas espontâneas e estimativa de densidade. De Castro et al. (2018) ao combinar imagens de RPAS, *Random Forest* (RF) e Análise de Imagem Baseada em Objeto (OBIA), permitiram o mapeamento preciso de plantas espontâneas entre e dentro das linhas de cultivos de culturas herbáceas, para aplicação de herbicida. Neste mesmo contexto, Pantazi et al. (2020), ressaltam que o AM possibilita realizar o tratamento específico do local de ocorrência das espécies indesejadas.

Segundo Faceli et al. (2011), a IA teve uma maior disseminação para solução de problemas reais em meados da década de 1970, sendo anteriormente usada de forma teórica. Para Collins (2018), a IA é definida como programas computacionais que possuem a capacidade de operar de forma em que se acredita imitar os processos de pensamento dos seres humanos. Neste processo insere-se o AM, que visa desenvolver algoritmos e técnicas computacionais capazes de adquirir conhecimento de forma automática a partir de dados atuais e históricos, aperfeiçoando assim o seu desempenho (GOLDSCHIMIDT, 2010; SIMON, 2013).

Dessa forma, essas aplicações tecnológicas apresentam vantagens quando comparada às abordagens estatísticas convencionais, principalmente quando abrange grandes conjuntos de dados com alta dimensão de variáveis não

normalmente distribuídas; são robustas para modelar o sobreajuste, além de generalizar um problema de predição mesmo com amostras de treinamento limitadas (MALENOVSKÝ et al., 2017). Para tanto, se faz necessário um bom sistema de detecção e mapeamento, nos quais precisam ser capazes de separar as plantas espontâneas e as plantas em fase de desenvolvimento no nível da planta ou folha individual.

2 HIPÓTESE

A utilização de imagens multipectrais advindas de RPAS combinada ao uso de algoritmos de inteligência artificial é capaz de mapear e quantificar a densidade de plantas espontâneas em plantios comerciais de *Eucalyptus saligna*, no estado do Rio Grande do Sul, Brasil.

3 OBJETIVOS

3.1 OBJETIVO GERAL

Mapear a densidade de plantas espontâneas em plantios comerciais de *Eucalyptus saligna* por meio de técnicas de inteligência artificial aplicadas a imagens multispectrais de altíssima resolução espacial.

3.2 OBJETIVOS ESPECÍFICOS

a) Realizar um estudo do estado da arte sobre as pesquisas desenvolvidas com RPAS para o mapeamento das plantas espontâneas em áreas florestais e agrícolas.

b) Identificar quais são os intervalos de comprimento de onda do espectro eletromagnético que sejam capazes de distinguir plantas espontâneas de indivíduos de *Eucalyptus saligna* em plantios comerciais.

c) Avaliar e validar o algoritmo de inteligência artificial no mapeamento e identificação das plantas espontâneas em plantios comerciais de *Eucalyptus saligna*, utilizando sensor multiespectral embarcado em RPAS

d) Criar um mapa de densidade de plantas espontâneas em uma área de produção de *Eucalyptus saligna*.

4 CAPÍTULO I - REMOTELY PILOTED AIRCRAFT SYSTEMS (RPAS) E PLANTAS ESPONTÂNEAS: UMA ABORDAGEM NO CONTEXTO DA CIÊNCIA FLORESTAL E AGRÍCOLA

RESUMO

Produtos obtidos via Sistemas de Aeronaves Remotamente Pilotadas (RPAS) vêm ganhando espaço no contexto agrícola e florestal na última década em relação à vasta amplitude de aplicações e das significativas contribuições para a caracterização e modelagem de atributos espaciais. Neste contexto o objetivo desse estudo foi realizar uma revisão sistemática no que diz respeito as pesquisas desenvolvidas com RPAS para o mapeamento das plantas espontâneas em áreas florestais e agrícolas. Obteve-se 72 artigos científicos das plataformas *Web of Science* e *Scopus*, sendo identificados os locais de origem das publicações, alvos de estudo (espécies agrícola e florestal), plataforma, sensores, altura de voo, software e algoritmo. A maioria dos trabalhos foram publicados na Europa e Ásia, sendo a cultura agrícola *Zea mays* a espécie com maior número de pesquisas envolvendo RPAS e plantas espontâneas, enquanto na área florestal apenas uma espécie foi identificada o *Pinus radiata*. Plataformas multirrotor têm sido mais utilizadas em comparação as plataformas de asa fixa, os sensores multiespectrais e RGB totalizaram 40,27% cada um. Referente às alturas de voo, variaram principalmente de 0-9m (10 publicações); 30-39m (20), 60-69m (12) e 100-109m (10). Os softwares mais utilizados para o processamento das imagens nos artigos foram o *Matlab* e *eCognations Developer*. Quanto aos algoritmos utilizados nas publicações destacaram-se principalmente o *Convolutional Neural Network* (CNN) e Imagem Baseada em Objeto (OBIA). Dessa forma, é notório que o uso de RPAS no monitoramento agroflorestal têm se mostrado uma ferramenta eficaz, oferecendo alta resolução e velocidade em obter dados precisos, além de ser uma ferramenta poderosa para avaliar, detectar e monitorar variáveis complexas relacionadas à dinâmica da floresta e ao ambiente agrícola em muitas regiões.

Palavras-chave: RPAS. Plantas espontâneas. Aprendizado de Máquina.

ABSTRACT

Products obtained by Remotely Piloted Aircraft Systems (RPAS) have been gaining ground in the agricultural and forestry context in the last decade regarding the wide range of applications and significant contributions to the characterization and modeling of spatial attributes. In this context, the objective of this study was to carry out a systematic review regarding the research developed with RPAS for the mapping of weeds in forest and agricultural areas. In the Web of Science and Scopus search portals, we obtained 72 scientific articles, identifying the places of origin of the publications, study targets (agricultural and forestry species), platform, sensors, flight height, software and algorithm. Most of the works were published in Europe and Asia, with the agricultural crop *Zea mays* being the species with the highest number of research involving RPAS and spontaneous plants, while in the forest area only one species was identified, *Pinus radiata*. Multicopter platforms have been more used compared to fixed wing platforms, multispectral and RGB sensors totaled 40.27% each. Regarding flight heights, they ranged mainly from 0-9m (10 publications); 30-

39m (20), 60-69m (12) and 100-109m (10). The most used software for processing the images in the articles were *Matlab* and *eCognations Developer*. As for the algorithms used in the publications, the Convolutional Neural Network (CNN) and Object-Based Image (OBIA) stood out. Thus, it is clear that the use of RPAS in agroforestry monitoring has proved to be an effective tool, offering high resolution and speed in obtaining accurate data, in addition to being a powerful tool to assess, detect and monitor complex variables related to forest dynamics and to the agricultural environment in many regions.

Keywords: RPAS. Weeds. Machine Learning.

4.1 INTRODUÇÃO

O manejo de plantas espontâneas no sistema de produção agrícola e florestal é essencial para que não ocorram perdas no potencial produtivo em cada cultura. No setor florestal, em especial na produção de eucalipto, as plantas daninhas invasoras podem interferir diretamente na produtividade por meio de competição por água, luz, nutrientes, espaço, bem como podem ocasionar alelopatia entre as plantas, e também a hospedagem de pragas, doenças, riscos de incêndio, entre outros fatores que afetam diretamente a produção (SOUZA et al., 2010).

De acordo com Garau et al. (2009), em situações extremas de presença de plantas espontâneas, em plantios de eucaliptos, a redução de incremento de madeira pode chegar até 80 % em três anos, além disso, Toledo et al. (2000), afirmam que o eucalipto, em um período entre 14 e 28 dias de convivência com plantas espontâneas, já apresenta perdas significativa de crescimento. Em culturas agrícolas como o girassol, Silva et al. (2012) relatam que a presença de plantas espontâneas referente ao período de 49 dias após a emergência ocasiona perdas de 13,97% na produtividade. Já Brighenti et al. (2004), demonstram que as plantas invasoras presentes na cultura causam perdas de produtividade diárias que variam de 1,1 a 2,5 kg.ha⁻¹.

Em decorrência das perdas em produtividade impostas pela presença de plantas espontâneas, surge a necessidade de controle e, principalmente, a necessidade de gerenciar e mapear a presença dessas plantas, e da mesma forma a produção e eventuais perdas nas culturas. A agricultura e a floresta de precisão tornaram-se uma ferramenta importante para o manejo eficiente do sistema de produção, permitindo uma intervenção técnica a campo de forma localizada e precisa.

A partir do desenvolvimento da agricultura e floresta de precisão no mundo, foram implementadas novas tecnologias a fim de mapear a variabilidade espacial dos plantios. Nesse sentido, a rápida detecção de plantas espontâneas é, portanto, uma das principais formas para minimizar os prejuízos no setor agroflorestal. Uma das ferramentas mais inovadoras para detecção precoce é a utilização dos *Remotely Piloted Aircraft Systems* - RPAS para a coleta de informações de forma ágil.

Ao contrário das imagens de satélite, as imagens de RPAS oferecem alta resolução e alta flexibilidade em termos de tempo de aquisição da imagem. Os RPAS podem cobrir uma grande área em um curto espaço de tempo, enquanto fornecem alta resolução temporal que permite capturar imagens a qualquer momento durante o desenvolvimento da cultura, detectando pequenos objetos, como plantas daninhas (RASMUSSEN et al., 2019). O uso de RPAS no manejo de plantas espontâneas segundo Adegas et al. (2017) tem se mostrado eficiente, com redução entre 40 a 60% no número de aplicações de herbicidas.

Diversas metodologias de aplicação do Sensoriamento Remoto para identificação de problema em lavouras vêm sendo utilizadas nos últimos anos (Formaggio et al., 2017), entretanto, ainda existem algumas lacunas do conhecimento, o que impede “avanços chave” para pesquisas em agricultura e floresta de precisão. Mulla (2013) destaca que para permitir tal avanço se faz necessário a continuidade no desenvolvimento de índices espectrais, permitindo, simultaneamente, a avaliação de múltiplas características da cultura (área foliar, biomassa, dentre outros) e de estresses (falta de água, déficits nutricionais, pressão por plantas espontâneas, incidência de doenças).

Os principais métodos de discriminação aplicados às imagens capturadas por RPAS são baseados em inteligência artificial (IA), na qual está relacionada principalmente com a utilização de técnicas de aprendizado de máquina (AM), e ferramentas de classificação. Novas abordagens de IA, combinando redes neurais e lógica *fuzzy* para o reconhecimento de padrões na classificação de imagens, surgem como uma alternativa oportuna, viável e inovadora (Giacco et al., 2010), pois, permitem realizar a mineração de grandes volumes de dados proveniente do sensoriamento remoto utilizando RPAS (MA et al., 2015; NAJAFABADI et al., 2015; SCHMIDHUBER, 2015).

Dessa forma, a criação de softwares e algoritmos que possam interligar o mapeamento e a tomada de ação é essencial para inovar e trazer agilidade à

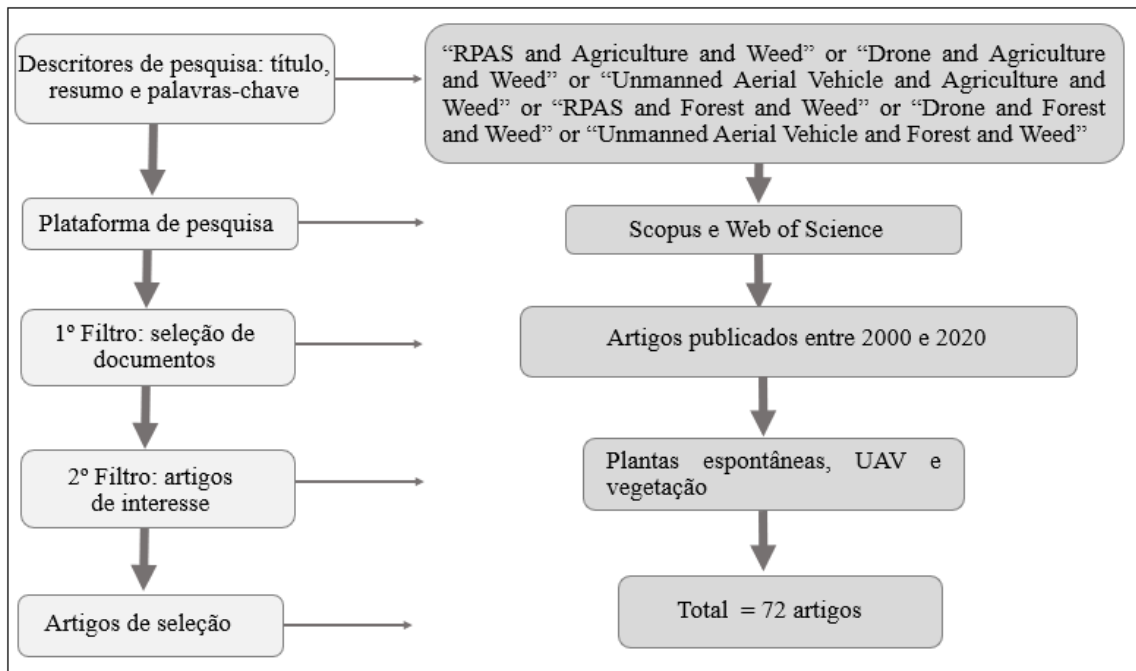
produção florestal e agrícola, fazendo-se necessário determinar indicadores da dinâmica e evolução das informações científicas e tecnológicas a respeito desses temas. Para tanto, o estudo bibliométrico de identificação da relação existente entre as imagens de RPAS com a presença de plantas espontâneas nas áreas florestais e agrícolas trarão a luz as informações necessárias para os próximos avanços no setor. Nesse contexto, o presente estudo teve por objetivo realizar uma revisão bibliométrica para a última década sobre pesquisas desenvolvidas com RPAS para o mapeamento das plantas espontâneas em áreas florestais e agrícolas, bem como, elucidar as principais ferramentas utilizadas.

4.2 MATERIAIS E MÉTODOS

4.2.1 Coleta dos dados

Esta pesquisa foi estruturada com base na revisão de publicações científicas no campo de RPAS para mapear plantas espontâneas presentes em culturas florestais e agrícolas. A pesquisa bibliográfica foi realizada em 12 de janeiro de 2021 nas plataformas de informação científica *Web of Science* (WoS), produto da *Thomson Reuters*, e *Scopus*, da *Elsevier*. Considerou-se apenas artigos com *Digital Object Identifier System* (DOI) e conferências, publicados em inglês em todo o mundo. O período da pesquisa compreendeu o ano de 2000 a 2020, sendo considerados os descritores em títulos, palavras-chave e resumos (Figura 1). Os termos descritivos foram configurados em combinações conforme consta na Tabela 1.

Figura 1 - Procedimentos e critérios estabelecidos para executar a análise bibliométrica



Fonte: Autor. Santa Maria, RS, UFSM, 2021.

Tabela 1 - Descritores utilizados para as buscas de artigos científicos, nas plataformas Web of Science e Scopus

Eixos temáticos	Termos descritivos
Plataformas	“RPAS”, “Drone”, “ <i>Unmanned Aerial Vehicle</i> ”
Área	“ <i>Agriculture</i> ”, “ <i>Forest</i> ”
Aplicações	“ <i>Weed</i> ”

Fonte: Autor. Santa Maria, RS, UFSM, 2021.

4.2.2 Processamento e análise de dados

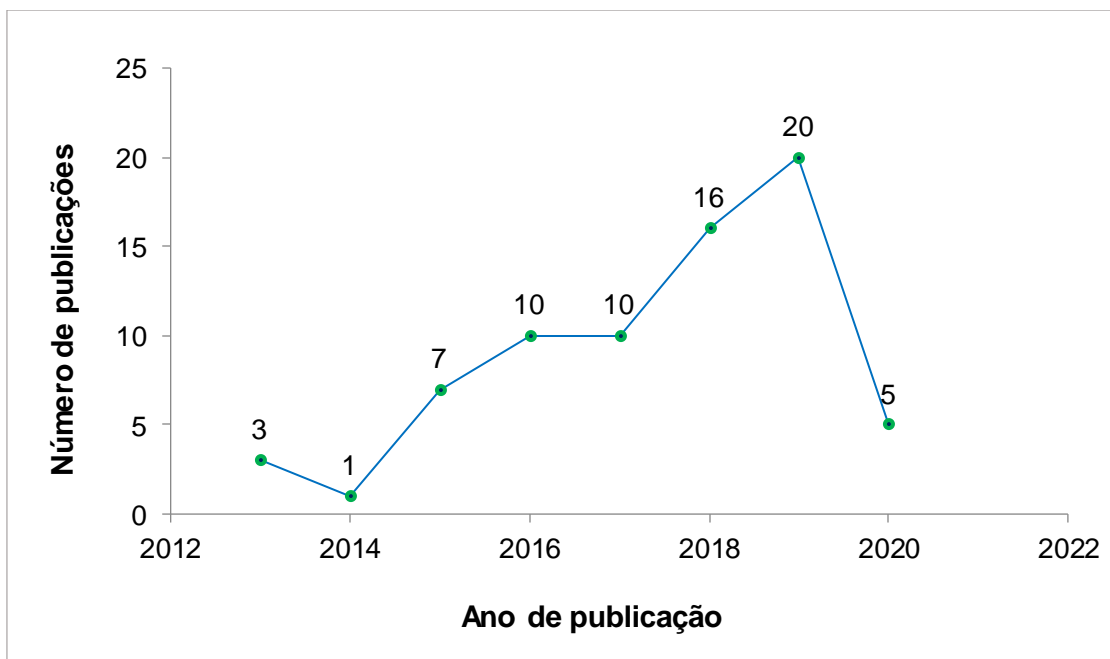
As variáveis analisadas foram: ano de publicação, país, alvos de estudo (espécies agrícola e florestal), plataforma, sensores, altura de voo, software e algoritmo. Para análise e quantificação, os dados foram tabulados em planilha do Microsoft Excel.

4.3 RESULTADOS

4.3.1 Número e distribuição global das publicações

Observa-se uma tendência crescente de publicações relacionadas a pesquisas com RPAS aplicado as plantas espontâneas presentes em culturas florestais e agrícolas partir do ano de 2013 (Figura 2). O aumento acentuado em número de publicações pode ser observado principalmente entre os anos de 2018 e 2019. No entanto, no ano seguinte, ocorre um declínio nas publicações, esse fato permite ao leitor inferir que o interesse em realizar investigações nessa linha diminuiu ao longo de 2020, principalmente sob a influência global da humanidade em relação a presença do vírus SARS-CoV-2 (COVID 19) e suas restrições impostas.

Figura 2 - Frequência das publicações ao longo do tempo relacionadas à temática RPAS e plantas espontâneas no contexto agrícola e florestal



Fonte: Autor. Santa Maria, RS, UFSM, 2021.

Espera-se que a tendência de aumento de publicações retorne no ano de 2021, visto que o uso de plataformas RPAS e acesso a softwares tem se intensificado positivamente ao longo do tempo, tornando-se cada vez mais difundido no âmbito agrícola e florestal.

A partir de indicadores gerados pela pesquisa bibliométrica realizada, é possível identificar a origem das publicações referentes ao uso de RPAS em culturas agrícolas e florestais, como pode ser observado na Figura 3.

Figura 3 - Distribuição mundial das publicações de RPAS presentes em culturas florestais e agrícolas




Fonte: Autor. Santa Maria, RS, UFSM, 2021.

O continente europeu detém o maior número de artigos (28), seguido pela Ásia com sete, já o terceiro continente em número de publicações é a América do Norte com cinco. Os países da Europa destacam-se quando comparados aos demais, indicando que estes promovem maior número de pesquisas com o uso dessas tecnologias, demonstrando também um maior interesse na área. Corroborando com os estudos de Eugenio (2020), no qual foi observado uma tendência maior na quantidade de publicações na Europa.

4.3.2 Culturas agrícolas e florestais citadas nas publicações

O conjunto de publicações analisadas na revisão bibliométrica permitiu identificar quais culturas agrícolas e florestais possuem maior abordagem quanto ao uso de RPAS, conforme as informações contidas na Figura 4.

Figura 4 - Proporção de publicações quanto às culturas abordadas



Fonte: Autor. Santa Maria, RS, UFSM, 2021.

Entre as espécies agrícolas estudadas nos artigos observados, o *Zea mays* L. (milho) é a espécie com maior número de pesquisas envolvendo RPAS e plantas espontâneas (13 publicações). Peña et al. (2013) usaram imagens multiespectrais de RPAS para o mapeamento de ervas daninhas em plantios de milho na Espanha, com a intenção de contribuir com o manejo de plantas espontâneas nesses locais, os autores relatam resultados satisfatórios que permitem tomadas de decisão com antecedência, referente ao controle das plantas espontâneas e o uso de herbicidas, evidenciando a aplicabilidade dos métodos aplicados na pesquisa.

Em outra pesquisa realizada em plantações da mesma cultura, Louargant et al. (2017) comprovaram o potencial de uso de RPAS para discriminar vegetação-solo e cultura-plantas espontâneas em linhas de cultivo de milho. Da mesma forma, Wang et al. (2019) apresentam um método de detecção da densidade de plantas espontâneas, aliando imagens adquiridas por RPAS ao uso de algoritmo e aprendizado profundo, para a classificação de plantas espontâneas em áreas de cultivo de milho, assegurando um controle preciso dessas plantas.

Na sequência das culturas com maior número de publicações, encontra-se a cultura do *Helianthus* sp. (girassol) que apresentou 10 publicações, valor próximo ao da espécie *Triticum* sp. (trigo) que possui 9 artigos publicados. Ao observarem um

plântio de girassol em estágio inicial com uma infestação de plantas espontâneas Torres-Sánchez et al. (2013) obtiveram resultados promissores com o uso de uma plataforma *quadcopter* com uma câmara multiespectral, demonstrando a capacidade das RPAS no manejo das safras de girassol, bem como em culturas semelhantes.

Corroborando com o exposto, Pérez-Ortiz et al. (2015) ao usarem imagens de RPAS para mapear a infestação de ervas daninhas em plantações de girassol, atingiram um excelente desempenho dos métodos propostos na pesquisa, assim como, López-Granados et al. (2015) que, além de apresentarem excelentes resultados quanto a distinção entre plantas de girassol, plantas espontâneas e solo nu, demonstraram a aplicabilidade dos RPAS em definir as operações de manejo da cultura do girassol, pois possibilita calcular as necessidades corretas de herbicida para cada situação, incidindo em economia com herbicidas. Assim, os resultados relatados pelos diferentes estudos, motivam o uso de mapas de ervas daninhas para projetar estratégias de controle dessas plantas.

Outros estudos relevantes estão direcionados ao *Oryza sativa* (arroz) com sete publicações. Barrero e Perdomo (2018) usaram imagens RGB advindas de RPAS de asa fixa, para detectar ervas daninhas em campos de arroz com 50 dias após a emergência. Recentemente Kawamura et al. (2020) propuseram um método para discriminar a cultura de arroz de ervas daninhas usando RPAS e câmara RGB, bem como algoritmo de *Simple Linear Iterative Clustering* (SLIC) e *Random Forest* (RF). Os resultados com algoritmo SLIC-RF foram discriminados com precisão aceitável para atender às necessidades de manejo de ervas daninhas, mesmo nos estágios iniciais de crescimento de pequenas plantas de arroz.


No que diz respeito às espécies florestais, observou-se apenas uma publicação, onde Pearse et al. (2020) desenvolveram e validaram métodos para mapear mudas de coníferas (*Pinus radiata* (D. Don)) em imagem RGB de alta resolução. Embora a detecção de plantas espontâneas usando RPAS tenha avançado no setor agrícola, poucas pesquisas ainda nesse âmbito são exploradas em ambientes florestais.

4.3.3 Plataformas e sensores

De acordo com a Figura 5 a plataforma de RPAS mais utilizada foi a do tipo multirotor representado por 70,8% dos artigos analisados, quanto aos RPAS de asa

fixa totalizaram 9,7% e 25% das pesquisas não informaram o tipo de plataforma utilizada. É interessante ressaltar que apenas um artigo fez uso da plataforma do tipo helicóptero (GARCIA-RUIZ et al., 2015) no qual os autores examinaram a discriminação de plantas de beterraba e plantas espontâneas no plantio, resultando em uma validação da identificação das distintas espécies a partir das imagens.

Figura 5 - Modelos e fabricantes das plataformas utilizadas nos artigos analisados

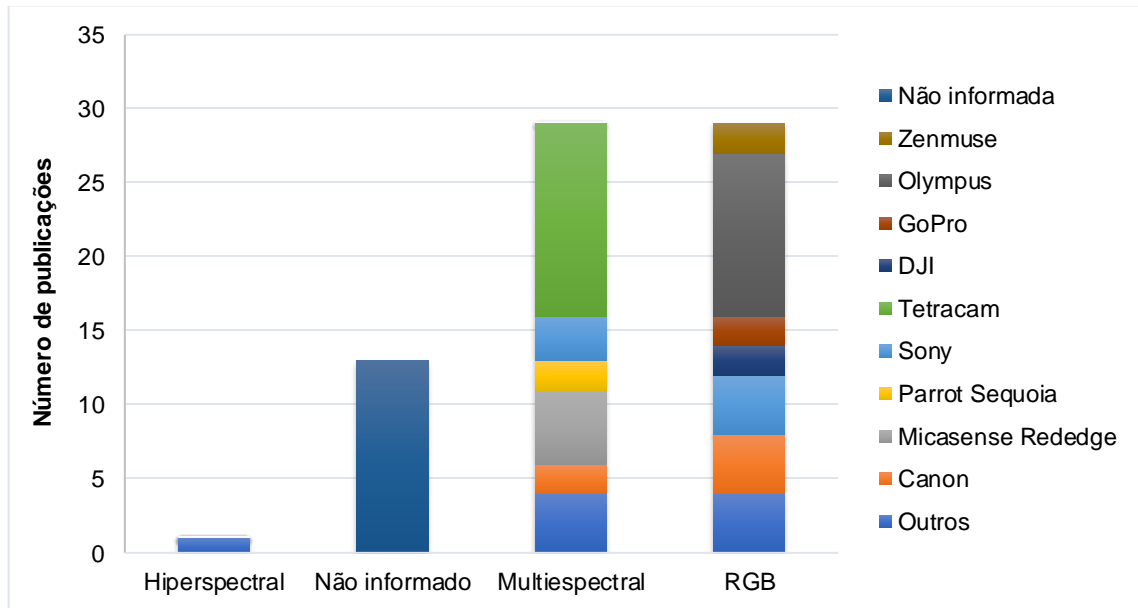


Fonte: Autor. Santa Maria, RS, UFSM, 2021.

Quanto aos fabricantes das plataformas utilizadas a DJI (*Dà-Jiang Innovations Science and Technology*) foi a predominante entre as pesquisas totalizando 30,55%. De acordo com Eugenio e Zago (2019), a fabricante asiática é bastante difundida em trabalhos do setor industrial e também para o uso recreativo.

O fabricante alemão Microdrone foi o segundo mais frequente (20,83%) sendo utilizados nos trabalhos de Brenes et al. (2019), Ortiz et al. (2016), Sánchez et al. (2013) principalmente para classificar e mapear a ocorrência de plantas espontâneas em culturas agrícolas. Em contrapartida, 25% das pesquisas optaram por não informar os fabricantes das plataformas utilizadas. Em relação aos tipos de sensores acoplados aos RPAS (Figura 6) os multiespectrais e RGB representaram 40,27% cada um, enquanto o hiperespectral apenas 1,38% dos trabalhos analisados, sendo o restante não informado pelos autores.

Figura 6 - Principais sensores e marcas usados pelos autores



Fonte: Autor. Santa Maria, RS, UFSM, 2021.

As marcas que se sobressaíram às demais, citadas nas pesquisas que compõe a revisão bibliométrica, foram respectivamente *Tetracam* (13 artigos) e *Olympus* (11 artigos).

A americana *Tetracam* oferece plataformas de câmeras padrão e personalizadas, as quais têm sido aplicadas em diferentes usos de imagens eletrônicas, englobando diversas áreas das ciências e até mesmo no ramo de segurança. As câmeras operam além da faixa de luz visível, como câmeras UV, câmeras NIR e câmeras térmicas. É importante salientar que nos artigos analisados os equipamentos da marca utilizados eram em sua totalidade sensores do tipo multiespectral (TETRACAM, 2021).


Já a *Olympus* é uma empresa de equipamentos ópticos japonesa, no mercado atual destaca-se no ramo de câmeras digitais, equipamentos científicos e médicos. Entre as pesquisas que compõe a revisão bibliométrica, os sensores utilizados da marca *Olympus* operam na faixa espectral do visível. Pérez-Ortiz et al. (2016) utilizaram câmera modelo *Olympus* para mapear a infestação de ervas daninhas no plantio de girassol e milho. Ao analisarem dois campos de girassol, Borra-Serrano et al. (2015) utilizaram RPAS e imagens adquiridas por duas câmeras diferentes, uma câmera *Olympus* e uma câmera multiespectral, *Tetracam*. Mesas-

Carrascosa et al, (2015) utilizaram câmeras *Tetracam* acoplada em RPAS para a detecção de solo nu e vegetação (trigo e ervas daninhas).

4.3.4 Altura do voo

Os intervalos das altitudes de voo referentes às publicações estão representados na Figura 7. De acordo com a metodologia utilizada nas publicações, as altitudes variaram principalmente de 0-9m (10 publicações); 30-39m (20), 60-69m (12) e 100-109m (10).

Figura 7 - Altitudes de voo realizada por meio de RPAS



Fonte: Autor. Santa Maria, RS, UFSM, 2021.

Ao utilizarem uma plataforma do tipo helicóptero Garcia-Ruiz et al. (2015) determinaram uma altitude de voo de 2 m a 30 m acima do solo resultando em resoluções de pixel de 1,4 a 20 mm, a fim de garantir resolução espacial suficiente para identificar plantas de beterraba e plantas espontâneas.


Conforme Huang et al. (2018), as imagens de RPAS foram capturadas em um campo de arroz a 6 m de altitude. Barrero e Perdomo (2018), usaram imagens de RPAS a 60-70 m de altitude a fim de detectar ervas daninhas em campos de arroz aos 50 dias após a emergência. López-Granados et al. (2016) obteve imagens no visível e multiespectral por meio de RPAS a altitudes de 30, 60 e 100 m em dois campos de milho. Peña et al. (2013) classificaram com sucesso ervas daninhas em

um plantio de milho a partir de imagens coletadas por RPAS a uma altitude de 30 m, usando a posição das plantas como referência.

4.3.5 Software

Os principais softwares utilizados nas publicações estão descritos na Figura 8, bem como, sua frequência de uso entre as pesquisas. O software *Matlab*, foi o mais utilizado (15,27%) no tratamento dos dados obtidos por RPAS em culturas agrícolas como nas pesquisas de Wang et al. (2019) na detecção de plantas espontâneas no cultivo de milho, Barreiro e Perdomo (2018) em plantios de arroz, bem como, Rasmussen et al. (2018) no mapeamento de plantas espontâneas em uma cultura de trigo.

Figura 8 - Softwares mais difundidos entre as publicações



Fonte: Autor. Santa Maria, RS, UFSM, 2021.


Também há um destaque para o software alemão *eCognations Developer*, o qual foi utilizado como ferramenta de processamento de dados em 11,11% dos trabalhos, entre eles pode-se citar principalmente as pesquisas realizadas para a cultura do girassol, como os de López-Granados et al. (2015), Serrano et al. (2015) e Castro et al. (2018). Já a linguagem *Python* apresentou baixa frequência de uso

entre os artigos que compõe esta pesquisa bibliométrica, estando presente em apenas um deles.

4.3.6 Algoritmos

A distribuição de uso dos algoritmos de AM nestas publicações também pode ser verificada na Figura 9. O predomínio do algoritmo *Convolutional Neural Network* (CNN) fica bastante evidente, seguido de Imagem Baseada em Objeto (OBIA), *Support Vector Machine* (SVM), *Random Forest* (RF) e *Simple Linear Iterative Clustering* (SLIC).

Figura 9 - Principais algoritmos utilizados nas pesquisas



Fonte: Autor. Santa Maria, RS, UFSM, 2021.

4.3.6.1 *Convolutional Neural Network* - CNN

A CNN tornou-se uma ferramenta proeminente para análise de dados na agricultura e florestas, por ser considerada, segundo Kamilaris e Prenafeta-Boldú (2018), um dos melhores métodos para o processamento e classificação de imagens. As CNNs são algoritmos de *Deep Learning* (DL), que depende de múltiplas (às vezes centenas ou milhares) de camadas de rede neural (HASSLER e BAYSAL-GUREL et al., 2019).

Modelos baseados em CNN aplicados às imagens de alta resolução que os RPAS podem capturar podem superar outros métodos de detecção com custos de

dados e complexidade mais baixos (PEARSE et al., 2020). Estudos realizados por Huang et al. (2018) no desempenho de diversas arquiteturas de DL para classificação em pixels de arroz e ervas daninhas, descobriram que a arquitetura de CNN superou outras arquiteturas analisadas, com precisão de 88% para o reconhecimento de plantas espontâneas. Fromm et al. (2019) explorou o uso de CNNs para detectar mudas de coníferas em regeneração em imagens de RPAS, demonstrando alta precisão.

A CNN baseada na detecção de objetos foi treinada e avaliada em imagens de RPAS para detecção de ervas daninhas na cultura de soja (VEERANAMPALAYAM SIVAKUMAR et al., 2020). Usando imagens RGB de alta qualidade capturadas por RPAS, Hameed e Amin (2018) analisaram dados da safra de trigo em diferentes fases e ervas daninhas por meio da CNN. Huang et al. (2020) usaram imagens de RPAS em dois diferentes campos de arroz e analisaram por meio da OBIA e abordagens de CNN o mapeamento de ervas daninhas.

Pearse et al. (2020), destacaram em seu estudo que modelos baseados em CNN podem ser ferramentas poderosas para o mapeamento de mudas de *Pinus radiata* usando imagens RGB.

4.3.6.2 Imagem Baseada em Objeto - OBIA

A análise de OBIA no campo do SR, vem ganhando popularidade nos últimos anos, juntamente com as imagens de alta resolução. No método OBIA, de acordo com Maes e Steppe (2019) as análises não são realizadas em pixels individuais, e sim em objetos, grupos de pixels adjacentes com propriedades espectrais semelhantes. Dessa forma, ela reduz os problemas referente à variabilidade espectral intraclasse que surge devido à natureza do objeto. A ideia central por trás desse algoritmo segundo Comba et al. (2015) é agrupar os pixels espacialmente adjacentes uns aos outros e, posteriormente, constituir o objeto combinando os pixels homogêneos e aplicando técnicas de classificação.

A OBIA tem sido usada no mapeamento de plantas espontâneas usando imagens RPAS. Mateen e Zhu (2019), usando imagens RGB e multiespectrais capturadas por RPAS em uma altura de 30-60m, utilizaram OBIA para detectar plantas espontâneas em campos de trigo. A altura da planta foi incorporada a um

algoritmo *Random Forest* - OBIA para segmentação de objetos contendo ervas daninhas em fileiras de algodão e girassol (DE CASTRO et al., 2018).

Imagens de alta resolução espacial de RPAS e OBIA foram usadas para mapear de forma rápida e precisa ervas daninhas e gramíneas em áreas de vinhedos (JIMÉNEZ-BRENES et al., 2019). Gao et al. (2018) desenvolveram um procedimento com OBIA e RF combinado com técnicas de seleção de características para classificar solo, ervas daninhas e milho.

Nos estudos de López-Granados et al. (2015) a OBIA foi utilizada para a construção de mapas precisos, em combinação com diferentes fatores como altura de voo e tipos de sensores, permitindo o cálculo preciso das necessidades de herbicida para o manejo oportuno e específico de plantas espontâneas pós-emergência na cultura do girassol, contribuindo para a economia quanto à aplicação desses produtos no controle de plantas espontâneas. Nesse caso a OBIA classificou com 100 % de precisão a cultura do girassol nas diferentes alturas de voo (30 e 60m).

4.3.6.3 *Support Vector Machine* – SVM

O *Support Vector Machine* (SVM) consiste em um algoritmo de aprendizado de máquina supervisionado que é amplamente utilizado em tarefas de classificação ou regressão. De acordo com Saradhi et al. (2005) o SVM classifica um conjunto de pontos de dados mapeados para um espaço de características multidimensional usando uma função kernel.

Este classificador considera propriedades geométricas e não estatísticas das classes, os SVMs não requerem uma estimativa das distribuições estatísticas para realizar a tarefa de classificação, mas definem o modelo de classificação explorando o conceito de margem maximização (MELGANI e BRUZZONE, 2004).

No trabalho de Pflanz et al. (2018) realizado em uma área de cultivo de trigo, o SVM foi usado para calibrar o classificador de imagem com a função kernel linear e diferentes *solvers*. Enquanto o *solver Stochastic Dual Coordinate Ascent* (SDCA) maximiza os objetivos do SVM, o *Stochastic Gradient Descent* (SGD) minimiza o objetivo principal do SVM, a fim de construir um dicionário visual de características locais das imagens coletadas. As ocorrências de plantas espontâneas foram

mapeadas nas imagens, alcançando excelentes resultados na classificação e identificação delas.

Castaldi et al. (2016) fizeram uso de imagens oriundas de RPAS para criar mapas de plantas espontâneas presentes em uma cultura de milho, usando classificação supervisionada com base no algoritmo SVM, o que permitiu separar classes de treinamento definidas (solo, cultura e plantas espontâneas) usando uma superfície de decisão (hiperplano), que maximiza a margem entre as classes, os autores consideraram a precisão dos mapas de prescrição foi como satisfatória.

Já David e Ballado (2016) desenvolveram uma metodologia para mapear automaticamente o uso do solo em uma fazenda de hortaliças com imagem aérea de altíssima resolução. Para tanto, os autores utilizaram diferentes estrutura de classificação de SVM para avaliar os resultados, gramíneas, plantas espontâneas e berinjelas foram mapeadas de forma satisfatória usando a classificação SVM em dois cenários considerados na pesquisa: índice de vegetação em conjunto com texturas em níveis de cinza com precisão de 0,75; e usando somente o índice de vegetação a precisão geral foi de 0,58 .

4.3.6.4 *Random Forest* – RF

Entre os algoritmos de aprendizado de máquina o classificador *Random Forest* (RF) tem se consolidado perante a comunidade de sensoriamento remoto, de acordo com Du et al. (2015), isso se deve à sua alta velocidade de operação, bem como, seu desempenho generalizado. Para Breiman (2001), o RF trata-se de um conjunto de árvores de classificação, nele cada árvore de decisão emprega um subconjunto de amostras de treinamento e variáveis selecionadas por uma abordagem de *bagging*¹, enquanto as amostras restantes são usadas para validação cruzada interna do desempenho de RF.

A utilização do RF foi detectada entre os artigos analisados, principalmente no que tange a classificação de imagens, alcançando resultados satisfatórios. No trabalho desenvolvido por De Castro et al. (2018) o RF foi usado para selecionar e classificar um conjunto de treinamento segmentado em classes, obteve-se os

¹ Abordagem que utiliza o mesmo algoritmo de treinamento para todos os preditores e treiná-los em diferentes subconjuntos aleatórios da base de treino, em seguida, combina as previsões de todos os modelos (GÉRON, 2021).

valores ótimos das características e classificou-se a imagem, não necessitando de treinamento manual, tornando este procedimento mais rápido e preciso.

Lambert et al. (2017) testaram o desempenho preditivo de modelos estatísticos ajustados às imagens de uma plantação de trigo com infestação de plantas espontâneas, para tanto usaram um classificador RF para avaliar a capacidade dos dados espectrais de discernir as densidades de ervas daninhas, os autores relatam que o RF distinguiu plantas de trigo de plantas espontâneas, demonstrando que o conjunto de dados RGB atingiu uma acurácia de 0,68.

4.3.6.5 *Simple Linear Iterative Clustering* – SLIC

O *Simple Linear Iterative Clustering* (SLIC) é um dos algoritmos de superpixel mais populares e bem-sucedidos na atualidade, pois tem sido usado tanto no contexto de algoritmos clássicos de análise de imagens quanto no contexto de aprendizagem profunda, por isso, é cada vez mais aplicado a diferentes tipos de processamento de imagem (ACHANTA et al., 2012). Trata-se de uma adaptação da abordagem k-means para geração de superpixels, com controle do tamanho e compactação dos superpixels. O SLIC cria um agrupamento local de pixels com base em seus valores espectrais

Bah et al. (2018), ao realizarem um trabalho para diferenciar culturas de ervas daninhas, fizeram uso do SLIC para obter uma máscara a partir da interseção de superpixels e as linhas detectadas. Ainda de acordo com os autores o SLIC foi escolhido por ser simples e eficiente em termos de qualidade de resultados e tempo de computação, e neste caso prestou-se de forma positiva atingindo precisão geral de 93% para beterraba, 81% para espinafre e 69% para feijão.

4.3.7 **Variáveis utilizadas como preditoras**

Entre as variáveis utilizadas nas pesquisas que compõe o trabalho as mais frequentes foram a RGB estando em 16,30% dos artigos, seguido por NIR com 15,22 %, na sequência está a variável ExG (*Excess Green Index*) com 14,13 % e por fim NDVI (*Normalized Difference Vegetation Index*) compondo 13,04% das pesquisas.

Torres-Sánchez et al. (2013) apresentaram as diferenças espectrais entre plantas espontâneas, plantas de girassol e solo descoberto, o ExG (*Excess Green Index*) foi significativo para altitude de 30 m, no entanto na discriminação entre vegetação e solo descoberto, foi observado uma maior separabilidade espectral com o índice NDVI. Comparando zonas infestadas e livres de plantas espontâneas, Peña et al. (2015), obtiveram uma precisão com a câmera multiespectral (usando imagens NDVI) de 14%, 18% e 5% maior do que a precisão alcançada com a câmera de luz visível (usando imagens ExG) coletadas com um intervalo de 6-7 dias em 29 de maio, 4 de junho e 11 de junho para diferenciar as plantas nas distintas fases de crescimento.

Alexandridis et al. (2017) utilizaram imagens obtidas com uma câmera multiespectral (green-red-NIR) acoplada em um RPA, para realizar a detecção e mapeamento de plantas espontâneas em uma cultura de cereais. Fawakherji et al. (2019) usaram imagens multiespectrais (NIR-Red) e o índice NDVI para analisar a cultura da beterraba, bem como, fizeram uso do método de aprendizado profundo para estimar a cultura e distribuição de plantas espontâneas por meio dessas imagens.

4.4 CONCLUSÃO

Existe um crescente interesse por parte dos pesquisadores em relação ao tema abordado, envolvendo principalmente as culturas agrícolas. No que diz respeito as espécies florestais, poucas produções foram encontradas ao longo da pesquisa, indicando que há muito a ser explorado quanto a estudos nessa área, uma vez que se encontrou apenas um artigo sobre o assunto.

A plataforma mais frequente, entre os artigos analisados, foi a do tipo Multirotor do fabricante DJI. Existe, entre os autores relacionados, uma preferência pelo uso de imagens multiespectrais e RGB, mostrando a eficiência dessas imagens para o mapeamento das plantas espontâneas em áreas agrícolas e florestais.

Os *softwares Matlab* e *eCognations Developer* atualmente são os mais utilizados para processamento de dados obtidos por RPAS para diagnóstico da ocorrência de plantas espontâneas em áreas de plantio agrícola e florestal. Já em relação ao uso de algoritmos, há um maior número de estudos que tenham utilizado o CNN e OBIA.

As informações obtidas pelo RPAS oferecem diversas possibilidades na identificação e no monitoramento da incidência das plantas espontâneas, facilitando assim na elaboração de estratégias para reduzir os problemas ocasionados por essas plantas, principalmente no que diz respeito ao rendimento final da produção das espécies agrícolas e florestais.

4.5 REFERÊNCIAS

ACHANTA, R.; SHAJI, A.; SMITH, K.; LUCCHI, A.; FUA, P.; SUSSTRUNK, S. SLIC superpixels compared to state-of-the-art superpixel methods. **IEEE Trans. Pattern**, 2012, v.34, n.11, p. 2274–2282.

ADEGAS, F.S.; VARGAS, L.; GAZZIERO, D.L.P.; KARAM, D. **Impacto econômico da resistência de plantas daninhas a herbicidas no Brasil**. Londrina, Embrapa Soja, 11p. (Circular Técnica 132). 2017.

ALEXANDRIDIS, T. K.; TAMOURIDOU, A. A.; PANTAZI, X. E.; LAGOPODI, A. L.; KASHEFI, J.; OVAKOGLU, G.; MOSHOU, D. Novelty detection classifiers in weed mapping: silybum marianum detection on UAV multispectral images. **Sensors**, v. 17, n. 9, p. 2007, 2017.

BAH, M. D.; HAFIANE, A.; CANALS, R. Deep Learning with Unsupervised Data Labeling for Weed Detection in Line Crops in UAV Images. **Remote Sensing**, 2018, v. 10, p. 1-22.

BARRERO, O.; PERDOMO, S. A. RGB and multispectral UAV image fusion for Gramineae weed detection in rice fields. **Precision Agriculture**, 2018, v. 19, n. 5, p. 809-822.

BORRA-SERRANO, I.; PEÑA, J. M.; TORRES-SÁNCHEZ, J.; MESAS-CARRASCOSA, F. J.; LÓPEZ-GRANADOS, F. Spatial quality evaluation of resampled unmanned aerial vehicle-imagery for weed mapping. **Sensors**, 2015, v. 15, n. 8, p.19688-19708.

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

BRENES, J. M. F.; GRANADOS, F. L. SANCHEZ, J. T.; PEÑA, M. J. RAMÍREZ, P.; GONZÁLEZ, C. L. I.; DE CASTRO, I.A. Automatic UAV-based detection of *Cynodon dactylon* for site-specific vineyard management. **PloS One**, 2019, v. 14, n. 6.

BRIGHENTI, A. M. et al. Períodos de interferência de plantas daninhas na cultura do girassol. **Planta Daninha**, jun. 2004. v. 22, n. 2, p. 251–257. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0100-83582004000200012&lng=pt&tlng=pt>. Acesso em: 14 mar. 2020.

CASTALDI, F. et al. Assessing the potential of images from unmanned aerial vehicles (UAV) to support herbicide patch spraying in maize. **Precision Agriculture**, 2017, v.

18, n. 1, p. 76-94.

CASTRO, A. I.; SÁNCHEZ, J. T.; PEÑA, J. M.; JIMÉNEZ-BRENES, F. M.; CSILLIK, O. LÓPEZ-GRANADOS, F. An Automatic Random Forest-OBIA Algorithm for Early Weed Mapping between and within Crop Rows Using UAV Imagery. **Remote Sensing**, 2018, v. 10, p. 1-21.

COMBA, L.; GAY, P.; PRIMICERIO, J.; AIMONINO, D. R. 2015. Vineyard detection from unmanned aerial systems images. **Comput Electron Agr.** 114:78-87.

DAVID, L. C. G.; BALLADO, A. H. Vegetation indices and textures in object-based weed detection from UAV imagery. In: **2016 6th IEEE International Conference on Control System, Computing and Engineering**. 2016, p. 273-278.

DU, P.; SAMAT, A.; WASKE, B.; LIU, S.; LI, Z. Random forest and rotation forest for fully polarized SAR image classification using polarimetric and spatial features. *ISPRS J. Photogramm. Remote Sens.* 2015, 105, 38–53.

EUGENIO, F. C.; SCHONS, C. T.; MALLMANN, C. L.; SCHUH, M. S.; FERNANDES, P.; BADIN, T. L. "Remotely piloted aircraft systems and forests: A global state of the art and future challenge", **Can. J. For. Res.**, Vol. 50, n° 8, p. 705-716, 2020.

EUGENIO, F. C.; ZAGO, H. B. O Livro dos Drones: Um Guia Completo para entender todas as partes e funcionamento. 2019.

FORMAGGIO, A. R.; FORMAGGIO, R. A.; SANCHES, I. D. **Sensoriamento Remoto em Agricultura**. [S.l.]: [s.n.], 2017.

FAWAKHERJI, M.; POTENA, C.; BLOISI, D. D.; IMPEROLI, M. PRETTO, A.; NARDI, D. Uav image based crop and weed distribution estimation on embedded gpu boards. In: **International Conference on Computer Analysis of Images and Patterns**. Springer, Cham, 2019. p. 100-108.

FROMM, M.; SCHUBERT, M.; CASTILLA, G.; LINKE, J.; MCDERMID, G. Automated detection of conifer seedlings in drone imagery using convolutional neural networks. **Remote Sensing**, 2019 11, 2585.

GARAU, A. M. et al. Weeds in *Eucalyptus globulus* subsp. *maidenii* (F. Muell) establishment: Effects of competition on sapling growth and survivorship. **New Forests**, 9 maio. 2009. v. 37, n. 3, p. 251–264.

GARCIA-RUIZ, F. J.; WULFSOHN, D.; RASMUSSE, J. Sugar beet (*Beta vulgaris* L.) and thistle (*Cirsium arvensis* L.) discrimination based on field spectral data. **Biosystems Engineering**, 2015. v. 139, p. 1-15.

GAO, J.; LIAO, W.; NUYTENS, D.; LOOTENS, P.; VANGHEYTE, J.; PIŽURICA, A.; PIETERS, J. G. Fusion of pixel and object-based features for weed mapping using unmanned aerial vehicle imagery. **International journal of applied earth observation and geoinformation**, v. 67, p. 43-53, 2018.

GÉRON, A. **Mãos à obra: aprendizado de máquina com Scikit-Learn, Keras & TensorFlow**. 2ª edição ed. Rio de Janeiro: Alta Books, 2021. 614p.

GIACCO, F. et al. Uncertainty analysis for the classification of multispectral satellite images using SVMs and SOMs. *IEEE Transactions on Geoscience and Remote Sensing*, out. 2010. v. 48, n. 10, p. 3769–3779.

HAMEED, S.; AMIN, I. Detection of weed and wheat using image processing. In: 2018 IEEE 5th **International Conference on Engineering Technologies and Applied Sciences (ICETAS)**. IEEE, 2018. p. 1-5.

HASSLER, S. C.; BAYSAL-GUREL, F. Unmanned aircraft system (UAS) technology and applications in agriculture. *Agronomy*, v. 9, n. 10, p. 618, 2019.

HUANG, H.; DENG, J.; LAN, Y.; YANG, A.; DENG, X.; ZHANG, L. A fully convolutional network for weed mapping of unmanned aerial vehicle (UAV) imagery. *PloS one*, v. 13, n. 4, p. e0196302, 2018.

HUANG, H.; LAN, Y.; YANG, A.; ZHANG, Y.; WEN, S.; DENG, J. Deep learning versus Object-based Image Analysis (OBIA) in weed mapping of UAV imagery. *International Journal of Remote Sensing*, v. 41, n. 9, p. 3446-3479, 2020.

KAMILARIS, A.; PRENAFETA-BOLDÚ, F. X. Deep learning in agriculture: A survey. *Comput. Electron. Agric.* 2018, 147, 70–90.

KAWAMURA, K.; ASAI, H.; YASUDA, T.; SOISOUVANH, P.; PHONGCHANMIXAY, S. Discriminating crops/weeds in an upland rice field from UAV images with the SLIC-RF algorithm. *Plant Production Science*, p. 1-18, 2020.

LAMBERT, J. P. T.; HICKS, H. L.; CHILDS, D. Z.; FRECKLETON, R. P. Evaluating the potential of Unmanned Aerial Systems for mapping weeds at field scales: a case study with *Alopecurus myosuroides*. *Weed Research*, 2017. v. 58, p. 35-45.

LÓPEZ-GRANADOS, F.; TORRES-SÁNCHEZ, J.; SERRANO-PÉREZ, A.; CASTRO, A.; MESAS-CARRASCOSA, F. J.; PEÑA, J. M. Early season weed mapping in sunflower using UAV technology: variability of herbicide treatment maps against weed thresholds. *Precisión Ariculture*, 2016. v. 17, p. 183–199.

LOUARGANT, M.; VILLETTE, S.; JONES, G.; VIGNEAU, N.; PAOLI, J. N.; GÉ, C. Weed detection by UAV: simulation of the impact of spectral mixing in multispectral images. *Precision Agric*, 2017. v. 18, p. 932-951.

MA, Y. et al. Remote sensing big data computing: Challenges and opportunities. *Future Generation Computer Systems*, 1 out. 2015. v. 51, p. 47–60.

MAES, W. H.; STEPPE, K. Perspectives for remote sensing with unmanned aerial vehicles in precision agriculture. *Trends in plant science*, v. 24, n. 2, p. 152-164, 2019.

MATEEN, A.; ZHU, Q. Weed detection in wheat crop using UAV for precision agriculture. **Pakistan Journal of Agricultural Sciences**, v. 56, n. 3, 2019.

MESAS-CARRASCOSA, F. J.; TORRES-SÁNCHEZ, J.; CLAVERO-RUMBAO, I.; GARCÍA-FERRER, A.; PEÑA, J. M.; BORRA-SERRANO, I.; LÓPEZ-GRANADOS, F. Assessing optimal flight parameters for generating accurate multispectral orthomosaics by UAV to support site-specific crop management. **Remote Sensing**, 2015, v. 7, n. 10, p. 12793-12814.

MULLA, D. J. Twenty five years of remote sensing in precision agriculture: Key advances and remaining knowledge gaps. **Biosystems Engineering**, 2013. v. 114, n. 4, p. 358–371. Disponível em: <http://dx.doi.org/10.1016/j.biosystemseng.2012.08.009>.

NAJAFABADI, M. M. et al. Deep learning applications and challenges in big data analytics. *Journal of Big Data*, 2015. v. 2, n. 1, p. 1–21.

PEARSE, G. D.; TAN, A. Y.; WATT, M. S.; FRANZ, M. O.; DASH, J. P. Detecting and mapping tree seedlings in UAV imagery using convolutional neural networks and field-verified data. **ISPRS Journal of Photogrammetry and Remote Sensing**, 168, 156-169, 2020.

PENÁ, J. M.; TORRES-SÁNCHEZ, J.; DE CASTRO, A. I.; KELLY, M.; LÓPEZ-GRANADOS, F. Weed Mapping in Early-Season Maize Fields Using Object-Based Analysis of Unmanned Aerial Vehicle (UAV) Images. *Pos One*, 2013, v. 8, p.1-11.

PEÑA, J. M.; TORRES-SÁNCHEZ, J.; SERRANO-PÉREZ, A.; DE CASTRO, A. I.; LÓPEZ-GRANADOS, F. Quantifying efficacy and limits of unmanned aerial vehicle (UAV) technology for weed seedling detection as affected by sensor resolution. *Sensors*, v. 15, n. 3, p. 5609-5626, 2015.

PÉREZ-ORTIZ, M.; GUTIÉRREZ, P. A.; PEÑA, J. M.; SANCHAEZ, S. T. C.; MARTINEZ, H. C.; GRANADOS, F. L. An experimental comparison for the identification of weeds in sunflower crops via unmanned aerial vehicles and object-based analysis. **International Work-Conference on Artificial Neural Networks**. 2015, Palma de Mallorca, Spain.

PÉREZ-ORTIZ, M.; PEÑA, J. M.; GUTIÉRREZ, P. A.; TORRES-SÁNCHEZ, J.; HERVÁS-MARTÍNEZ, C.; LÓPEZ-GRANADOS, F. Selecting patterns and features for between-and within-crop-row weed mapping using UAV-imagery. **Expert Systems with Applications**, 2016, v. 47, p. 85-94.

PFLANZ, M.; NORDMEYER, H.; SCHIRRMANN, M. Weed Mapping with UAS Imagery and a Bag of Visual Words Based Image Classifier. **Remote Sensing**, 2018. v. 10, p. 1-17.

RASMUSSEN, J. et al. Pre-harvest weed mapping of *Cirsium arvense* in wheat and barley with off-the-shelf UAVs. **Precision Agriculture**, 2019. v. 20, n. 5, p. 983–999. Disponível em: <https://doi.org/10.1007/s11119-018-09625-7>.

SANCHEZ, J. T.; GRANADOS, L. F.; DE CASTRO, I. A. BARRAGAN, P. M. J. Configuration and Specifications of an Unmanned Aerial Vehicle (UAV) for Early Site Specific Weed Management. *Plos One*, 2013, v. 8, p. 1-15.

SARADHI, V., KAMIK, H., MITRA, P. A Decomposition Method for Support Vector Clustering. In Proc. of the 2nd International Conference on Intelligent Sensing and Information Processing (ICISIP), p. 268-271, 2005.

SCHMIDHUBER, J. Deep Learning in neural networks: An overview. **Neural Networks**, 2015. v. 61, p. 85–117.

SERRANO, I. B.; PEÑA, J. M.; SÁNCHEZ, J. T.; MESAS-CARRASCOSA, F. J.; LÓPEZ-GRANADOS, F. Spatial Quality Evaluation of Resampled Unmanned Aerial Vehicle-Imagery for Weed Mapping. **Sensors**, 2015. v. 15, p. 19688-19708.

SILVA, J. I. C. et al. Determinação dos períodos de interferência de plantas daninhas na cultura do girassol. **Planta Daninha**, 2012. v. 30, n. 1, p. 27–36.

SOUZA, M. C. DE; COSTAAGUIAR ALVES, P. L. DA; SALGADO, T. P. Interferência da comunidade infestante sobre plantas de *Eucalyptus grandis* de segundo corte. **Scientia Forestalis/Forest Sciences**, 2010. n. 85, p. 63–71.

TETRACAM. Sobre a Tetracam. Disponível em: <https://www.tetracam.com/Company.htm>. Acesso em: 17/04/2021

TOLEDO, R. E. B. et al. Efeito de períodos de controle de plantas daninhas sobre o desenvolvimento inicial de plantas de eucalipto. **Planta Daninha**, 2000. v. 18, n. 3, p. 395–404.

TORRES-SÁNCHEZ, J.; LÓPEZ-GRANADOS, F.; DE CASTRO, A. I.; PEÑA-BARRAGÁN, J. M. Configuration and specifications of an unmanned aerial vehicle (UAV) for early site specific weed management. **PloS one**, v. 8, n. 3, p. e58210, 2013

TORRES-SÁNCHEZ, J.; PEÑA-BARRAGÁN, J. M.; GÓMEZ-CANDÓN, D.; DE CASTRO, A. I.; LÓPEZ-GRANADOS, F. Imagery from unmanned aerial vehicles for early site specific weed management. In: J. V. Stafford (Ed.), **Precision agriculture** 2013. Wageningen, The Netherlands: Wageningen Academic Publishers.

VEERANAMPALAYAM SIVAKUMAR, A. N. V.; LI, J.; SCOTT, S.; PSOTA, E., J JHALA, A.; LUCK, J. D.; SHI, Y. Comparison of Object Detection and Patch-Based Classification Deep Learning Models on Mid-to Late-Season Weed Detection in UAV Imagery. **Remote Sensing**, v. 12, n. 13, p. 2136, 2020.

WANG, S.; HAN, Y.; CHEN, J; PAN, Y; CAO, Y; MENG, H; ZHENG, Y. A Deep-Learning-Based Low-Altitude Remote Sensing Algorithm for Weed Classification in Ecological Irrigation Area. **Springer Nature Singapore**, 2019. v. 932, p. 451-460.

WATT, M. S. et al. Use of remotely sensed data to characterize weed competition in forest plantations. **International Journal of Remote Sensing**, 2017. v. 38, n. 8–10, p. 2448–2463. Disponível em: <<http://dx.doi.org/10.1080/01431161.2016.1230290>>.

5 CAPÍTULO II – IDENTIFICAÇÃO DOS INTERVALOS DE COMPRIMENTO DE ONDA DE MAIOR IMPORTÂNCIA PARA IDENTIFICAÇÃO DE ESPÉCIES ESPONTÂNEAS EM PLANTIO DE *EUCALYPTUS SALIGNA*

RESUMO

O objetivo geral desse estudo foi identificar quais intervalos de comprimento de onda do espectro eletromagnético de maior capacidade para distinguir plantas espontâneas de indivíduos de *Eucalyptus saligna* em plantios comerciais. De forma específica, o trabalho buscou ainda, aplicar essa análise de preditores na classificação de espécies preditoras segundo o padrão foliar em: folha larga x folha estreita. Com auxílio do espectrorradiômetro FieldSpec® 3, foram coletadas curvas espectrais de diferentes espécies de plantas espontâneas e indivíduos de *Eucalyptus saligna* como idade média de 54 dias após o plantio, presentes em oito unidades amostrais distribuídas em quatro áreas de produção no Rio Grande do Sul. O algoritmo *Random Forest* – RF foi utilizado no processo de classificação, e avaliação da importância dos preditores, por meio do índice de Gini. A modelagem seguiu uma abordagem hiperespectral, com 501 variáveis preditoras entre 400-900nm e, outra multiespectral, com a reflectância média de quatro bandas dentro desse intervalo. Com precisão global de 95,44%, o modelo hiperespectral determinou como intervalos de maior importância, 510 a 589 nm, 400 a 423 nm, 674 a 731 nm e 886 a 900 nm na classificação Plantas espontâneas x *Eucalyptus saligna*. Já na distinção Folha estreita x Folha larga, o modelo RF atingiu 94,29% de precisão global, com quatro intervalos mais relevantes na classificação: 695 a 733 nm, 400 a 425 nm, 521 a 582 nm e 762 a 768 nm. De forma geral, na abordagem multiespectral os resultados seguem a mesma tendência. Esses resultados podem contribuir no aprimoramento de modelos empregados no monitoramento de áreas de produção utilizando sensoriamento remoto.

Palavras-chave: Espectrorradiometria. Random Forest. Seleção de preditores.

ABSTRACT

The main goal of this study was to identify which wavelength ranges of the electromagnetic spectrum have the greatest capacity to distinguish weeds from *Eucalyptus saligna* individuals in commercial plantations. Specifically, the work also sought to apply this analysis of predictors in the classification of predictor species according to the leaf pattern in: broad leaf x narrow leaf. The FieldSpec® 3 spectroradiometer was used to collect spectral curves of different weed species and *Eucalyptus saligna* individuals with an average age of 54 days after planting, present in eight sampling units distributed in four production areas in Rio Grande do Sul. The Random Forest – RF algorithm was used in the classification process, and in the evaluation of predictors importance, using the Gini index. The modeling followed a hyperspectral approach, with 501 between 400-900nm, and a multispectral approach, with the average reflectance of four bands within this range. With an overall accuracy of 95.44%, the hyperspectral model determined as the most important intervals, 510 to 589 nm, 400 to 423 nm, 674 to 731 nm and 886 to 900 nm in the classification Weeds x *Eucalyptus saligna*. In the broad leaf x narrow leaf distinction, the RF model reached 94.29% of global accuracy, with four most relevant intervals in the

classification: 695 to 733 nm, 400 to 425 nm, 521 to 582 nm and 762 to 768 nm. In general, in the multispectral approach the results follow the same trend. These results can contribute to the improvement of models used to monitor production areas using remote sensing.

Keywords: Spectroradiometry. Random Forest. Feature selection.

5.1 INTRODUÇÃO

Estudos da interação da energia eletromagnética com a vegetação, tem grande importância uma vez que fornecem informações sobre a tipologia, a estrutura do dossel, o estado fenológico, as condições de estresse, a falta de nutrientes, entre outros (LIPPERT et al., 2009). Para Adam (2012), o sensoriamento remoto oferece métodos alternativos e potencialmente econômicos para discriminação da vegetação. Segundo Alba (2019), a evolução das tecnologias de aquisição de dados combinada ao avanço tecnológico da computação no processamento das informações, possibilitaram que a identificação de fisionomias pudesse ser realizada de forma célere, menos onerosa e com alta periodicidade.

Segundo Florenzano (2002), as porções de reflexão, absorção e transmissão da radiação eletromagnética dos objetos da superfície terrestre como a vegetação, a água e o solo, variam em comprimento de onda de acordo com suas características físico-químicas. Diversas técnicas ligadas ao sensoriamento remoto têm sido utilizadas para análise do comportamento espectral da vegetação em diferentes paisagens e níveis de abordagem. De acordo com Ponzoni et al. (2012), a medição da reflectância espectral da vegetação pode ser feita através dos espectrorradiômetros, que fornecem uma curva que descreve as propriedades radiométricas de um determinado material. Avaliar o comportamento espectral da vegetação com o uso de espectrorradiômetros torna-se oportuno, tendo em vista que estes sensores possuem a capacidade de ampla leitura do espectro eletromagnético com altíssima resolução (SCHUH et al., 2016).

Um aspecto relevante no estudo da vegetação a partir da reflectância é o método empregado para a construção de modelos preditivos que permita a distinção dos alvos de forma eficiente e precisa. Há uma busca por alternativas que possam aproveitar o poder computacional atual e ao mesmo tempo aproveitar o volume de informações disponível, o que muitas vezes não é possível com a maioria dos

modelos estatísticos convencionais, em razão da sua baixa flexibilidade e rigidez (MONTAÑO, 2016). Nesse sentido, algoritmos de arquitetura sofisticada como o *Random Forest* – RF (BREIMAN, 2001), tem demonstrado grande capacidade para a construção de modelos complexos e flexíveis. Segundo Malenovský et al. (2017), a técnica RF tem sido cada vez mais utilizada para classificação de imagens e para estimativa de parâmetros quantitativos de vegetação na área de sensoriamento remoto.

Ao passo que dados hiperespectrais constituem uma base rica em informação acerca dos alvos, apresentam-se como um desafio à parte, em função do elevado número de variáveis a ser considerado no processo de modelagem. Assim, técnicas robustas de aprendizado de máquina focadas em automatizar a seleção prévia de atributos preditivos podem contribuir para reduzir a carga de trabalho computacional investida na resolução de tarefas de aprendizado mais complexas (EUGENIO et al., 2020).

Nesse sentido o presente estudo tem por objetivo principal identificar quais são os intervalos de comprimento de onda do espectro eletromagnético que sejam capazes de distinguir plantas espontâneas de indivíduos de *Eucalyptus saligna* em plantios comerciais. Como objetivo específico, o trabalho busca ainda aplicar essa análise de preditores para diferenciar as espécies espontâneas quanto ao padrão foliar, segundo a tipologia folha larga e folha estreita.

5.2 MATERIAIS E MÉTODOS

5.2.1 Local do Estudo

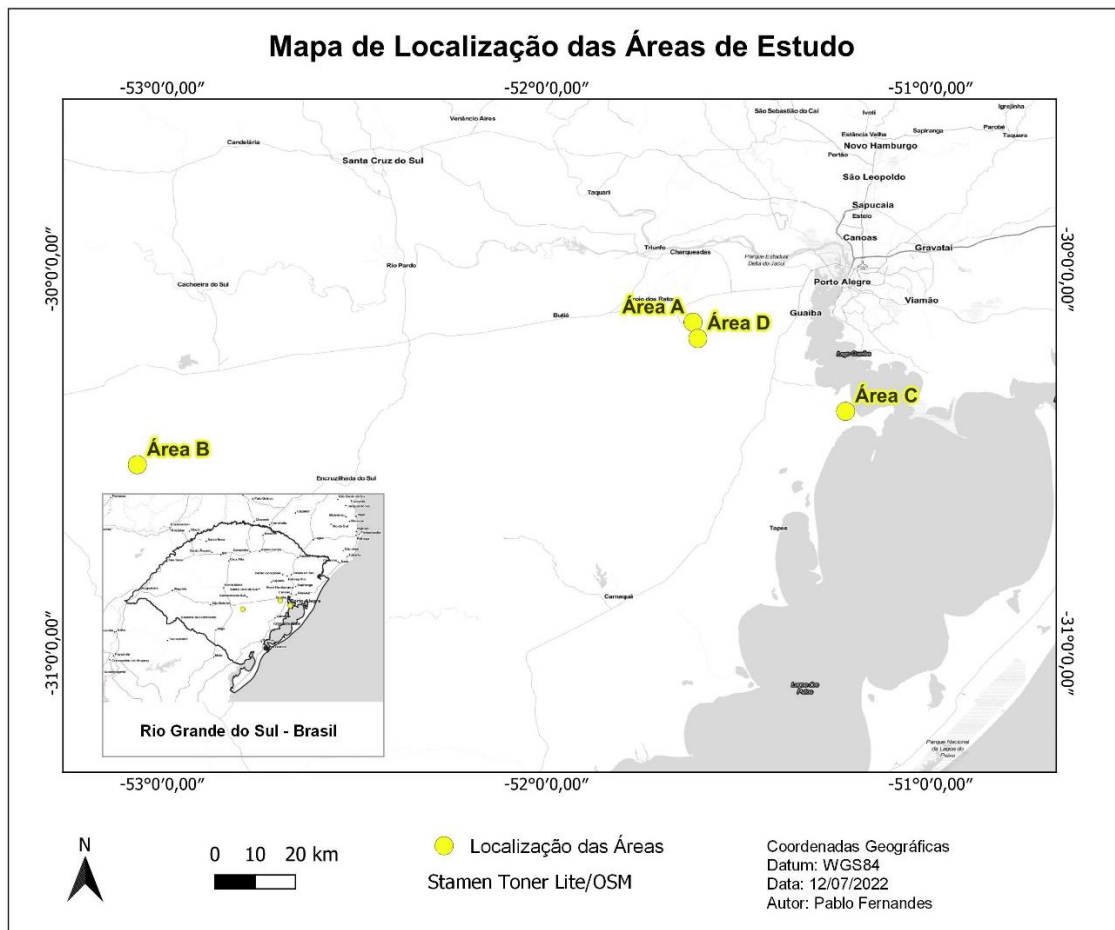
O presente estudo foi realizado em quatro locais nas dependências das áreas de produção da empresa CMPC (CELULOSE RIOGRANDENSE LTDA), no estado do Rio Grande do Sul, Brasil, conforme a Tabela 2. As distribuições das áreas foram baseadas na disponibilidade operacional de plantio da empresa parceira do estudo, no qual os dados do experimento foram obtidos entorno de 54 dias após a implementação do *Eucalyptus saligna* nas áreas, conforme a o mapa de localização das áreas dentro do estado (Figura 10).

Tabela 2 - Informações de localização de cada área do estudo

Identificador da Área	Município	Altitude Média
Área A	Eldorado do Sul	80 m
Área B	Cachoeira do Sul	170 m
Área C	Guaíba	24 m
Área D	Eldorado do Sul	137 m

Fonte: Autor. Santa Maria, RS, UFSM, 2022.

Figura 10 - Mapa com a distribuição das quatro áreas de estudo no estado do Rio Grande do Sul



Fonte: Autor. Santa Maria, RS, UFSM, 2022.

Segundo Streck et al. (2018) o solo das áreas denominadas A e D são classificados como Argissolo Vermelho - Amarelo Distrófico, e a Área B, possui o solo classificado como Argissolo Vermelho-Amarelo Eutrófico, já a Área C, o solo é

classificado como Neossolos Flúvicos, sendo solos aluviais eutróficos ou distróficos, com textura mais arenosa.

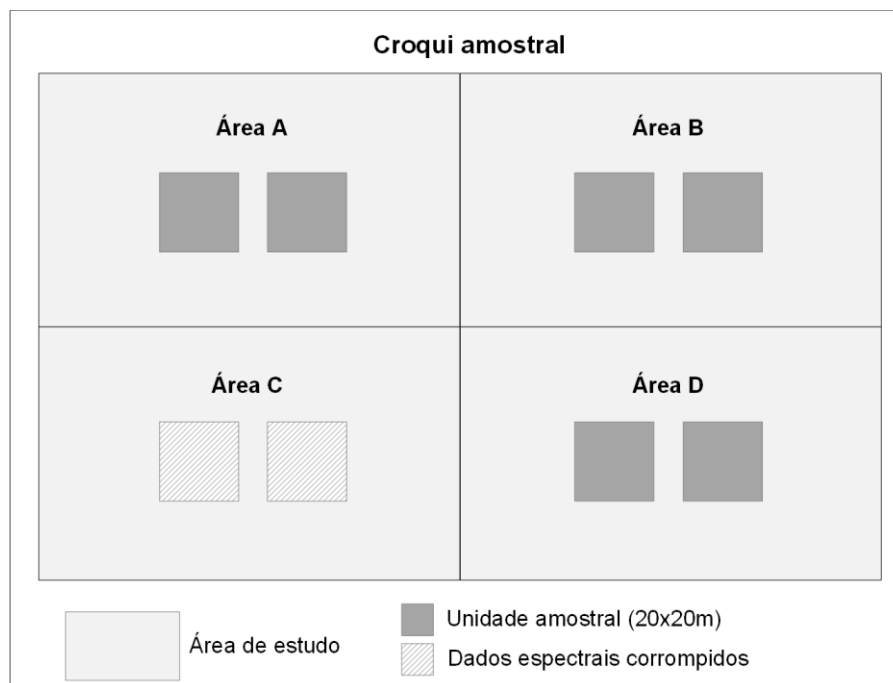
As áreas de estudo são locais de reforma, ou seja, unidades onde já houve um ciclo de produção, sendo o atual decorrente do plantio de novos indivíduos e não pelo sistema de condução por rebrota. Dessa forma, as áreas caracterizam-se pela presença de resíduos vegetais pós-colheita, como galhos e cascas, assim como tocos e rebrotas remanescentes.

A Área A possui uma topografia mais plana de baixa declividade, com presença inclusive de água acumulada dentro do talhão, caracterizando um ambiente mais húmido. Já a Área B, de maneira geral, está situada nas porções mais elevadas nas áreas de produção da região de Cachoeira do Sul, embora dentro do próprio talhão existam locais de acentuada diferença de nível. A Área C, por sua vez, está em uma região mais plana, levemente ondulada, com presença de canais de drenagem em meio ao talhão. Por fim, a área D, apresenta declividade mais acentuada em relação as demais. Toda área do talhão apresenta sentido único de inclinação e encontra-se próxima a um curso curso d'água e sua respectiva APP (Área de Preservação Permanente).

5.2.2 Aquisição de Dados

A coleta de informações foi realizada em quatro áreas de plantio de *Eucalyptus saligna*, que possuíam em média 54 dias após o plantio, nas quais foi delimitado um total de 8 parcelas amostrais de 20 x 20 m, conforme o croqui amostral (Figura 11). Conforme a topologia do terreno possibilitava, a localização de uma das parcelas era posicionada em um nível mais baixo, enquanto a outra em um patamar mais elevado do talhão. Em cada unidade amostral, foram tomadas medições radiométricas de exemplares de *Eucalyptus saligna*, assim como das plantas espontâneas presentes, utilizando um espectrorradiômetro portátil. Para auxiliar na identificação das espécies espontâneas foram realizados registros fotográficos e a classificação dos indivíduos teve como base o Manual de Identificação e Controle de Plantas Daninhas (LORENZI et al., 2014).

Figura 11- Croqui de distribuição amostral das parcelas dentro de cada área do estudo



Fonte: Autor. Santa Maria, RS, UFSM, 2022.

Foi utilizado o espectrorradiômetro FieldSpec® 3 (ASD, 2006), com faixa de leitura espectral de 350 - 2500 nm, com resolução espectral de 01 (um) nm. O registro dos valores de reflectância foi realizado na posição ortogonal à vegetação (NADIR), aproximadamente a 1,3 m dos alvos (Figura 12). Cada novo ciclo de medição do FieldSpec® 3 foi precedida pela recalibração do instrumento, com o auxílio de uma placa Spectralon®², para eliminar a influência da variação natural diária da radiação solar sobre os dados de reflectância da vegetação.

Para cada espécie de planta espontânea foram realizadas leituras de um ou mais exemplares distintos dentro da mesma parcela, totalizando assim 15 leituras por espécie. Para os indivíduos de *Eucalyptus saligna* e demais alvos³ presentes, como solo, água, casca e toco foram realizadas, dentro das áreas, de forma aleatória, o total de 50 leituras para cada um desses grupos.

² Polímero industrial que mais se aproxima de uma superfície *Lambertiana*, com reflectância perfeitamente difusa (LABSPHERE, 2022).

³ A tomada de leituras sobre demais alvos objetivou criar uma biblioteca espectral suplementar de modo a caracterizar as feições espectrais predominantes na área de estudo.

Figura 12 - Tomada de leitura espectral de planta espontânea utilizando o espectrorradiômetro FieldSpec® 3



Fonte: Autor. Santa Maria, RS, UFSM, 2022.

A Tabela 3 apresenta as informações pertencentes aos períodos de coleta de dados espectrais e identificação das espécies, assim como algumas características de manejo florestal da cultura do *Eucalyptus saligna* nas áreas do estudo, como produtos químicos utilizados no controle de espécies espontâneas pré-plantio e espaçamento utilizados no plantio. Na Figura 13 é possível visualizar as condições das áreas no momento de obtenção dos dados.

Tabela 3 - Informações do manejo da cultura e coleta de dados em cada área de estudo

Nome da Área	Data de Plantio	Data de Leitura	Dias de Leituras Após Plantio	Espaçamento de Plantio	Herbicida Pré-Plantio	Herbicida Pré-Emergente
Área A	05/12/2020	28/01/2021	54	3,0 x 2,5 m	Glifosato 2,12kg/ha	Oxifluorfen 1,44 L/ha
Área B	27/03/2021	12/06/2021	77	3,0 x 2,5 m	Não Informado	Não Informado
Área C	06/12/2021	14/01/2022	39	6,0 e 3,0 x 2,5 m	Glifosato 1,99L/ha e Saf lufenacil 1,02 Kg/ha	Oxifluorfen 2,96 L/ha
Área D	01/12/2021	15/01/2022	45	3,0 x 2,5 m	Glifosato 2,58Kg/ha e Saf lufenacil 0,10 Kg/ha	Oxifluorfen 4,83 L/ha

Fonte: Autor. Santa Maria, RS, UFSM, 2022.

Figura 13 - Imagem com vista panorâmica das quatro áreas de *Eucalyptus saligna* elencadas para o estudo



Fonte: Autor. Santa Maria, RS, UFSM, 2022.

5.2.3 Processamento dos dados espectrorradiométricos

A base de dados coletada com o espectrorradiômetro FieldSpec® 3 foi importada no software SAMS - *Spectral Analysis and Management System* (CSTARS, 2011), para visualização prévia das curvas espectrais, permitindo converter as curvas para o formato .csv que posteriormente foram processadas em linguagem R (R Core Team, 2021) no ambiente de programação do software RStudio (RStudio Team, 2021).

A fim de eliminar *outliers*, valores de reflectância superiores a 1 (um) foram excluídos da base de dados. Da mesma forma, através de uma inspeção visual, repetições de espécies com padrão de curva espectral anormal também foram descartadas. Nesse processo de depuração da amostragem, identificou-se que os

dados do espectroradiômetro levantados na Área C (Figura 11) estavam corrompidos, torando-os inutilizáveis para o processamento. Dessa forma a Área C não foi considerada nas análises.

Em razão do comportamento dos dados, optou-se pelo recorte das curvas espectrais no intervalo situado entre 400 e 900 nm, já que essa região apresentou menor ocorrência de ruídos, o que possibilitou melhor aproveitamento da base de dados. Ademais, essa faixa corresponde a região do visível e infravermelho próximo, de fundamental relevância no sensoriamento remoto aplicado, já que os índices propostos na literatura para explorar o comportamento espectral da vegetação utilizam especialmente essa região (PONZONI et al., 2012). O que vai ao encontro dos resultados da pesquisa bibliométrica apresentada no item **4.3.3 Plataformas e sensores** do CAPÍTULO I, onde se observa expressiva maioria de sensores RGB e multiespectrais operando nessa região.

Após a depuração das curvas, a base de dados foi organizada em dois subconjuntos:

- *Subconjunto hiperespectral*: O primeiro conjunto de dados compreende o intervalo de comprimento de onda de 400-900 nm, com resolução espectral de 01 (um) nm, totalizando 501 variáveis preditoras.
- *Subconjunto multiespectral*: Com objetivo de realizar uma aplicação prática dos dados do espectroradiômetro para intervalos de comprimento de onda de sensores embarcados em plataformas RPAS o segundo conjunto de dados, ficou restrito às quatro bandas da câmera Parrot Sequoia (PARROT, 2022) (*Green*: 550nm e largura de banda de 40nm, *Red*: 660nm e largura de banda de 40nm, *Red edge*: 735nm e largura de banda de 10nm e *Near infrared*: 790nm e largura de banda de 40nm), no qual foi calculado a média de resultados de cada leitura para cada intervalo de comprimento de onda presente na câmera, totalizando quatro variáveis preditoras.

Na sequência de processamento de dados, os dois subconjuntos foram tabulados e preparados para o processo de modelagem. Na estrutura utilizada, a primeira coluna traz o rótulo da classe (identificação da espécie), enquanto as demais colunas representam as variáveis preditoras (comprimento de onda), de modo que as linhas trazem os valores de reflectância das espécies.

5.2.4 Análise de Preditores com Inteligência Artificial

O processo de classificação e análise de preditores deu-se em dois níveis. No primeiro nível, levou-se em conta a predição de espécies agrupadas em duas classes: *Eucalyptus saligna* e plantas espontâneas. Já o segundo nível foi baseado no tipo de largura das folhas das plantas espontâneas, resultando na classificação em duas classes: folhas largas e folhas estreitas. Cada nível foi executado em ambos os subconjuntos de dados (hiperespectral e multiespectral), totalizando assim, quatro cenários de classificação.

Cada cenário de classificação foi executado individualmente nas áreas A, B e D. Também optou-se por analisar todas as áreas juntas, denominando esse agrupamento de Área Geral.

O algoritmo de inteligência artificial elencado para modelagem e análise da importância de variáveis preditoras foi o *Random Forest* – RF, difundido no contexto de classificação de padrões da vegetação utilizando dados multiespectrais e hiperespectrais, como nos trabalhos de Poona et al. (2016), Adam et al. (2017), Amini et al. (2018) e Wang et al. (2020). De acordo com Breiman (2001), idealizador da técnica RF, o uso de uma seleção aleatória de variáveis para dividir cada nó das árvores de decisão, produz taxas de erro que são monitoradas internamente, o que além de permitir a depuração da estimativa, possibilita medir a importância de cada preditor.

Essa importância pode ser expressa pelo índice de Gini. O gráfico da diminuição média no coeficiente de Gini (*Mean Decrease Gini*) expressa quanta precisão o modelo perde excluindo cada variável, sendo uma medida de como cada variável contribui para a homogeneidade dos nós e folhas na floresta aleatória resultante (MARTINEZ-TABOADA e REDONDO, 2020). Nesse sentido, quanto maior o valor desse indicador, maior a importância da variável para o modelo.

Com os dados provenientes do Índice de Gini para Área Geral utilizou-se o terceiro quartil como linha de corte para identificar os intervalos de comprimento de onda mais relevantes na classificação. Esse limiar foi estabelecido para minimizar a subjetividade no processo de seleção, já que o número exato ou mesmo o percentual de preditores mais importantes está atrelado ao contexto específico do estudo, como se observa nos trabalhos de Kumar et al. (2015), Han et al. (2016) e Marchesan et al. (2020), aonde não há um critério comum para o limiar de seleção.

O processo de modelagem foi implementado em linguagem R utilizando as ferramentas do pacote randomForest (LIAW e WIENER, 2002). Após alguns testes, apenas o parâmetro *n*tree (número de árvores aleatórias a serem criadas), foi alterado de 500 (*default*) para 1000, para que número de arvores não limitasse a precisão encontrada pelo algoritmo. Os demais parâmetros de entrada do modelo RF, conforme descrição de Liaw e Wiener (2002), não foram alterados da sua forma padrão. Ao final do processo, como indicadores de precisão dos modelos gerados, avaliou-se o Erro Global e a Matriz de Confusão.

5.3 RESULTADOS E DISCUSSÕES

5.3.1 Espécies encontradas

Foram realizadas leituras espectrais de 53 espécies encontradas na área de estudo. Desse número, além do *Eucalyptus saligna*, foram levantadas 52 espécies espontâneas, das quais 43 foram identificadas e 9 não identificadas. O Apêndice A apresenta a lista e a proporção amostral geral das espécies observadas.

Dentre as áreas amostrais, a área D foi a que apresentou maior quantidade de espécies de plantas espontâneas, respondendo por 64,15% das espécies levantadas, considerando que houve repetição de espécies em diferentes áreas. Por sua vez, a Área A apresentou menor quantidade de espécies de plantas espontâneas, com 22,64%, conforme a Tabela 4.

Tabela 4 - Quantidade de plantas espontâneas encontradas por área amostral

Área	Número de Plantas Espontâneas
A	12
B	14
D	34
Geral	53

Fonte: Autor. Santa Maria, RS, UFSM, 2022.

A proporção amostrada para análise de classificação entre *Eucalyptus saligna* e plantas espontâneas é apresentada pela Tabela 5. Observa-se que o somatório das leituras com espectrorradiômetro de *Eucalyptus saligna* foi apenas de 8% em relação a plantas espontâneas dentro da parcela D, menor proporção entre as áreas. Área D está posicionada próximo ao um córrego, na borda da área de

preservação permanente (APP), assim, contemplada pela diversidade biológica do ecossistema da área de preservação, o que naturalmente eleva a competição no talhão da Área D.

Tabela 5 - Proporção amostral para a classificação do *Eucalyptus saligna* e plantas espontâneas nas áreas de estudo

Área	<i>Eucalyptus saligna</i>	Plantas Espontâneas
A	0,22	0,78
B	0,17	0,83
D	0,08	0,92
Geral	0,14	0,86

Fonte: Autor. Santa Maria, RS, UFSM, 2022.

Na subdivisão de plantas espontâneas, por tamanho de folha, classificando-as em folha estreita e folha a larga, observa-se na Tabela 6 que de forma geral, a proporção de espécies classificadas como folha estreita foi muito inferior, apenas 15%. Em especial na Área B, que apresentou relação de amostragem de 5%, representado apenas por uma única espécie do tipo folha estreita.

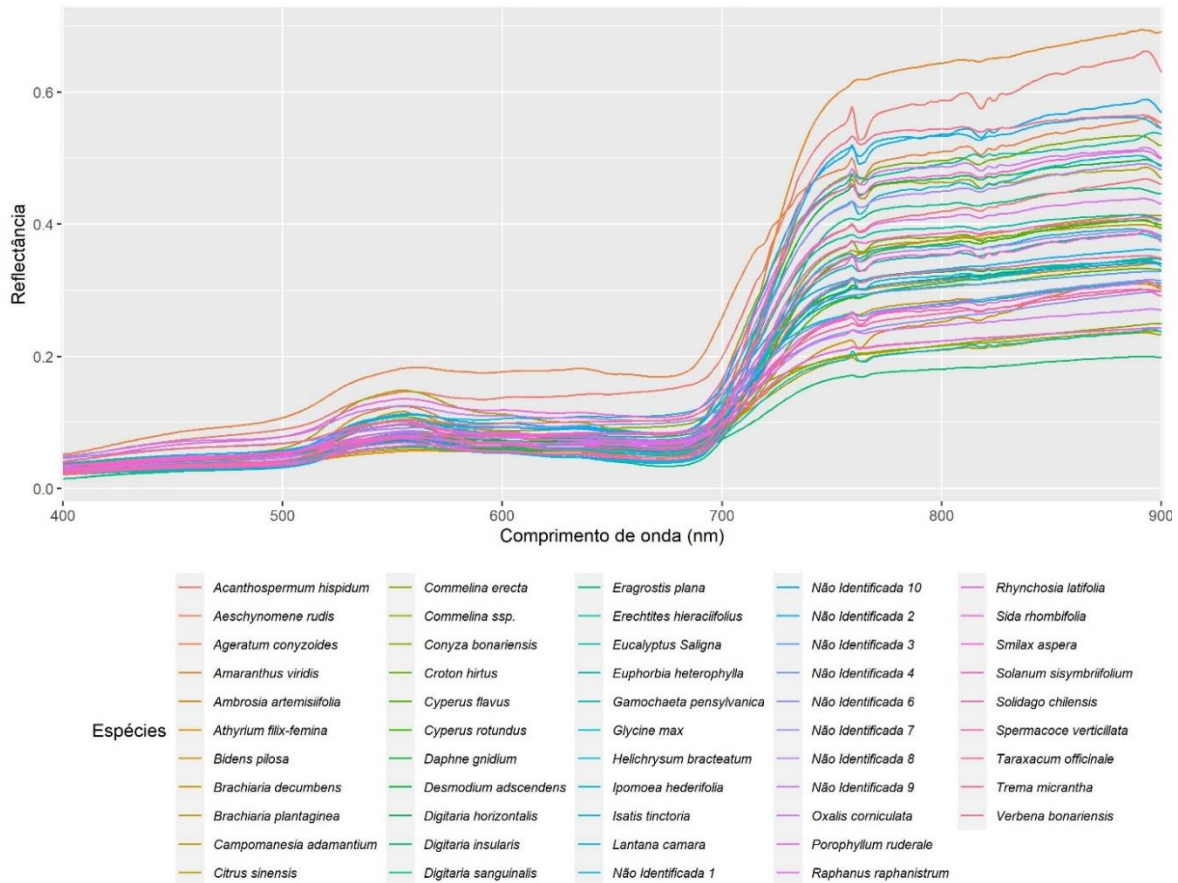
Tabela 6 - Proporção amostral por tipo de folha das plantas espontâneas nas áreas de estudo

Área	Folha Estreita	Folha Larga
A	0,37	0,63
B	0,05	0,95
D	0,12	0,88
Geral	0,15	0,85

Fonte: Autor. Santa Maria, RS, UFSM, 2022.

Em uma análise visual do gráfico da Figura 14, que representa a curva média espectral das espécies de plantas espontâneas e *Eucalyptus saligna*, observa-se que a maioria das espécies apresenta características espectrais esperadas para a vegetação, bem como apresentam uma maior diferenciação na região do verde e do infravermelho próximo. Algumas espécies como *Acanthospermum hispidum* e *Aeschynomene rudis*, apresentaram maior diferenciação na região do visível. Esse incremento na reflectância pode ser resultado da mistura espectral entre as folhas da vegetação e do solo exposto, em função da condição geométrica no momento da tomada das leituras.

Figura 14 - Curvas espectrais médias por espécie de planta espontânea e do *Eucalyptus saligna*




Fonte: Autor. Santa Maria, RS, UFSM, 2022.

A Figura 15 apresenta a curva espectral média por área amostral dos indivíduos de *Eucalyptus saligna* observados no estudo. Observa-se que na Área A, a curva apresenta um padrão espectral característico da vegetação verde e sadia, com grande absorção no azul e vermelho, aumento da reflectância no verde e, grande amplitude entre as regiões do visível e infravermelho próximo. Já a curva representativa da Área B apresenta uma atenuação no infravermelho próximo em relação à curva A. O período de realização das coletas pode estar associado a esse comportamento. As coletas na área A foram realizadas durante o verão, enquanto a Área B foi levantada durante os últimos dias do outono. Ademais, tomando como referência as datas de coleta, os indivíduos de *Eucalyptus saligna* da Área B possuíam 23 dias a mais após o plantio, do que em relação a Área A. A Figura 16 traz indivíduos representativos de *Eucalyptus saligna* para as três áreas levantadas, onde é possível identificar diferenças no porte das mudas.

A curva média de reflectância que apresenta maior contraste em relação as

demais, corresponde aos indivíduos da Área D (Figura 15). Ainda que as coletas da Área D também tenham sido realizadas durante a estação do verão, houve uma diferença de período de quase um ano em relação Área A (Tabela 3). Em janeiro de 2022 quando das coletas na Área D, a região passava por restrições hídricas, com precipitação abaixo da média histórica ao longo da estação, com acumulado entre os meses de novembro, dezembro e janeiro de 239mm, e somente dentro do mês de janeiro, a última precipitação foi nove dias antes do levantamento dos dados, com uma precipitação de 32 mm segundo INMET (2022)⁴. Durante as atividades de campo foi possível constatar sintomas de estresse hídrico nas mudas.

Figura 15 - Curva espectral média do *Eucalyptus saligna* por área amostral




Fonte: Autor. Santa Maria, RS, UFSM, 2022.

Embora a Área D tenha apresentado restrição hídrica no período de coleta dos dados, a curva de reflectância na região do infravermelho próximo, possui um padrão comparável ao observado na Área A (Figura 15), o que demonstra não haver sintomas de colapso estrutural foliar nos indivíduos, caracterizado pelo grande

⁴ Dados da estação meteorológica "83967 – Porto Alegre". Estação em atividade mais próxima ao local de estudo.

incremento de reflectância nessa faixa em função do aumento do espalhamento interno (CATUREGLI et al., 2020; PONZONI et al., 2012). Como mencionado, a área amostral D está posicionada na paisagem, próxima a um córrego, o que pode favorecer a disponibilidade hídrica aos indivíduos e atenuar o efeito da escassez de chuvas. Já na faixa do visível, observa-se o incremento e suavização da curva de reflectância, o que pode ser atribuído à mistura espectral com solo exposto seco. Embora o solo da Área D possua a mesma classificação da Área A, na Figura 16 fica evidente a aparência mais seca do solo na Área D, característica essa que pode ter sido incorporada no dado espectral.

Figura 16 - Imagens de indivíduos de *Eucalyptus saligna* por área, A – Indivíduo da Área A, B – Indivíduo da Área B, D– Indivíduo da Área D



Fonte: Autor. Santa Maria, RS, UFSM, 2022.

5.3.2 Análise hiperespectral da classificação do *Eucalyptus saligna* x Plantas Espontâneas

A Tabela 7 apresenta o ranking contendo os cinco preditores de maior importância utilizados para realizar a classificação entre *Eucalyptus saligna* e plantas espontâneas, com o algoritmo *Random Forest* - RF. Na área amostral A, os preditores de maior destaque encontram-se na região do verde e do azul, ao passo que na Área B, os preditores que receberam maior peso encontram-se somente na faixa do verde. Na Área D, por sua vez, as variáveis de maior contribuição estão na região do azul e do infravermelho próximo. Ao rodar o modelo com todas as áreas reunidas, os preditores mais relevantes estão na região do verde e na do azul.

Assim como no padrão das curvas espectrais, as características inerentes a cada área amostral tiveram eco na solução encontrada pelo algoritmo RF ao gerar os modelos. Diferenças como idade das mudas de *Eucalyptus saligna*, variáveis climáticas e distinção entre espécies espontâneas encontradas em cada área, são fatores que ao impactar a resposta espectral, interferem no ajuste dos modelos.

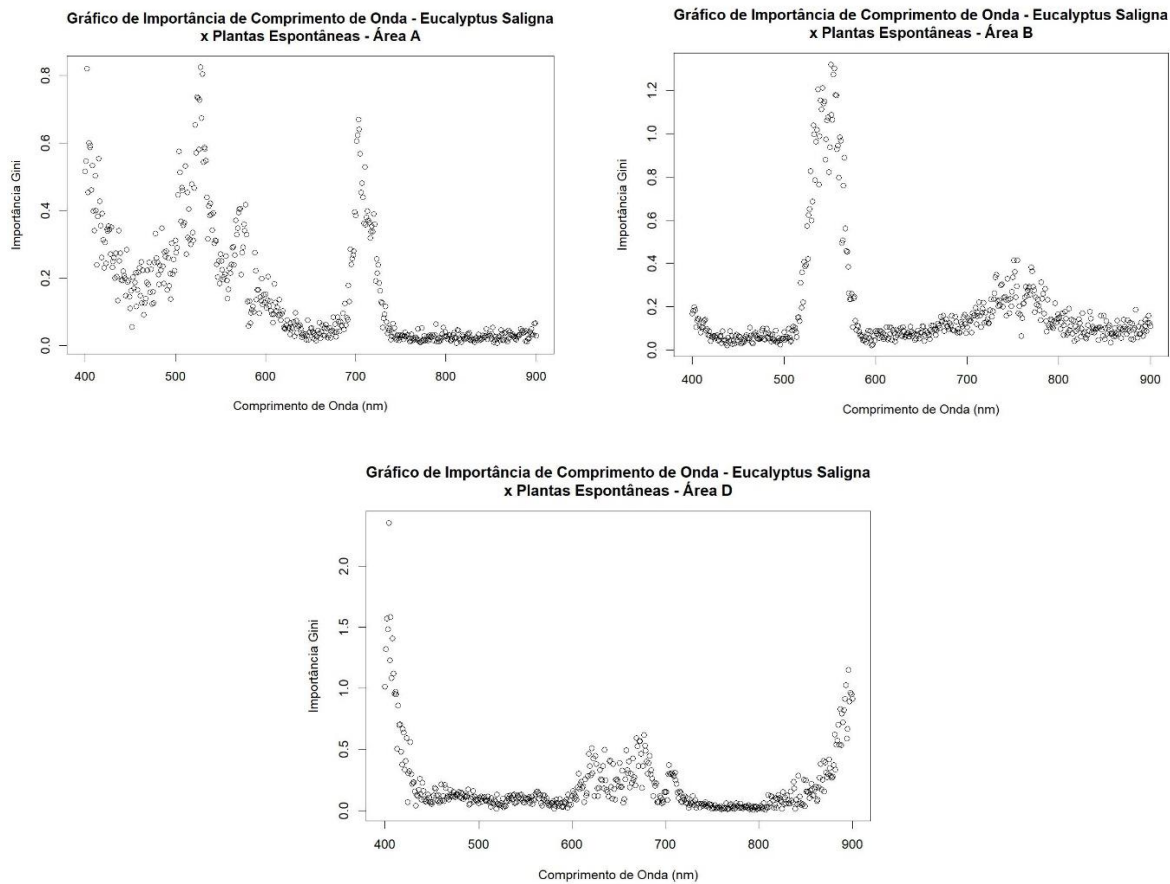
Tabela 7 - Comprimentos de onda de maior importância segundo o índice de Gini dos modelos RF utilizados na classificação de *Eucalyptus saligna* x Plantas Espontâneas para cada área de estudo

Ranking	Comprimento de Onda (nm)			
	Área A	Área B	Área D	Área Geral
1	528	551	404	523
2	402	555	406	524
3	530	554	402	527
4	525	542	408	528
5	527	537	896	406

Fonte: Autor. Santa Maria, RS, UFSM, 2022.

Ao estender o resultado dessa análise para todos os comprimentos de onda utilizados no estudo (400-900nm), percebe-se novamente uma distinção na importância dada aos preditores entre as áreas de estudo (Figura 17), ainda que para as áreas A e B exista uma tendência comum na região do infravermelho próximo. Na Área D, por sua vez, a importância dos preditores fica concentrada nos extremos da distribuição, na faixa do azul e infravermelho próximo, com menor relevância para a região do vermelho.

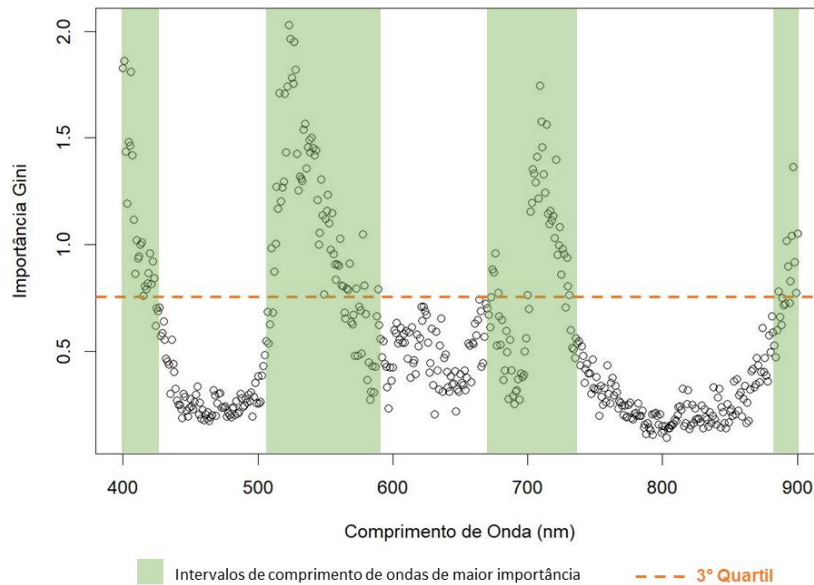
Figura 17 - Representação gráfica da importância dos comprimentos de onda como preditores segundo o índice de Gini dos modelos RF utilizados na classificação de *Eucalyptus saligna* x Plantas Espontâneas para as diferentes áreas de estudo



Fonte: Autor. Santa Maria, RS, UFSM, 2022.

Ao analisar as áreas amostrais em conjunto, denominada Área Geral (Figura 18), fica confirmada a tendência de preditores quando das áreas isoladas. A maior convergência de importância é registrada no início da região do verde, azul, borda do vermelho e no infravermelho próximo, com menor relevância para a faixa espectral do vermelho. Cabe mencionar ainda que, novamente, a maior concentração de importância de preditores deu-se na região visível, em detrimento do infravermelho próximo.

Figura 18 - Representação gráfica da importância dos comprimentos de onda como preditores segundo o índice de Gini do modelo RF utilizado na classificação de *Eucalyptus saligna* x Plantas Espontâneas para todas as áreas amostrais em conjunto (Área Geral)



Fonte: Autor. Santa Maria, RS, UFSM, 2022.

Para melhor compreender e quantificar de forma mais precisa os intervalos de comprimento de onda de maior importância, os dados apresentados nas Figuras 17 e 18 foram selecionados a partir da estatística do terceiro quartil, aonde se encontram os 25% dos dados mais elevados da distribuição. A síntese dessa análise é apresentada na Tabela 8. Ao examinar as áreas amostras individualmente, os dados seguem a mesma tendência geral da análise gráfica, assim como para a Área Geral. No entanto, agora é possível resgatar precisamente os quatro intervalos de comprimento de onda de maior relevância.

O primeiro, na região do verde, mais especificamente no intervalo de 510 nm até 589 nm com um pico em 523 nm. Thenkabail et al. (1999), assim como Elvidge e Chen (1995), encontraram relação entre a derivada de primeira ordem dessa região com o tipo de cobertura agrícola. Já Nichol et al. (2000), atestaram sensibilidade dessa faixa ao conteúdo de pigmentos e rendimento fotossintético em exemplares de floresta boreal. O segundo intervalo, corresponde a região do azul, entre 400-423 nm com pico em 406 nm. Para Thenkabail et al. (1999), nessa faixa espectral a vegetação é sensível à perda de clorofila, de maturação, senescência, e também é influenciada pelos efeitos de superfície do solo. O terceiro intervalo, na região borda do vermelho, entre 674-731 nm com pico em 709 nm. É uma região sensível ao estresse da vegetação e, fornece a informação adicional sobre o status de clorofila e

nitrogênio das plantas (CLEVERS, 1999; ELVIDGE e CHEN, 1995; SHAW et al. 1998). O quarto intervalo, corresponde a região infravermelho próximo, entre 886-900 nm com pico em 897 nm. É a região de pico ou de máxima reflectância do espectro NIR para determinados tipos e/ou estágios do crescimento da vegetação ou das culturas (Thenkabail et al., 1999, 2000) e também útil para determinar o índice de umidade da cultura (Peñuelas et al. 1993). Em estudo voltado a identificação de plantas espontâneas com imagens RPAS, Bah et al., (2018), foram bem sucedidos ao utilizar as bandas do espectro visível combinadas em imagem RGB, aliadas ao índice ExG (*Excess Green Vegetation Index*), empregando RF na modelagem.

Tabela 8 - Intervalos de comprimento de onda de maior importância para a classificação de *Eucalyptus saligna* x Plantas Espontâneas para cada área de estudo

Área A			
Comprimento de Onda (nm)			
Ranking	Pico	Inicial	Final
1	528	478	588
2	402	400	446
3	703	694	721

Área B			
Comprimento de Onda (nm)			
Ranking	Pico	Inicial	Final
1	551	518	577
2	755	709	811

Área D			
Comprimento de Onda (nm)			
Ranking	Pico	Inicial	Final
1	404	400	437
2	896	842	900
3	677	607	711

Área Geral			
Comprimento de Onda (nm)			
Ranking	Pico	Inicial	Final
1	523	510	589
2	406	400	423
3	709	674	731
4	897	886	900

Fonte: Autor. Santa Maria, RS, UFSM, 2022.

A precisão global, considerando todas as áreas juntas, denominada Área Geral foi de 95,44% de acerto na determinação da classificação entre *Eucalyptus saligna* x Plantas Espontâneas (Tabela 9). Analisando a matriz de confusão da Área Geral, o índice de acerto dentro da classe Plantas Espontâneas é de 99,17%, aonde apenas nove leituras foram erroneamente classificadas como *Eucalyptus saligna*. Embora a precisão dentro da classe *Eucalyptus saligna*, seja aceitável (71,08%), houve um grande número de indivíduos dessa classe confundidos com plantas espontâneas. Tendência essa que se repete ao se analisar as áreas amostrais isoladamente. Esse resultado pode estar relacionado ao desbalanceamento da amostragem, já que a proporção de leituras de *Eucalyptus saligna* é de apenas 13,27% em relação ao total levantado (Apêndice A).

Tabela 9 - Matriz de confusão e estimativa do erro para classificação de *Eucalyptus saligna* x Plantas Espontâneas, utilizando a base de dados hiperespectral

Área A			
	<i>Eucalyptus saligna</i>	Plantas Espontâneas	Erro da Classe
<i>Eucalyptus saligna</i>	41	13	24,07%
Plantas Espontâneas	2	192	1,03%
Estimativa de Erro Total			6,05%
Área B			
	<i>Eucalyptus saligna</i>	Plantas Espontâneas	Erro da Classe
<i>Eucalyptus saligna</i>	39	18	31,58%
Plantas Espontâneas	4	280	1,41%
Estimativa de Erro Total			6,45%
Área D			
	<i>Eucalyptus saligna</i>	Plantas Espontâneas	Erro da Classe
<i>Eucalyptus saligna</i>	47	8	14,55%
Plantas Espontâneas	3	604	0,49%
Estimativa de Erro Total			1,66%
Área Geral			
	<i>Eucalyptus saligna</i>	Plantas Espontâneas	Erro da Classe
<i>Eucalyptus saligna</i>	118	48	28,92%
Plantas Espontâneas	9	1076	0,83%
Estimativa de Erro Total			4,56%

Fonte: Autor. Santa Maria, RS, UFSM, 2022.

5.3.3 Análise hiperespectral por tipo de folha das Plantas Espontâneas

Ao realizar a análise hiperespectral para classificar as plantas espontâneas por tipo de folha, observa-se na Tabela 10, que para todas as áreas incluindo a Área Geral, os cinco primeiros comprimentos de onda de maior importância estão na região da borda do vermelho. Embora essa faixa seja comumente associada ao vigor vegetativo e utilizada para estimativa de parâmetros biofísicos como o conteúdo de clorofila (USTIN e JACQUEMOUD, 2020), a reflectância na borda do vermelho também pode estar associada ao resultado da interação entre a energia eletromagnética e a componente estrutural da folha (CÁRDENAS et al., 2015), a exemplo do que ocorre no infravermelho próximo. Nesse sentido, pode-se inferir que os aspectos relacionados a anatomia foliar (morfologia interna do limbo foliar), tiveram maior relevância na solução encontrada pelo algoritmo RF na distinção entre folha larga x folha estreita. Alguns estudos mostraram que o uso da borda do vermelho pode melhorar a separabilidade entre diferentes características da cobertura do solo, o que desempenha um papel importante na melhoria da precisão da classificação de sensoriamento remoto de culturas (FORKUOR et al., 2017; QIU et al., 2017; KANG et al., 2021).

Tabela 10 - Comprimentos de onda de maior importância segundo o índice de Gini dos modelos RF utilizados para a classificação do tipo de folha das plantas espontâneas nas diferentes áreas de estudo

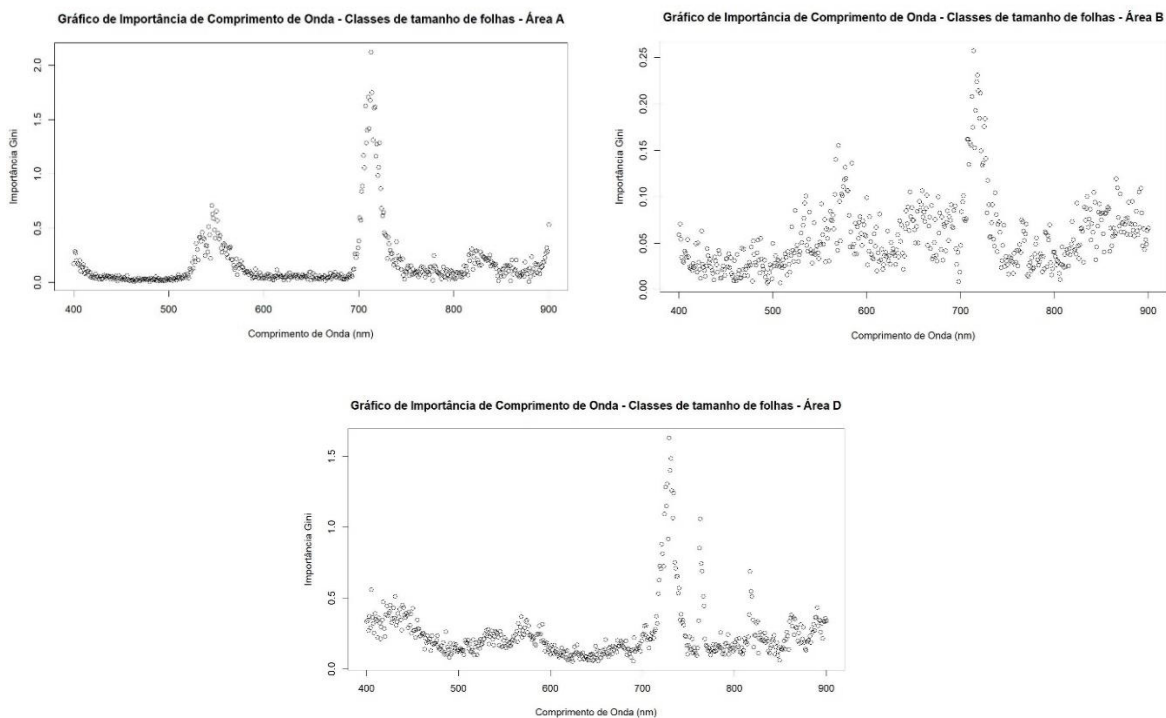
Ranking	Comprimento de Onda (nm)			
	Área A	Área B	Área D	Área Geral
1	711	714	729	711
2	713	718	731	712
3	710	717	730	714
4	714	719	727	710
5	715	721	725	708

Fonte: Autor. Santa Maria, RS, UFSM, 2022.

Quando observando todos dados do índice de Gini para todo o intervalo de espectro estudado (400-900nm), percebe-se a grande concentração de preditores relevantes na região da borda do vermelho (Figura 19). No gráfico da Área A pode-se ver ainda o destaque para a região do verde. A Área B apresenta dados mais

dispersos, além das duas regiões já citadas, apresenta certa concentração de importância no vermelho e infravermelho próximo, conforme a Tabela 11. A Área D também apresenta destaque para região da borda do vermelho, com menor importância na região do azul e picos locais no infravermelho próximo.

Figura 19 - Representação gráfica da importância dos comprimentos de onda como preditores segundo o índice de Gini dos modelos RF utilizados na classificação do tipo foliar das plantas espontâneas para as diferentes áreas de estudo



Fonte: Autor. Santa Maria, RS, UFSM, 2022.

O gráfico da Figura 20, representando a importância dos preditores do modelo RF compondo a Área Geral, traz novamente o destaque para região da borda do vermelho. A síntese da análise estatística do terceiro quartil é apresentada na Tabela 11. Para a Área Geral, o ranking traz um primeiro intervalo situado na borda do vermelho, entre 695 e 733 nm, com pico em 711 nm. O segundo intervalo de comprimento de onda mais importante refere-se a região do azul de 400 a 425 nm e com pico em 402 nm. Um terceiro intervalo contempla região do verde de 521 a 582 nm e com pico em 574 nm e, por fim o último intervalo contempla a região do infravermelho próximo de 762 e 768 nm.

Tabela 11 - Intervalo de comprimento de onda de maior importância para a classificação do tipo folhar das plantas espontâneas para cada área de estudo.

Área A			
Comprimento de Onda (nm)			
Ranking	Pico	Inicial	Final
1	711	695	747
2	547	526	576
3	815	815	900

Área B			
Comprimento de Onda (nm)			
Ranking	Pico	Inicial	Final
1	714	701	738
2	570	524	614
3	866	824	893
4	659	635	694

Área D			
Comprimento de Onda (nm)			
Ranking	Pico	Inicial	Final
1	729	702	745
2	763	761	767
3	817	816	825
4	405	400	457
5	890	860	900
6	568	565	591

Área Geral			
Comprimento de Onda (nm)			
Ranking	Pico	Inicial	Final
1	711	695	733
2	402	400	425
3	574	521	582
4	763	762	768

Fonte: Autor. Santa Maria, RS, UFSM, 2022

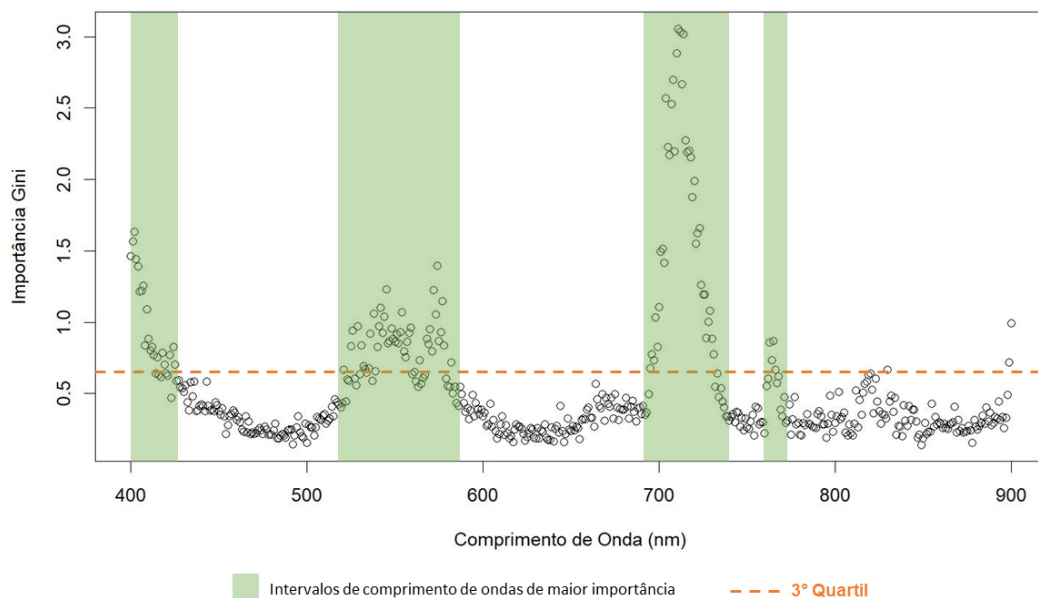
Além da borda do vermelho a região correspondente ao azul também apresentou relevância no processo de classificação. Uso de bandas na faixa do azul é tradicionalmente questionável em sensoriamento remoto orbital e, mesmo aéreo, devido à sensibilidade dessa região aos efeitos atmosféricos, que eventualmente, mesmo com o avanço nos processos de correção atmosférica, podem incorporar mais ruído aos dados, do que informações sobre as propriedades da vegetação (JIANG et al., 2008).

Entretanto, as condições de estresse hídrico evidenciadas na Área D podem ter atribuído maior importância a banda do azul. Para Jensen (2009), quando a planta é afetada por estresse, os pigmentos de clorofila podem desaparecer, permitindo que os carotenos e outros pigmentos tornem-se dominantes. De acordo

com Ponzoni et al. (2012), dentre os principais pigmentos encontrados nos cloroplastos (clorofilas, carotenos e xantofilas), somente a clorofila absorve na região do vermelho. Dessa forma, com a degradação da clorofila, decorrente da restrição hídrica, a azul ganha relevância em detrimento da região do vermelho.

Ao utilizar dados de satélite e imagens multiespectrais RPAS para caracterizar a competição entre plantas espontâneas e plantios de *Pinus sp.*, Watt et al. (2016), demonstraram que além de índices de vegetação, a banda do azul teve grande impacto positivo nos modelos.

Figura 20 - Representação gráfica da importância dos comprimentos de onda como preditores segundo o índice de Gini dos modelos RF utilizados na classificação do tipo foliar das plantas espontâneas para todas as áreas amostrais em conjunto (Área Geral)



Fonte: Autor. Santa Maria, RS, UFSM, 2022.

A precisão global, da Área Geral (Tabela 12) resultante para determinar as variáveis preditoras na classificação por tipo de folha foi de 94,29%, no qual o erro para classificar folhas largas foi de 1,61% e para folhas estreitas 30,13%. Esse fato pode ser atribuído ao número menor de leituras com o espectrorradiômetro para folhas estreitas, de apenas 15% em relação ao total amostrado, conforme a Tabela 6. Na Tabela 12 é possível visualizar ainda que em todas as áreas amostrais o erro é maior para a classe de folha estreita, com destaque para a Área B, onde as 15 leituras dessa classe são de indivíduos de apenas uma espécie e, como o algoritmo classificou essas repetições como folha larga, o erro dentro da classe folha estreita,

foi de 100%. Dessa forma, assim como ocorreu na classificação *Eucalyptus saligna* x Plantas espontâneas, o desbalanceamento entre o número de amostras entre as classes Folha Estreita x Folha Larga, teve efeito direto na precisão da classificação.

Tabela 12 - Matriz de confusão e estimativa do erro para classificação do tipo foliar das plantas espontâneas, utilizando a base de dados hiperespectral

Área A			
	Estreita	Larga	Erro da Classe
Estreita	65	6	8,45%
Larga	8	115	6,50%
Estimativa de Erro Total			7,22%
Área B			
	Estreita	Larga	Erro da Classe
Estreita	0	15	100%
Larga	0	269	0,00%
Estimativa de Erro Total			5,28%
Área D			
	Estreita	Larga	Erro da Classe
Estreita	52	18	25,71%
Larga	5	532	0,93%
Estimativa de Erro Total			1,81%
Área Geral			
	Estreita	Larga	Erro da Classe
Estreita	109	47	30,13%
Larga	15	914	1,61%
Estimativa de Erro Total			5,71%

Fonte: Autor. Santa Maria, RS, UFSM, 2022.

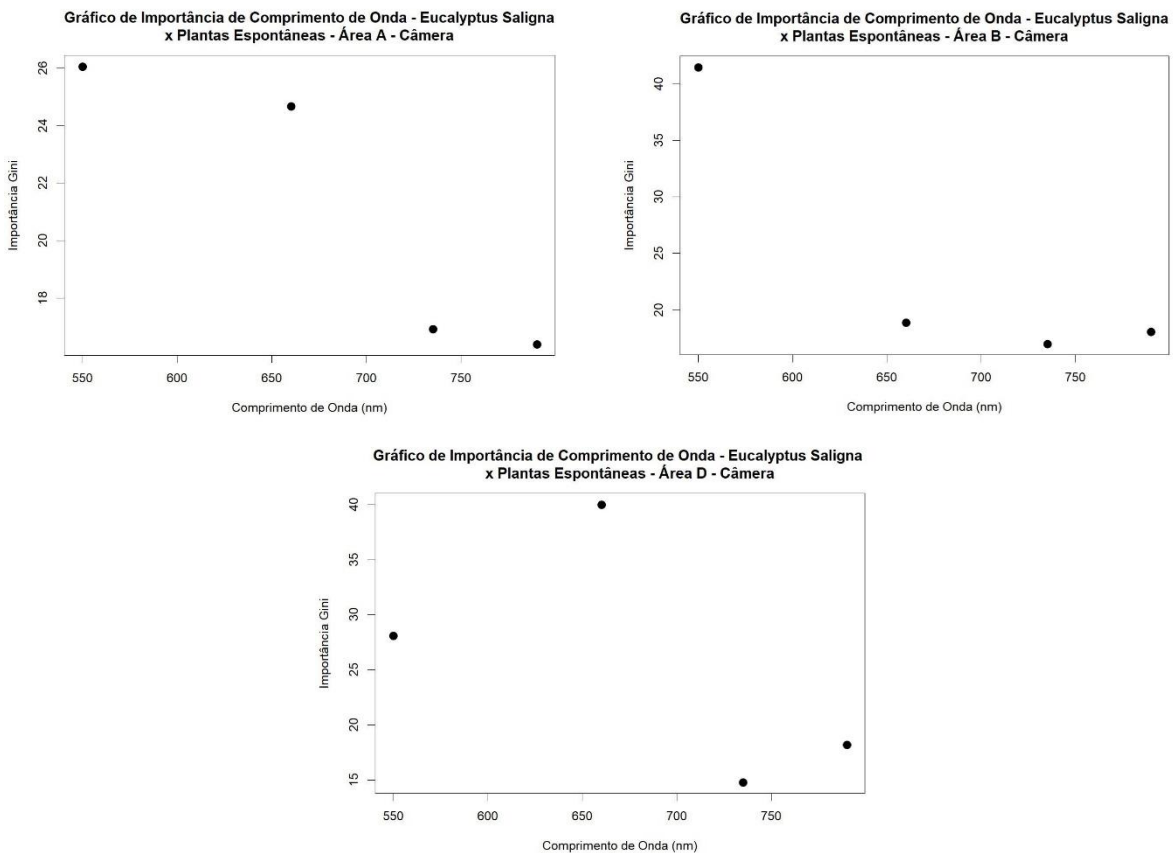
5.3.4 Análise multiespectral para a classificação do *Eucalyptus saligna* x Plantas Espontâneas

Os intervalos encontrados de comprimento de onda com a análise hiperespectral dos dados do espectrorradiômetro para classificação do *Eucalyptus saligna* x Plantas Espontâneas apresentam semelhança com os intervalos de comprimento de onda da câmera multiespectral Parrot Sequoia, exceto a região do azul que a câmera não possui. Assim, ao compilar as leituras do espectrorradiômetro das espécies para a média de cada banda da câmera, observa-se na Figura 21 e Tabela 13, que em todas as áreas a região do visível demonstrou maior relevância

em relação as demais bandas da câmera (borda do vermelho e infravermelho próximo). A Área A e B obtiveram a mesma sequência no visível, priorizando a banda do verde, alternando a prioridade na borda do vermelho e do infravermelho. Já Área D priorizou a banda do vermelho como variável preditora de maior importância, influenciada pela mistura espectral entre solo e vegetação, bem como a baixa atividade fotossintética em função da restrição hídrica do período de coleta de dados.


A análise de todas as áreas em conjunto, denominada Área Geral, apresentou o mesmo ranking de importância das bandas para as áreas A e B. A sequência em ordem de relevância das variáveis no modelo é: Banda do verde, vermelho, borda do vermelho e por fim, infravermelho próximo (Figura 22 e Tabela 13).

Figura 21 - Representação gráfica da importância das bandas espectrais como preditores segundo o índice de Gini dos modelos RF utilizados na classificação *Eucalyptus saligna* x Plantas Espontâneas para cada área de estudo



Fonte: Autor. Santa Maria, RS, UFSM, 2022.

Figura 22 - Representação gráfica da importância das bandas espectrais como preditores segundo o índice de Gini dos modelos RF utilizados na classificação *Eucalyptus saligna* x Plantas Espontâneas para todas as áreas amostrais em conjunto (Área Geral)



Fonte: Autor. Santa Maria, RS, UFSM, 2022.

Tabela 13 – Bandas espectrais de maior importância segundo o índice de Gini dos modelos RF utilizados na classificação de *Eucalyptus saligna* x Plantas Espontâneas para cada área de estudo

Ranking	Área A	Área B	Área D	Área Geral
1	Verde	Verde	Vermelho	Verde
2	Vermelho	Vermelho	Verde	Vermelho
3	Borda do Vermelho	Infravermelho Próximo	Infravermelho Próximo	Borda do Vermelho
4	Infravermelho Próximo	Borda do Vermelho	Borda do Vermelho	Infravermelho Próximo

Fonte: Autor. Santa Maria, RS, UFSM, 2022.

A precisão global, da Área Geral (Tabela 14) foi de 93,05 % de acerto na determinação da classificação entre *Eucalyptus saligna* x Plantas Espontâneas. Analisando a matriz de confusão da Área Geral, o índice de acerto dentro da classe Plantas Espontâneas é de 98,16%, já para a classe *Eucalyptus saligna*, esse valor cai para 59,64%. Essa mesma tendência de proporção de precisão ocorreu para as áreas individuais. A área amostral A, apresentou a menor precisão na classificação dentre as demais, com 46,30% de erro dentro da classe *Eucalyptus saligna*. Como já referido, o desbalanceamento entre o número de amostras para as diferentes classes, é um dos fatores que contribui para elevar o erro do modelo. Além desse, a

degradação da resolução espectral para intervalos da câmera gerando apenas quatro variáveis preditoras afetou a precisão do modelo, quando comparado com a abordagem hiperespectral. Nesse sentido, apesar de o modelo apresentar uma alta precisão, tendo em vista o erro global, cerca de 40% dos indivíduos de *Eucalyptus saligna* serão classificados erroneamente e aumentarão a densidade de plantas espontâneas (falsos positivos de plantas espontâneas).

Tabela 14 - Matriz de confusão e estimativa do erro para classificação de *Eucalyptus saligna* x Plantas Espontâneas, utilizando a base de dados multiespectral

Área A			
	<i>Eucalyptus saligna</i>	Plantas Espontâneas	Erro da Classe
<i>Eucalyptus saligna</i>	29	25	46,30%
Plantas Espontâneas	8	186	4,12%
Estimativa de Erro Total			13,31%
Área B			
	<i>Eucalyptus saligna</i>	Plantas Espontâneas	Erro da Classe
<i>Eucalyptus saligna</i>	37	20	35,09%
Plantas Espontâneas	3	281	1,06%
Estimativa de Erro Total			6,74%
Área D			
	<i>Eucalyptus saligna</i>	Plantas Espontâneas	Erro da Classe
<i>Eucalyptus saligna</i>	45	10	18,18%
Plantas Espontâneas	7	600	1,15%
Estimativa de Erro Total			2,57%
Área Geral			
	<i>Eucalyptus saligna</i>	Plantas Espontâneas	Erro da Classe
<i>Eucalyptus saligna</i>	99	67	40,36%
Plantas Espontâneas	20	1065	1,84%
Estimativa de Erro Total			6,95%

Fonte: Autor. Santa Maria, RS, UFSM, 2022.

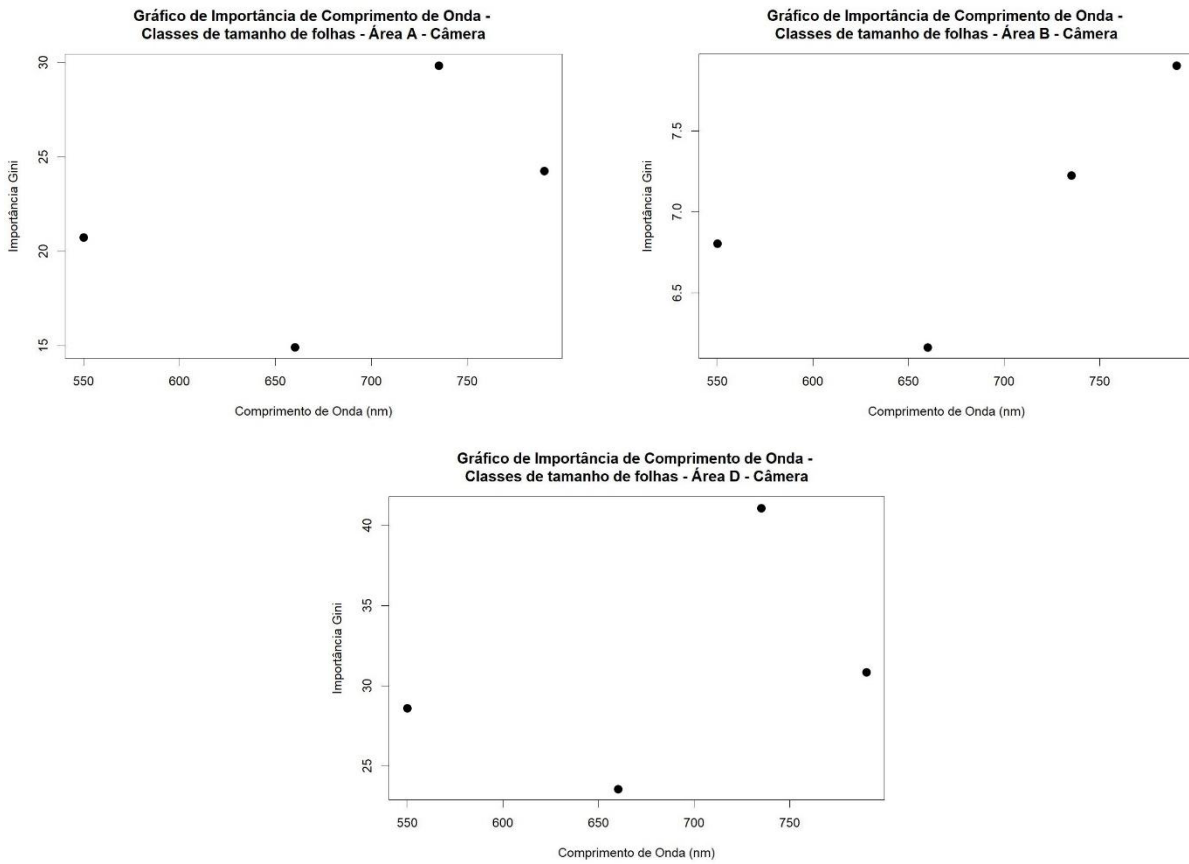
5.3.5 Análise multiespectral para o tipo de folha das Plantas Espontâneas

Ao analisar o gráfico da Figura 23, bem como a Tabela 15, observa-se que ao realizar a abordagem multiespectral para classificar as plantas espontâneas por tipo de folha, a banda da borda do vermelho e do infravermelho próximo, tiveram maior destaque na classificação, de acordo com o índice de Gini. As áreas A e D apresentaram o mesmo comportamento em relação a ordem de importância, enquanto a Área B apenas inverteu a ordem de importância, colocando a banda do infravermelho próximo como a mais relevante.

O gráfico da Área Geral (Figura 24) apresenta a borda do vermelho e infravermelho próximo como dois preditores mais importantes para determinar o tipo de folha das plantas espontâneas. A precisão global total para essa determinação foi de 90,41% (Tabela 16), na matriz de confusão as folhas largas obtiveram um erro de 2,58% enquanto as folhas do tipo estreita concentraram um erro de 51,28%, devido à baixa proporção amostral.


De maneira geral a degradação da resolução espectral, restrito aos intervalos de comprimento de onda da câmera, também influenciou na precisão da classificação do tipo de folhas.

Figura 23 - Representação gráfica da importância das bandas espectrais como preditores segundo o índice de Gini dos modelos RF utilizados na classificação do tipo foliar das plantas espontâneas para cada área de estudo



Fonte: Autor. Santa Maria, RS, UFSM, 2022.

Figura 24 - Representação gráfica da importância das bandas espectrais como preditores segundo o índice de Gini dos modelos RF utilizados na classificação do tipo foliar das plantas espontâneas para as áreas amostrais reunidas (Área Geral)



Fonte: Autor. Santa Maria, RS, UFSM, 2022.

Tabela 15 - Bandas espectrais de maior importância segundo o índice de Gini dos modelos RF utilizados na classificação do tipo foliar das plantas espontâneas para cada área de estudo

Ranking	Área A	Área B	Área D	Área Geral
1	Borda do Vermelho	Infravermelho Próximo	Borda do Vermelho	Borda do Vermelho
2	Infravermelho Próximo	Borda do Vermelho	Infravermelho Próximo	Infravermelho Próximo
3	Verde	Verde	Verde	Verde
4	Vermelho	Vermelho	Vermelho	Vermelho

Fonte: Autor. Santa Maria, RS, UFSM, 2022.

Tabela 16 - Matriz de confusão e estimativa do erro para classificação do tipo foliar das plantas espontâneas, utilizando a base de dados multiespectral

Área A			
	Folha Estreita	Folha Larga	Erro da Classe
Folha Estreita	61	10	14,08%
Folha Larga	11	112	8,94%
Estimativa de Erro Total			10,82%
Área B			
	Folha Estreita	Folha Larga	Erro da Classe
Folha Estreita	0	15	100%
Folha Larga	1	268	0,37%
Estimativa de Erro Total			5,63%
Área D			
	Folha Estreita	Folha Larga	Erro da Classe
Folha Estreita	45	25	35,71%
Folha Larga	12	525	2,23%
Estimativa de Erro Total			6,10%
Área Geral			
	Folha Estreita	Folha Larga	Erro da Classe
Folha Estreita	76	80	51,28%
Folha Larga	24	905	2,58%
Estimativa de Erro Total			9,59%

Fonte: Autor. Santa Maria, RS, UFSM, 2022.

5.4 CONCLUSÃO

A abordagem utilizando o algoritmo RF na modelagem de dados espectrorradiométricos permitiu identificar as porções do espectro eletromagnético de maior capacidade para os dois níveis de classificação propostos: Plantas Espontâneas x *Eucalyptus saligna* e, plantas espontâneas do tipo Folha larga x Folha estreita.

Utilizando dados hiperespectrais, o modelo RF atingiu precisão global de 95,44% na classificação entre *Eucalyptus saligna* e plantas espontâneas, sendo quatro intervalos espectrais de maior importância para a classificação: 510 a 589 nm, 400 a 423 nm, 674 a 731 nm e 886 a 900 nm. Na abordagem multiespectral, ao concentrar os preditores nas quatro bandas da câmera Parrot Sequoia, a precisão global do modelo foi de 94,05%, com maior relevância atribuída as bandas do verde e vermelho.

Ao trabalhar a classificação do tipo foliar das plantas espontâneas utilizando a base de dados hiperespectral, o modelo RF atingiu 94,29% de precisão global, com quatro intervalos espectrais mais relevantes na classificação: 695 a 733 nm, 400 a 425 nm, 521 a 582 nm e 762 a 768 nm. Já utilizando a base de dados multiespectral, o modelo teve precisão global de 90,41%, como maior importância a borda do vermelho e infravermelho próximo.

5.5 REFERÊNCIAS

ADAM, E.; DENG, H.; ODINDI, J.; ABDEL-RAHMAN, E. M.; MUTANGA, O. Detecting the early stage of phaeosphaeria leaf spot infestations in maize crop using in situ hyperspectral data and guided regularized random forest algorithm. **Journal of Spectroscopy**, v. 2017, 2017.

ADAM, E. M.; MUTANGA, O.; RUGEGE D.; ISMAIL R. Discriminating tine papyrus vegetation (*Cyperus papyrus* L.) and its co-existent species using random forest and hyperspectral data resampled to HYMAP. **International Journal of Remote Sensing**, v. 33, n. 2, p. 552-569, 2012.

ALBA, E. **Influência e análise da cobertura florestal na modificação do albedo com o uso de inteligência artificial e sensoriamento remoto**. 2019. Tese (Doutorado em Engenharia Florestal) – Universidade Federal de Santa Maria, Santa Maria, RS, 2019.

AMINI, S.; HOMAYOUNI, S.; SAFARI, A.; DARVISHSEFAT, A. A. Object-based classification of hyperspectral data using Random Forest algorithm.

<http://www.tandfonline.com/action/journalInformation?show=aimsScope&journalCode=tgsi20#.VsXpLiCLRhE>, v. 21, n. 2, p. 127–138, 2018. Taylor & Francis. Disponível em:

<<https://cogentoa.tandfonline.com/doi/abs/10.1080/10095020.2017.1399674>>.

Acesso em: 09 ago. 2022.

ASD. Analytical Spectral Devices. 2006. **FiedSpec 3 Spectroradiometer**. 5335 Sterling Drive, Boulder, Colorado – United States, 2006.

BAH, M. D., HAFIANE, A., CANALS, R. "Deep Learning with Unsupervised Data Labeling for Weed Detection in Line Crops in UAV Images", **Remote Sensing**, v. 10, n. 11, p. 1690, 26 out. 2018. DOI: 10.3390/RS10111690. Disponível em:

<<https://www.mdpi.com/2072-4292/10/11/1690/htm>>. Acesso em: 12 ago. 2022.

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

Disponível em:

<<https://link.springer.com/content/pdf/10.1023%2FA%3A1010933404324.pdf>>.

Acesso em: 08 ago. 2021.

CÁRDENAS, J. L. S., ROMERO, N. C., PIZAÑA, J. M. G., *et al.*, "**Geospatial technologies to support coniferous forests research and conservation efforts in Mexico**". In: WEBER, R. P. (Org.), *Old-Growth Forests and Coniferous Forests: Ecology, Habitat and Conservation*, [S.l.], Nova Science Publishers, 2015.

CATUREGLI, L.; MATTEOLI, S.; GAETANI, M.; *et al.* Effects of water stress on spectral reflectance of bermudagrass. **Scientific Reports**, v. 10, n. 1, 2020. Nature Publishing Group. Disponível em: </pmc/articles/PMC7490272/>. Acesso em: 11 ago. 2022.

CLEVERS, J. G. P. W. The use of imaging spectrometry for agricultural applications. **ISPRS Journal of Photogrammetry and Remote Sensing**, 54(5–6), 299–304. 1999.

CSTARS. Center for Spatial Technologies and Remote Sensing. Department of Land, Air and Water resources. University of California, Davis. **SAMS - Spectral Analysis and Management System**. Versão 3.2. Disponível em:

<<http://cstars.metro.ucdavis.edu/resources/software>>. Acesso em: 08 ago. 2022.

ELVIDGE, C.D.; CHEN, Z. Comparison of broad and narrow-band red and near-infrared vegetation indices. **Remote Sensing of Environment**, New York, v. 54, p.38-48, 1995.

EUGENIO, F. C.; BADIN, T. L.; FERNANDES, P.; *et al.* Remotely Piloted Aircraft Systems (RPAS) and machine learning: A review in the context of forest Science. **International Journal of Remote Sensing**, v. 42, n. 21, p. 8207–8235, 2021. Taylor & Francis. Disponível em:

<<https://www.tandfonline.com/doi/abs/10.1080/01431161.2021.1975845>>. Acesso em: 16 ago. 2022.

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

FORKUOR, G.; DIMOBE, K.; SERME, I.; TONDOH, J. E. Landsat-8 vs. Sentinel-2: examining the added value of sentinel-2's red-edge bands to land-use and land-cover mapping in Burkina Faso. **GIScience & Remote Sensing**, v. 55, n. 3, p. 331–354, 2017. Taylor & Francis. Disponível em:

<<https://www.tandfonline.com/doi/abs/10.1080/15481603.2017.1370169>>. Acesso em: 12 ago 2022.

HAN, H.; GUO, X.; YU, H. Variable selection using Mean Decrease Accuracy and Mean Decrease Gini based on Random Forest. **Proceedings of the IEEE International Conference on Software Engineering and Service Sciences, ICSESS**, v. 0, p. 219–224, 2016. IEEE Computer Society. Acesso em: 01 ago. 2022.

INMET. Instituto Nacional de Meteorologia. Banco de Dados Meteorológicos. Disponível em: <<https://bdmep.inmet.gov.br/>>. Acesso em: 10 ago. 2022.

JENSEN, J. R. **Sensoriamento Remoto do Ambiente: Uma perspectiva em Recursos Naturais**. São José dos Campos, SP: Parêntese, 598 p. 2009.

JIANG, Z.; HUETE, A. R.; DIDAN, K.; MIURA, T. Development of a two-band enhanced vegetation index without a blue band. **Remote Sensing of Environment**, v. 112, n. 10, p. 3833–3845, 2008. Elsevier. Acesso em: 12 ago. 2022.

LABSPHERE. **Spectralon® Diffuse Reflectance Standards**. Disponível em: <<https://www.labsphere.com/labsphere-products-solutions/materials-coatings-2/targets-standards/diffuse-reflectance-standards/diffuse-reflectance-standards/>>. Acesso em: 08 ago. 2022.

LIAW, A.; WIENER, M. **Classification and Regression by RandomForest**. 2002.

LIPPERT, D. B.; BENEDETTI, A. C. P.; PEREIRA, R. S.; MUNIZ, M. F. B. Espectrorradiometria de folhas de *Eucalyptus camaldulensis* Dehnh. atacadas por *Phaeophleospora eucalypti* - PDF Free Download. Anais do XIV Simpósio Brasileiro de Sensoriamento Remoto. **Anais...** p.2793–2799, 2009. Natal- RN. Disponível em: <<https://docplayer.com.br/88741180-Espectrorradiometria-de-folhas-de-eucalyptus-camaldulensis-dehnh-atacadas-por-phaeophleospora-eucalypti.html>>. Acesso em: 16 ago. 2022.

LORENZI, H.; NICOLAI, M.; BIANCHI, M. A.; *et al.* **Manual de identificação e controle de plantas daninhas - Plantio direto e Convencional**. Instituto Plantarum, 7.ed, 383p., 2014.

MALENOVSKÝ, Z.; LUCIEER, A.; KING, D. H.; TURNBULL, J. D.; ROBINSON, S. A. Unmanned aircraft system advances health mapping of fragile polar vegetation. **Methods in Ecology and Evolution**, v. 8, n. 12, p. 1842–1857, 2017. John Wiley & Sons, Ltd. Disponível em: <<https://onlinelibrary.wiley.com/doi/full/10.1111/2041-210X.12833>>. Acesso em: 16 ago. 2022.

MARCHESAN, J.; ALBA, E.; SCHUH, M. S.; FAVARIN, J. A. S.; PEREIRA, R. S. Aboveground Biomass Estimation in a Tropical Forest With Selective Logging Using Random Forest and Lidar Data. **Floresta**, v. 50, n. 4, p. 1873, 2020. Disponível em: <<https://revistas.ufpr.br/floresta/article/view/66589>>. Acesso em: 08 ago. 2021.

- MARTINEZ-TABOADA, F.; REDONDO, J. I. The SIESTA (SEAAV Integrated evaluation sedation tool for anaesthesia) project: Initial development of a multifactorial sedation assessment tool for dogs. **PLOS ONE**, v. 15, n. 4, p. e0230799, 2020. Public Library of Science. Disponível em: <<https://journals.plos.org/plosone/article?id=10.1371/journal.pone.0230799>>. Acesso em: 09 ago. 2022.
- MIRANDA, E. N.; HENRIQUE GROENNER BARBOSA, B.; HENRIQUE GODINHO SILVA, S.; et al. Variable selection for estimating individual tree height using genetic algorithm and random forest. **Forest Ecology and Management**, v. 504, 2022. Elsevier B.V. Acesso em: 16 ago. 2022.
- MONTANO, R. A. N. R. **Aplicação de Técnicas de Aprendizado de Máquina na Mensuração Florestal**. Tese (Doutorado em Informática). 2016. Universidade Federal do Paraná. Programa de Pós-Graduação em Informática. Disponível em: <<https://acervodigital.ufpr.br/bitstream/handle/1884/45346/R-T-RAZERANTHOMNIZERROJASMONTANO.pdf?sequence=1&isAllowed=y>>. Acesso em: 12 ago. 2022.
- NICHOL, C. J., HUENNRICH, K. F., BLACK, T. A., JARVIS, P. G., WALTHALL, C. L., GRACE, J., & HALL, F. G. Remote sensing of photosynthetic-light-use efficiency of boreal forest. **Agricultural and Forest Meteorology**, 101(2–3), 131–142, 2000.
- PARROT. **Parrot Sequoia**. 2022. Disponível em: <<https://www.parrot.com/business-solutions-us/parrot-professional/parrot-sequoia>>. Acesso em: 08 ago. 2022.
- PEÑUELAS, J. et al. The reflectance at the 950—970 nm region as an indicator of plant water status. **International Journal of Remote Sensing**. v.14, p.1887-1905, 1993.
- PONZONI, F. J.; SHIMABUKURO, Y. E.; KUPLICH, T. M. **Sensoriamento remoto da vegetação**. 2ª edição. São Paulo: Oficina dos Textos, 160 p., 2012.
- POONA, N. K.; VAN NIEKERK, A.; NADEL, R. L.; ISMAIL, R. Random Forest (RF) Wrappers for Waveband Selection and Classification of Hyperspectral Data. **Applied Spectroscopy**, v. 70, n. 2, p. 322–333, 2016. Disponível em: <<https://doi.org/10.1177/0003702815620545>>. Acesso em: 08 ago. 2022.
- QIU, S.; HE, B.; YIN, C.; LIAO, Z. ASSESSMENTS OF SENTINEL-2 VEGETATION RED-EDGE SPECTRAL BANDS FOR IMPROVING LAND COVER CLASSIFICATION. **The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. XLII-2-W7, n. 2W7, p. 871–874, 2017. Copernicus GmbH. Disponível em: <<https://doi.org/10.5194/isprs-archives-XLII-2-W7-871-2017>>. Acesso em: 12 ago. 2022.
- KANG, Y.; MENG, Q.; LIU, M.; ZOU, Y.; WANG, X. Crop Classification Based on Red Edge Features Analysis of GF-6 WFV Data. **Sensors (Basel, Switzerland)**, v. 21, n. 13, 2021. Multidisciplinary Digital Publishing Institute (MDPI). Disponível em: <pmc/articles/PMC8271903/>. Acesso em: 12 ago. 2022.

KUMAR, A.; PATIDAR, V.; KHAZANCHI, D.; SAINI, P. Role of Feature Selection on Leaf Image Classification. **Journal of Data Analysis and Information Processing**, v. 03, n. 04, p. 175–183, 2015. Scientific Research Publishing. Disponível em: <<http://file.scirp.org/Html/>>. Acesso em: 09 ago. 2022.

R Core Team. **R: The R Project for Statistical Computing**. 2021. Vienna, Áustria. Disponível em: <<https://www.r-project.org/>>.

RStudio Team. **RStudio: Integrated Development Environment for R**. 2021. Boston, MA: RStudio, PBC. Disponível em: <<http://www.rstudio.com/>>.

SHAW, D. T.; MALTHUS, T. J.; KUPIEC, J. A. High-spectral resolution data for monitoring Scots pine (*Pinus sylvestris* L.) regeneration. **International Journal of Remote Sensing**, 19:13, 2601-2608, 1998.

SCHUH, M. S.; FAVARIN, J. A. S.; DESSBESELL, L.; et al. Temporal analysis of vegetative vigor through spectroradiometry. **Revista Brasileira de Geografia Física**, v. 9, n. 6, 2016.

THENKABAIL, P. S., R. B. SMITH, AND E. DE PAUW. "**Hyperspectral vegetation indices for determining agricultural crop characteristics**, CEO research publication series No. 1." Center for Earth Observation, Yale University Press, New Haven, 1999.

THENKABAIL, P.s.; SMITH, R.B.; DE-PAUW, E. Hyperspectral vegetation indices for determining agricultural crop characteristics. **Remote Sensing of Environment**, New York, v. 71, p.158-182, 2000.

USTIN, S. L., JACQUEMOUD, S., "How the optical properties of leaves modify the absorption and scattering of energy and enhance leaf functionality". **Remote Sensing of Plant Biodiversity**. Springer International Publishing, 2020. p. 349–384. DOI: 10.1007/978-3-030-33157-3_14/FIGURES/16. Disponível em: https://link.springer.com/chapter/10.1007/978-3-030-33157-3_14. Acesso em: 12 ago. 2022.

WANG, Y.; ZANG, S.; TIAN, Y. Mapping paddy rice with the random forest algorithm using MODIS and SMAP time series. **Chaos, Solitons & Fractals**, v. 140, p. 110116, 2020. Pergamon. Acesso em: 09 ago. 2022.

WATT, M. S.; HEAPHY, M.; DUNNINGHAM, A.; ROLANDO, C. Use of remotely sensed data to characterize weed competition in forest plantations., v. 38, n. 8–10, p. 2448–2463, **International Journal of Remote Sensing** 2016. Disponível em: <<https://www.tandfonline.com/doi/abs/10.1080/01431161.2016.1230290>>. Acesso em: 14 ago. 2022.

APÊNDICE A - TABELA COM A PROPORÇÃO AMOSTRAL EM RELAÇÃO AS ESPÉCIES LEVANTADAS NA ÁREA DE ESTUDO

	Espécie	Intensidade Amostrai		Espécie	Intensidade Amostrai
1	<i>Acanthospermum hispidum</i>	1,20%	28	<i>Glycine max</i>	3,60%
2	<i>Aeschynomene rudis</i>	1,20%	29	<i>Helichrysum bracteatum</i>	2,32%
3	<i>Ageratum conyzoides</i>	1,20%	30	<i>Ipomoea hederifolia</i>	1,20%
4	<i>Amaranthus viridis</i>	1,92%	31	<i>Isatis tinctoria</i>	2,16%
5	<i>Ambrosia artemisiifolia</i>	5,20%	32	<i>Lantana camara</i>	1,20%
6	<i>Athyrium filix-femina</i>	1,12%	33	Não Identificada 1	1,36%
7	<i>Bidens pilosa</i>	3,60%	34	Não Identificada 2	1,20%
8	<i>Brachiaria decumbens</i>	0,96%	35	Não Identificada 3	1,20%
9	<i>Brachiaria plantaginea</i>	1,20%	36	Não Identificada 4	1,20%
10	<i>Campomanesia adamantium</i>	1,20%	37	Não Identificada 6	1,20%
11	<i>Citrus sinensis</i>	1,20%	38	Não Identificada 7	1,20%
12	<i>Commelina erecta</i>	1,20%	39	Não Identificada 8	1,20%
13	<i>Commelina ssp.</i>	3,28%	40	Não Identificada 9	1,20%
14	<i>Conyza bonariensis</i>	3,60%	41	Não Identificada 10	1,20%
15	<i>Croton hirtus</i>	2,40%	42	<i>Oxalis corniculata</i>	1,20%
16	<i>Cyperus flavus</i>	2,40%	43	<i>Porophyllum ruderale</i>	1,20%
17	<i>Cyperus rotundus</i>	1,12%	44	<i>Raphanus raphanistrum</i>	1,20%
18	<i>Daphne gnidium</i>	2,16%	45	<i>Rhynchosia latifolia</i>	1,20%
19	<i>Desmodium adscendens</i>	1,20%	46	<i>Sida rhombifolia</i>	1,20%
20	<i>Digitaria horizontalis</i>	1,04%	47	<i>Smilax aspera</i>	1,20%
21	<i>Digitaria insularis</i>	0,96%	48	<i>Solanum sisymbriifolium</i>	3,76%
22	<i>Digitaria sanguinalis</i>	1,20%	49	<i>Solidago chilensis</i>	1,20%
23	<i>Eragrostis plana</i>	1,20%	50	<i>Spermacoce verticillata</i>	2,32%
24	<i>Erechtites hieraciifolius</i>	1,92%	51	<i>Taraxacum officinale</i>	2,40%
25	<i>Eucalyptus saligna</i>	13,27%	52	<i>Trema micrantha</i>	1,20%
26	<i>Euphorbia heterophylla</i>	1,20%	53	<i>Verbena bonariensis</i>	1,20%
27	<i>Gamochaeta pensylvanica</i>	1,20%			

Fonte: Autor. Santa Maria, RS, UFSM, 2022.

6 CAPITULO III – MAPEAMENTO DE DENSIDADE DE PLANTAS ESPONTANEAS EM PLANTIO DE *EUCALYPTUS SALIGNA* UTILIZANDO INTELIGENCIA ARTIFICIAL COM IMAGENS MULTIESPECTRAIS PROVENIENTES DE RPAS

RESUMO

A capacidade de monitoramento automatizado dos povoamentos florestais é um atributo fundamental da silvicultura de precisão. O levantamento preciso e de alta resolução é um pré-requisito fundamental para a intervenção direcionada no manejo das áreas produtivas. Nesse sentido, o objetivo desse trabalho foi modelar e mapear a incidência de plantas espontâneas em plantios comerciais de *Eucalyptus saligna* utilizando ferramentas de inteligência artificial e imagens multiespectrais de sensor embarcado em RPAS. Para tanto, foram tomadas imagens com a câmera Sequoia, embarcada no RPAS Phantom 4 Pro, em quatro áreas de produção, com 54 dias de plantio em média. Além das bandas espectrais, os índices de vegetação GNDVI, GRVI, MCARI, NDRE NDVI, serviram de entrada no processo de segmentação pelo algoritmo *K-means* no software Orfeo ToolBox 8.0. A base de dados derivada foi então rotulada e particionada para treinamento e teste. O modelo de classificação utilizando o algoritmo *Random Forest*, foi implementado em linguagem R. O modelo treinado e validado foi colocado em produção, com a elaboração de mapas temáticos. Como resultado, na fase de teste, o modelo treinado gerou estimativas com precisão global de 95,49% na classificação das categorias Plantas Espontâneas, *Eucalyptus saligna* e *Eucalyptus saligna* rebrote. Dessa forma foi possível obter produtos cartográficos de alta precisão contendo o indicativo da densidade de plantas espontâneas. Os produtos gerados por essa técnica são informações de suma importância para o gerenciamento, manejo e controle nas áreas de produção silvicultural.

Palavras-chave: Aprendizado de Máquina. Modelagem Preditiva. Silvicultura de Precisão. RPAS.

ABSTRACT

The ability of a automated monitored forest stands, is a key attribute of precision forestry. Accurated and with high-resolution surveys are a fundamental prerequisite for targeted intervention in the management of productive areas. In this sense, the objective of this work was to model and map the incidence of weeds in commercial plantations of *Eucalyptus saligna* using artificial intelligence tools and multispectral images from an embedded sensor in RPAS. For that, images were taken with the Sequoia camera, on board the RPAS Phantom 4 Pro, in four production areas, with an average of 54 days of planting. In addition to the spectral bands, the vegetation indices GNDVI, GRVI, MCARI, NDRE NDVI, served as input in the segmentation process by the K-means algorithm in the Orfeo ToolBox 8.0 software. The resulting database was then labeled and partitioned for training and testing. The classification model using the Random Forest algorithm was implemented in R language. The trained and validated model was put into production, with the elaboration of thematic maps. As a result, in the test phase, the trained model generated estimates with an overall accuracy of 95.49% in the classification of the categories Weed, *Eucalyptus saligna* and *Eucalyptus saligna* regrowth. In this way, it was possible to obtain high-precision cartographic products containing the indicative of the density of weed. The

products generated by this technique are extremely important information for the management, handling and control in silvicultural production areas.

Keywords: Machine Learning. Predictive Modeling. Precision Forestry. RPAS.

6.1 INTRODUÇÃO

A crescente demanda por produtos florestais faz com que o setor produtivo busque tecnologias que proporcionam mais informações sobre as características dos talhões, uma vez que a qualidade final do produto requer o monitoramento periódico das áreas produtivas (Bonete et al., 2016; Trevisan et al., 2016). Na silvicultura do eucalipto, um fator muito comum que afeta a rentabilidade da cultura é a ocorrência de plantas espontâneas. Além de afetar a produtividade, em razão da competição pelos recursos, a presença dessas plantas também ocasiona maiores custos na condução do povoamento (RESENDE e LELES, 2017). O período crítico de ocorrência de plantas espontâneas acontece nos primeiros meses após o plantio (TOLEDO, 2003), aonde são necessárias ações de controle na forma de capinas, roçadas e uso de herbicidas. Visando a otimização do processo diagnóstico/controle, surge a necessidade do emprego de ferramentas de monitoramento que permitam a realização de intervenções pontuais e no momento ideal para aumentar a eficiência e diminuir os custos das ações de manejo.

Conhecer e monitorar a densidade de plantas espontâneas é peça fundamental para o manejo adequado das culturas (PEREIRA et al., 2014). Dessa forma, é possível direcionar as intervenções antes que a competição se estabeleça, causando prejuízo a cultura. De modo geral, a detecção precisa e oportuna de plantas espontâneas no estágio inicial de crescimento da cultura, é considerado um dos principais desafios no manejo localizado (DE CASTRO et al., 2018; PEÑA et al., 2015)

Nesse cenário, o avanço tecnológico das plataformas RPAS proporcionam uma solução de alta resolução temporal e espacial, consistindo em um método rápido, preciso, econômico, para resgatar informações das culturas (EUGENIO et al., 2020; GAŠPAROVIĆ et al., 2017). Entre outros fatores, o sucesso do uso das imagens RPAS na detecção precoce de plantas espontâneas nas culturas, é a flexibilidade de voo que permite escolher a melhor janela para aquisição dos dados (SERRANO et al., 2015; DE CASTRO et al., 2018). Além da flexibilidade de voo, a

alta resolução espacial dos dados também é fator determinante. A distribuição espacial de plantas espontâneas dentro das culturas consiste em pequenas manchas, o que sugere o uso de imagens de resolução espacial muito alta, para sua determinação precisa (CARRASCOSA et al., 2015).

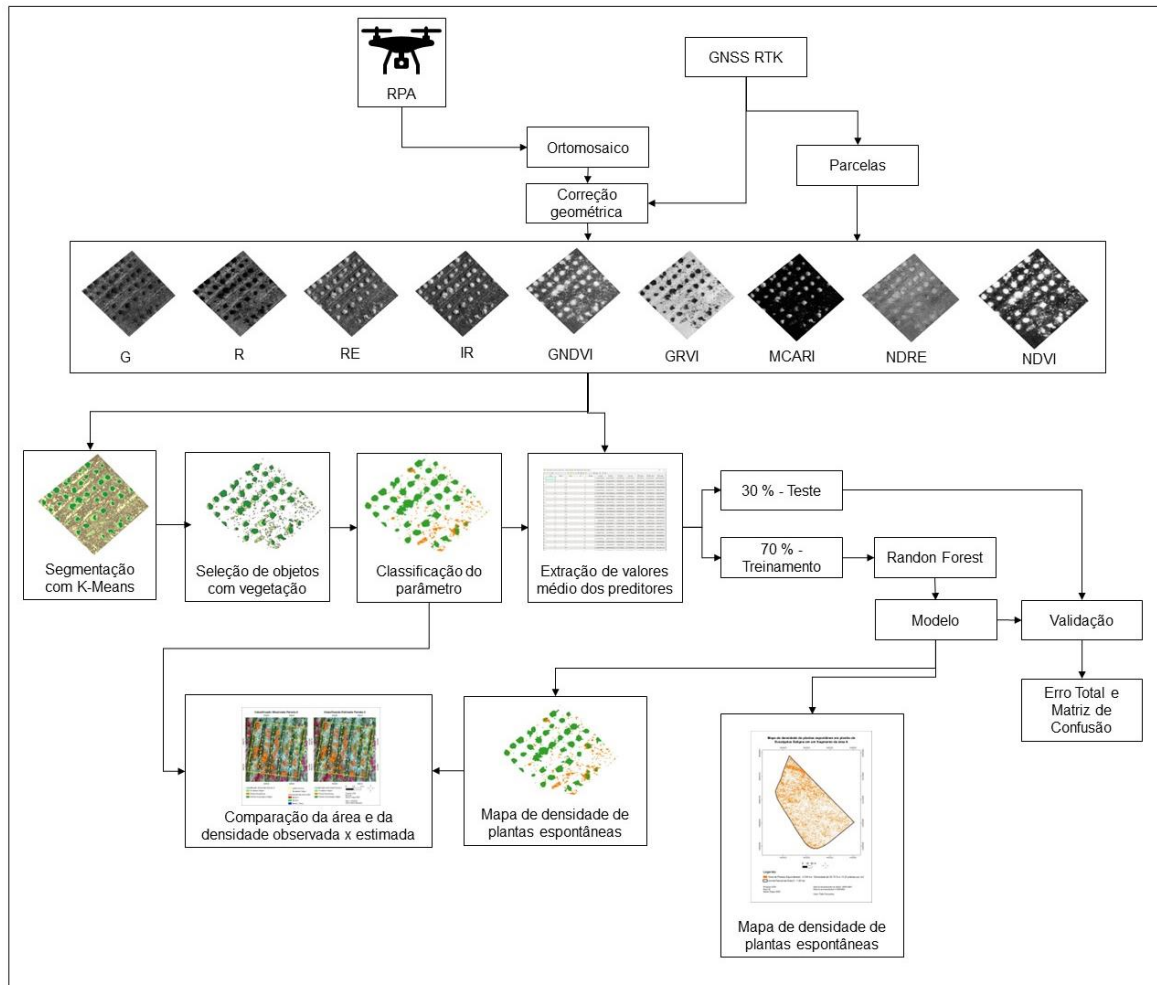
A combinação de aprendizado de máquina e produtos obtidos por RPAS tem se destacado no setor florestal na última década devido à ampla gama de aplicações e contribuições para a classificação e modelagem de atributos espaciais (EUGENIO et al., 2021). Ainda assim, no contexto específico do levantamento de plantas espontâneas, conforme evidencia a revisão bibliométrica do Capítulo I, poucos estudos envolvendo essas técnicas são voltadas a área florestal, a maioria absoluta das abordagens e soluções propostas envolve culturas agrícolas.

Nesse sentido, o objetivo geral desse trabalho é realizar a identificação e o mapeamento de plantas espontâneas em plantios comerciais de *Eucalyptus saligna* utilizando ferramentas de inteligência artificial e imagens multiespectrais de sensor embarcado em RPAS. De forma específica criar um mapa de densidade de plantas espontâneas em áreas de produção de *Eucalyptus saligna*.

6.2 MATERIAIS E MÉTODOS

Foi desenvolvido um fluxograma da metodologia do estudo para melhor elucidação do processo (Figura 25).

Figura 25 – Fluxograma da metodologia utilizada no estudo



Fonte: Autor. Santa Maria, RS, UFSM, 2022.

6.2.1 Local do estudo

O presente estudo foi realizado em quatro locais nas dependências das áreas de produção da empresa CMPC (CELULOSE RIOGRANDENSE LTDA), no estado do Rio Grande do Sul, Brasil, conforme a Tabela 17. As distribuições das áreas foram baseadas na disponibilidade operacional de plantio da empresa parceira do estudo, no qual os dados do experimento foram obtidos entorno de 54 dias após a

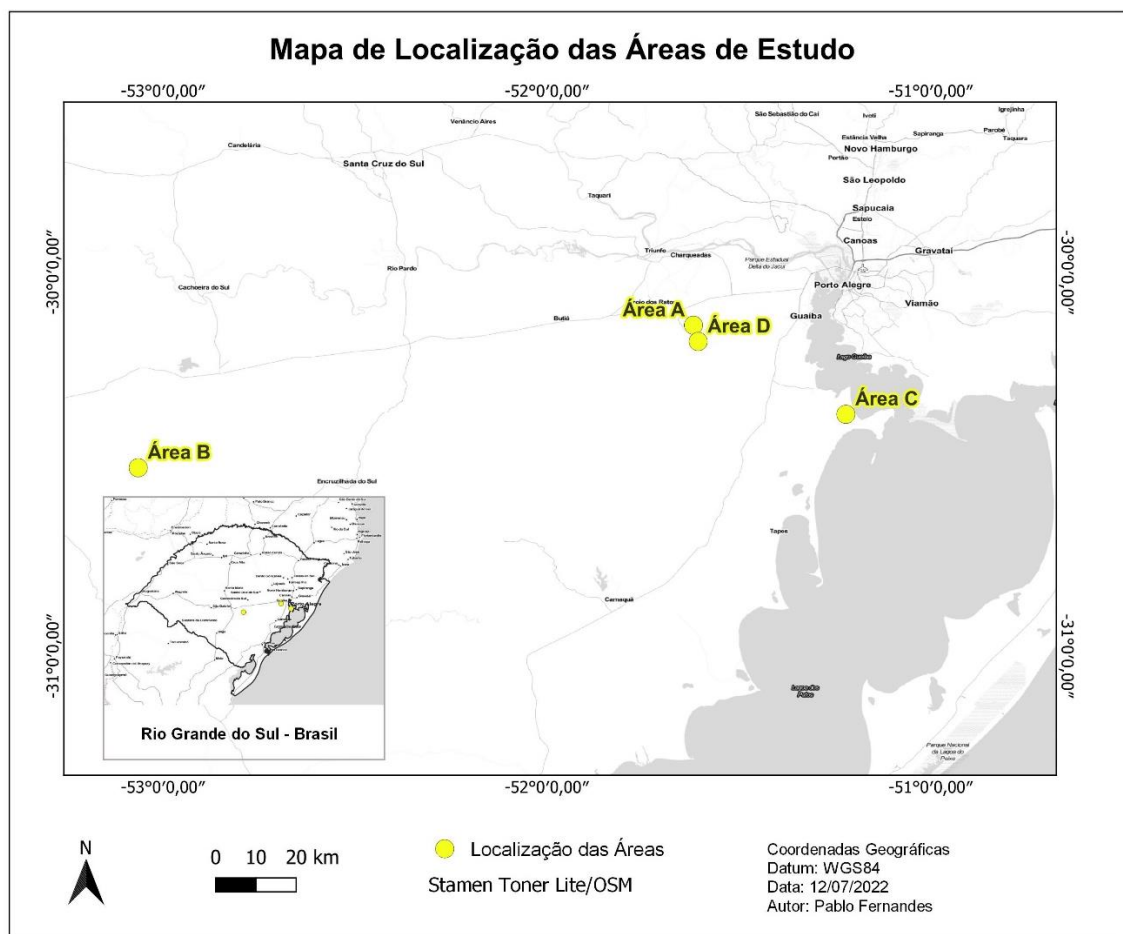
implementação do *Eucalyptus saligna* nas áreas, conforme a o mapa de localização das áreas dentro do estado (Figura 26).

Tabela 17 - Informações de localização de cada área do estudo

Identificador da Área	Município	Altitude Média
Área A	Eldorado do Sul	80 m
Área B	Cachoeira do Sul	170 m
Área C	Guaíba	24 m
Área D	Eldorado do Sul	137 m

Fonte: Autor. Santa Maria, RS, UFSM, 2022.

Figura 26 - Mapa com a distribuição das quatro áreas de estudo no estado do Rio Grande do Sul



Fonte: Autor. Santa Maria, RS, UFSM, 2022.

Segundo Streck et al. (2018) o solo das áreas denominadas A e D são

classificados como Argissolo Vermelho - Amarelo Distrófico, e a Área B, possui o solo classificado como Argissolo Vermelho-Amarelo Eutrófico, já a Área C, o solo é classificado como Neossolos Flúvicos, sendo solos aluviais eutróficos ou distróficos, com textura mais arenosa.

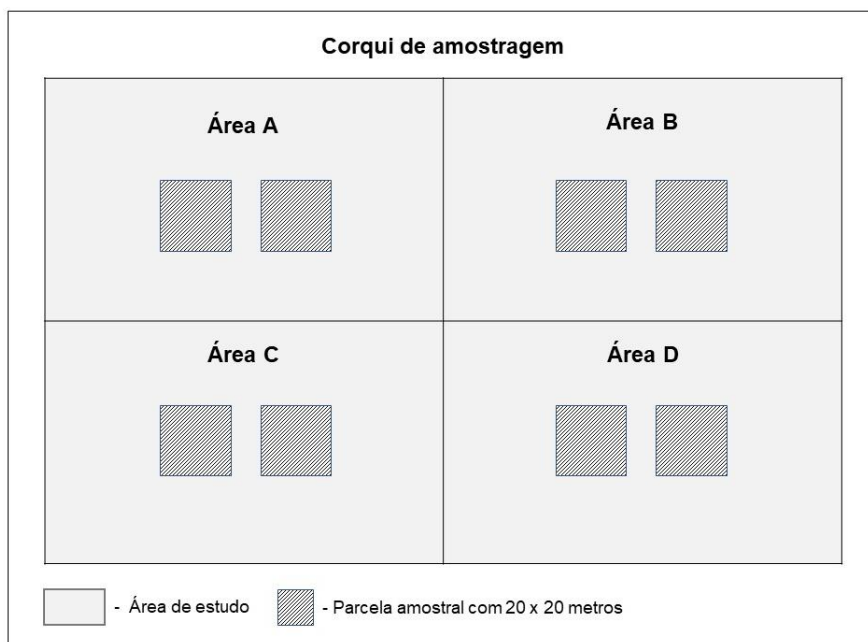
As áreas de estudo são locais de reforma, ou seja, unidades onde já houve um ciclo de produção, sendo o atual decorrente do plantio de novos indivíduos e não pelo sistema de condução por rebrota. Dessa forma, as áreas caracterizam-se pela presença de resíduos vegetais pós-colheita, como galhos e cascas, assim como tocos e rebrotas remanescentes.

A Área A possui uma topografia mais plana de baixa declividade, com presença inclusive de água acumulada dentro do talhão, caracterizando um ambiente mais húmido. Já a Área B, de maneira geral, está situada nas porções mais elevadas nas áreas de produção da região de Cachoeira do Sul, embora dentro do próprio talhão existam locais de acentuada diferença de nível. A Área C, por sua vez, está em uma região mais plana, levemente ondulada, com presença de canais de drenagem em meio ao talhão. Por fim, a área D, apresenta declividade mais acentuada em relação as demais. Toda área do talhão apresenta sentido único de inclinação e encontra-se próxima a um curso curso d'água e sua respectiva APP (Área de Preservação Permanente).

6.2.2 Aquisição de dados

A coleta de informações foi realizada em quatro áreas de plantio de *Eucalyptus saligna*, que possuíam em média 54 dias após o plantio, nas quais foi delimitado um total de 8 parcelas amostrais de 20 x 20 m, conforme o croqui amostral (Figura 27). Conforme a topologia do terreno possibilitava, a localização de uma das parcelas era posicionada em um nível mais baixo, enquanto a outra em um patamar mais elevado do talhão.

Figura 27 - Croqui de distribuição amostral das parcelas dentro de cada área do estudo



Fonte: Autor. Santa Maria, RS, UFSM, 2022.

A Tabela 18 apresenta as informações pertencentes aos períodos de coleta de dados espectrais e identificação das espécies, assim como algumas características de manejo florestal da cultura do *Eucalyptus saligna* nas áreas do estudo, como produtos químicos utilizados no controle de espécies espontâneas pré-plantio e espaçamento utilizados no plantio. Todas as unidades produtivas estudadas são áreas de reforma, ou seja, locais em que já houve a colheita do eucalipto e novo ciclo se dá por plantio de novos indivíduos e não pelo sistema de condução de rebrota. Na Figura 28 é possível visualizar as condições das áreas no momento de obtenção de dados.

Tabela 18 - Informações do manejo da cultura e coleta de dados em cada área de estudo

Nome da Área	Data de Plantio	Data de Leitura	Dias de Leituras Após Plantio	Espaçamento de Plantio	Herbicida Pré-Plantio	Herbicida Pré-Emergente
Área A	05/12/2020	28/01/2021	54	3,0 x 2,5 m	Glifosato 2,12kg/ha	Oxifluorfen 1,44 L/ha
Área B	27/03/2021	12/06/2021	77	3,0 x 2,5 m	Não Informado	Não Informado
Área C	06/12/2021	14/01/2022	39	6,0 e 3,0 x 2,5 m	Glifosato 1,99L/ha e Saflufenacil 1,02 Kg/ha	Oxifluorfen 2,96 L/ha
Área D	01/12/2021	15/01/2022	45	3,0 x 2,5 m	Glifosato 2,58Kg/ha e Saflufenacil 0,10 Kg/ha	Oxifluorfen 4,83 L/ha

Fonte: Autor. Santa Maria, RS, UFSM, 2022.

Figura 28 - Imagem com vista panorâmica das quatro áreas de *Eucalyptus saligna* elencadas para o estudo



Fonte: Autor. Santa Maria, RS, UFSM, 2022.

Para realizar o imageamento das áreas do estudo foi utilizado o RPAS (*Remotely Piloted Aircraft System*) Phantom 4 Pro (DJI,2021), (Figura 29), embarcado com três sensores. O primeiro é um sensor de imagem CMOS, nativo do RPAS Phantom 4 Pro, com resolução de 20 megapixel, que registra imagens na faixa do espectro visível com 3 bandas. O segundo é um sensor de imageamento modelo Parrot Sequoia (PARROT, 2021), com resolução de 1,2 megapixel e contempla a faixa multiespectral, com 4 bandas com os seguintes intervalos de comprimento de onda: Verde (530-570nm), Vermelho (640-680nm), Borda do Vermelho (730-740nm), Infravermelho Próximo (770-810nm). O terceiro é um sensor de correção radiométrica modelo Sunshine (PARROT, 2021), que é integrado com a câmera Sequoia.

Figura 29 - Imagem do RPAS Phantom 4 Pro embarcado com os sensores CMO, Parrot Sequoia e Sunshine, durante levantamento na área do estudo



Fonte: Autor. Santa Maria, RS, UFSM, 2022.

O planejamento de voo foi realizado no aplicativo Drone Deploy, com sobreposição longitudinal de 80% e sobreposição transversal de 70% a fim de garantir redundância de imagens no pós-processamento. A altura do voo realizada foi de 30 m em relação ao solo, gerando uma resolução espacial média para a câmera multiespectral de 3,3 cm. Também foi utilizada uma placa de calibração de imagens, para que as imagens fossem transformadas em unidade de refletância.

O levantamento dos GCPs (*Ground Control Points*) para realizar a correção geométrica das imagens do RPAS bem como o georreferenciamento do limite das parcelas amostrais, foi realizado com o GNSS (*Global Navigation Satellite System*) da marca Topcon, modelo Hiper V (Figura 30), com sistema de correção RTK (*Real Time Kinematic*).

Figura 30 – Levantamento GNSS na área de estudo. Base, rover e coletora do GNSS com RTK HIPER V da Topcon



Fonte: Autor. Santa Maria, RS, UFSM, 2022.

6.2.3 Processamento das Imagens

O processamento das imagens levantadas com o RPAS foi realizado com software Pix4D, o qual gerou o ortomosaico das imagens multiespectrais e a correção geométrica foi realizada no software ArcMap 10.1. Já para o restante das manipulações das imagens e elementos geoespaciais, foi utilizado o software QGIS 3.22, com as bibliotecas do software Orfeo ToolBox 8.0.

6.2.4 Análise das imagens

Além da utilização as bandas da câmera Parrot Sequoia, verde (G), vermelho (R), borda do vermelho (RE) e Infravermelho Próximo (NIR) como preditores (Tabela 19), também foram utilizados índices de vegetação como GNDVI (*Green normalized difference vegetation index*), GRVI (*Green-red vegetation index*), MCARI (*Modified Chlorophyll Absorption in Reflectance Index*), NDRE (*Red-edge Normalized Difference Vegetation Index*) e NDVI (*Normalized difference vegetation Index*). Estes índices contemplam a ordem de bandas de maior importância do segundo capítulo deste estudo e que são aplicáveis as bandas da câmera Parrot Sequoia.

Alguns autores em estudos aplicado a identificação de plantas espontâneas em culturas agrícolas também utilizaram os índices NDVI (PEÑA et al., 2015; WATT et al., 2017), GRVI (KAWAMURA et al., 2021), GNDVI (JIMÉNEZ-BRENES et al., 2019), NDRE (MINK et al., 2019). Além desses se utilizou o índice MCARI. Dessa forma, foi atendida a premissa de contemplar as bandas da borda do vermelho, vermelho e verde, em consonância como os resultados da análise de importância do capítulo dois desse estudo.

Tabela 19 – Expressão matemática dos índices de vegetação utilizados no estudo

Índices	Equação	Referência
Green normalized difference vegetation index (GNDVI)	$GNDVI = \frac{NIR - G}{NIR + G}$	Gitelson e Kaufman (1996)
Green-red vegetation index (GRVI)	$GRVI = \frac{R - G}{R + G}$	Motohka et al. (2010)
Modified Chlorophyll Absorption in Reflectance Index (MCARI)	$MCARI = ((RE - R) - 0.2 * (RE - G)) * \left(\frac{RE}{R}\right)$	Daughtry et al. (2000)
Red-edge Normalized Difference Vegetation Index (NDRE)	$NDRE = \frac{NIR - RE}{NIR + RE}$	Barnes et al. (2000)
Normalized difference vegetation Index (NDVI)	$NDVI = \frac{NIR - R}{NIR + R}$	Rouse, Haas e Schell (1974)

Fonte: Autor. Santa Maria, RS, UFSM, 2022.

A partir dos nove preditores a segmentação foi realizada através do algoritmo de cluster *K-Means*, com parâmetros padrões e configuração de sete classes, que foram capazes de discriminar a vegetação dos demais objetos. Abordagem similar ao trabalho de Perez-Ortiz et al. (2017), que utilizaram o *K-Means* para determinar

segmentação em classificação de plantas espontâneas utilizando RPAS.

Posteriormente foi realizada a discriminação da vegetação, através da separação de objetos que correspondem a essa classe. Esses objetos foram classificados de modo supervisionado dentro de todas as parcelas, considerando três classes: *Eucalyptus saligna*, plantas espontâneas, e rebrota de *Eucalyptus saligna*.

Foi extraída a média de cada preditor dentro de cada objeto através do algoritmo estatística zonal do software QGIS. Dessa forma criou-se um arquivo *shapefile* contendo os objetos com o rótulo da classe e o valor médio de cada preditor. Na sequência essa base de dados foi particionada em 70% para treinamento e 30% denominado teste, para validação do modelo. Na Tabela 20 é possível visualizar a proporção amostral de cada classe no particionamento.

Tabela 20 - Proporção amostral entre as classes usadas considerando o particionamento para modelagem

Classe	Treino	Teste	Total
<i>Eucalyptus saligna</i>	288	124	412
Plantas Espontâneas	7955	3410	11365
Rebrota de <i>Eucalyptus saligna</i>	248	106	354
Total	8491	3640	12131

Fonte: Autor. Santa Maria, RS, UFSM, 2022.

Para desenvolvimento do modelo com inteligência artificial foi utilizado o algoritmo RF (*Random Forest*), à exemplo do trabalho de Kawamura et al. (2021), que utilizaram o RF na classificação de plantas espontâneas em culturas agrícolas. Nessa mesma linha, de Castro et al. (2018), sugerem o emprego do RF para automação da classificação de plantas espontâneas, pois requer menos parâmetros de classificação do que técnicas semelhantes de aprendizado de máquina. O modelo RF foi implementado em linguagem R. Os parâmetros de entrada do modelo foram mantidos na sua forma padrão de execução, com exceção da configuração *n tree* (número de árvores aleatórias a serem criadas), foi alterado de 500 (*default*) para 1000.

Ao final do processo de classificação, como indicadores de precisão do modelo gerado, avaliou-se o Erro Global e a Matriz de Confusão, para os dados de teste. O modelo proveniente do RF foi aplicado para cada parcela, onde foi possível

realizar a comparação das variáveis *área* e a *densidade plantas espontâneas* no mapa com as classes observadas e as classes estimadas, de modo a compreender o impacto do erro de estimativa no manejo e controle plantas espontâneas.

Após a validação do modelo gerado pela inteligência artificial, o mesmo foi colocado em produção. Para tanto, utilizou-se um fragmento em cada área de estudo com extensão além das parcelas, compondo assim, o resultado final proposto pelo estudo, o mapa de densidade plantas espontâneas em plantio de *Eucalyptus saligna*. O mapa de densidade de plantas contém a informação da porcentagem da área recoberta de plantas espontâneas, bem como o indicador do número de plantas por unidade de área (plantas/m²), obtido na contagem do número de objetos encontrados na etapa de segmentação.

6.3 RESULTADOS E DISCUSSÕES

Para análise de dados de treinamento, obteve-se um erro global de 4,86% ou 95,14% de acerto com o modelo RF (Tabela 21). Cook e Bramley (1998), De Castro et al. (2018) e Stroppiana et al. (2018), também encontraram uma precisão acima de 95 % na identificação de plantas espontâneas em seus modelos aplicados em outras culturas como, videira, milho e arroz. Ainda na Tabela 21, ao analisar a matriz de confusão, observa-se que a classificação de plantas espontâneas teve erro de apenas 0,78%, ou precisão de acerto 99,22%. O modelo atribuiu de forma equivocada um número reduzido de indivíduos de plantas espontâneas às outras duas classes. Já para a classe de *Eucalyptus saligna*, observa-se um erro 82,29%, aonde grande parte dos objetos foram classificados erroneamente como plantas espontâneas. Esse baixo índice de acerto pode ser atribuído a dois fatores. O primeiro, referente a baixa proporção amostral de objetos da classe *Eucalyptus saligna*, equivalente a 3,39 % da amostragem em todas as parcelas. Outro fator, é a heterogeneidade dentro da classe em função da diferença de dias após plantio do *Eucalyptus saligna* entre as parcelas, chegando a amplitude de 38 dias. Os dados de espectrorradiometria aplicados ao intervalo da câmera Parrot Sequoia, referente do Capítulo II da presente tese, também apresentam um erro de 40,36% para classificação entre *Eucalyptus saligna* e plantas espontâneas. As rebrotas de *Eucalyptus saligna* também tiveram um número expressivo de objetos classificadas como plantas espontâneas, acumulando erro de 45,97% dentro da classe.

Tabela 21 - Resultado da matriz de confusão e erro total dos dados de treinamento do modelo


	<i>Eucalyptus saligna</i>	Plantas Espontâneas	Rebrota	Erro da Classe
<i>Eucalyptus saligna</i>	51	235	2	82,29%
Plantas Espontâneas	32	7893	30	0,78%
Rebrota de <i>Eucalyptus saligna</i>	7	107	134	45,97%
			Total	4.86%

Fonte: Autor. Santa Maria, RS, UFSM, 2022.

Ao rodar o algoritmo, também se identificou os preditores de maior importância utilizados, no quais os mais importantes foram GNDVI, MCARI e NDVI, conforme a Figura 31. Jiménez-Brenes et al., (2019), também encontraram o GNDVI como um dos principais preditores para determinar plantas espontâneas na cultura de uva, atingindo precisão de 97,7%. Sa et al. (2018), mencionam em seu estudo que a inclusão do NDVI proporcionou um aumento na precisão do modelo utilizando inteligência artificial para identificar plantas espontâneas na cultura da beterraba.

Watt et al. (2016), representa o único artigo na literatura, até o presente momento, que menciona a identificação de plantas espontâneas na área florestal, no contexto específico da cultura de *Pinus sp.* Utilizando imagens multiespectrais provenientes de RPAS, os autores mencionam a precisão de até 79% em seu modelo multivariado, utilizando bandas da câmera combinado com índices de vegetação, incluindo o NDVI.

Figura 31 - Preditores de maior importância encontrados pelo modelo RF na classificação *Eucalyptus saligna* x Plantas Espontâneas x Rebrotas de *Eucalyptus saligna*



Fonte: Autor. Santa Maria, RS, UFSM, 2022.

Ao submeter o modelo RF treinado aos dados de teste, observou-se um erro total de 4,51% ou 95,49% de precisão (Tabela 22). Houve uma expressiva redução no erro dentro da classe *Eucalyptus saligna*, cujo percentual caiu de 82,29% para 32,50%, no comparativo treino e teste, o que equivale a 49,79%. A mesma tendência observada para a classe rebrota de *Eucalyptus saligna*, uma redução de 27,46% no índice de erro. Já as plantas espontâneas apresentaram um aumento no erro de 3,08%, ainda assim, apresentam uma precisão de acerto dentro da classe de 96,14%. A variação na precisão das classes *Eucalyptus saligna* e rebrota de *Eucalyptus saligna*, foi mais sensível pela baixa quantidade de objetos amostrados nessas classes, de modo que a classificação equivocada de poucas instâncias, tem impacto expressivo sobre a precisão dentro da classe.

Tabela 22 – Resultado da matriz de confusão e erro total dos dados de teste do modelo

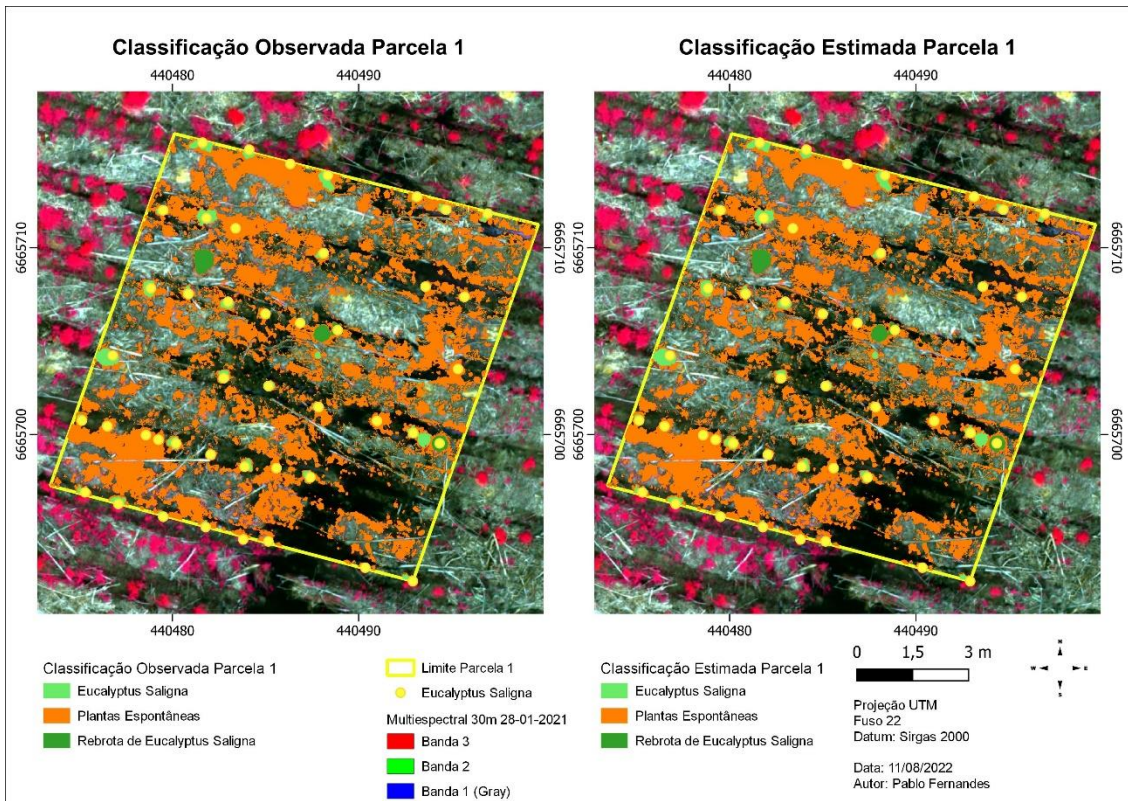
	<i>Eucalyptus saligna</i>	Plantas Espontâneas	Rebrota	Erro da Classe
<i>Eucalyptus saligna</i>	27	11	2	32,50%
Plantas Espontâneas	97	3384	39	3,86%
Rebrota de <i>Eucalyptus saligna</i>	0	15	65	18,75%
	Total			4,51%

Fonte: Autor. Santa Maria, RS, UFSM, 2022.

Para compreender o impacto desses erros na classificação dos objetos, referente a estimativa de densidade plantas espontâneas no manejo do *Eucalyptus saligna*, foi analisado em cada parcela, a área (em metros quadrados - m²) dos dados observados (parâmetros), em comparação as estimativas geradas pelo modelo RF treinado.

Na Figura 32, é apresentado o mapa de classificação referente a unidade amostral 1. Na porção esquerdo da figura, tem-se a classificação real da vegetação da parcela, ou seja, a classificação observada. Já na porção direita, tem-se a classificação a partir da estimativa do modelo RF. Visualmente, observa-se que a classificação de plantas espontâneas praticamente ficou inalterada. Conforme a Tabela 23, com uma pequena redução de área de 0,30% em relação área total da parcela (400m²), a densidade de plantas espontâneas passou de 32,20% para 31,90%, uma redução de 1,19m² em 400m², que foram distribuídos 0,15% na classe de *Eucalyptus saligna* e 0,16% na área da classe rebrota de *Eucalyptus saligna*. Conforme a Tabela 31, a densidade estimada é de 12,46 indivíduos/m², muito próxima a observada, que é de 12,44 indivíduos/m².

Figura 32 - Mapa de classificação observada e estimada da unidade amostral 1 – Área A



Fonte: Autor. Santa Maria, RS, UFSM, 2022.

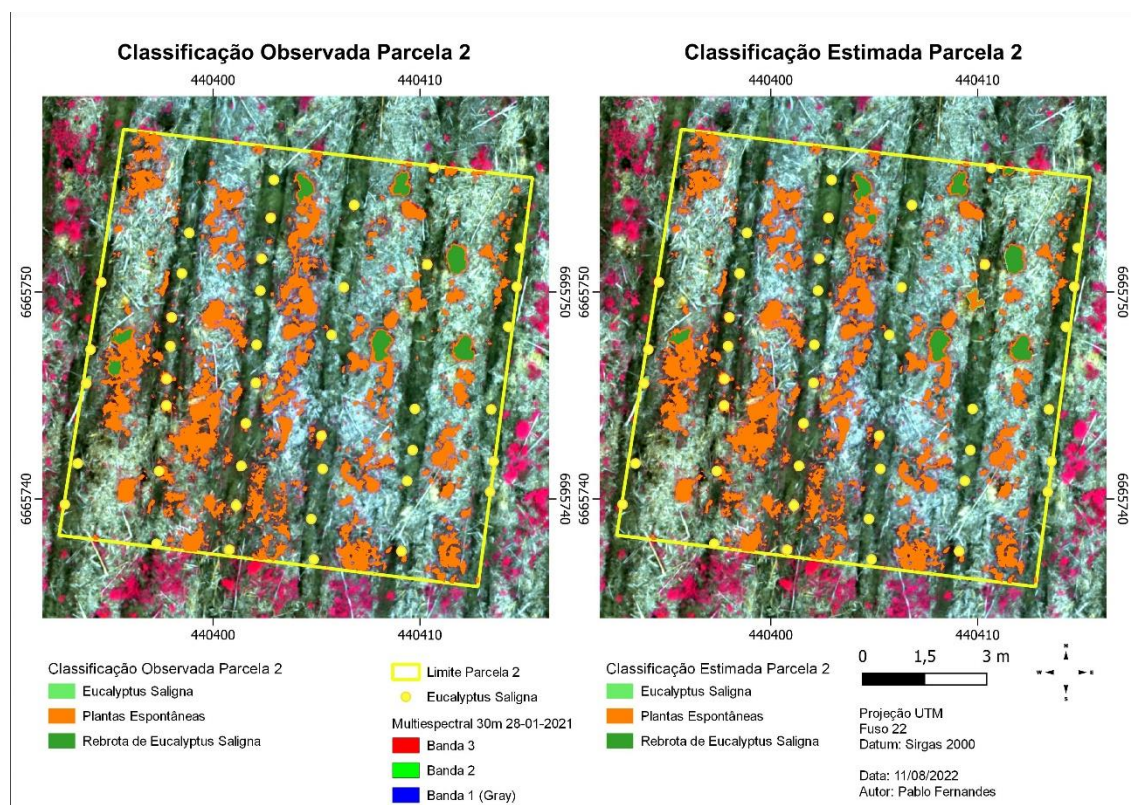
Tabela 23 - Análise de diferença de área na comparação da classificação observada e estimada da parcela 1

Classe	Área Observada (m ²)	Proporção Observada na Parcela	Área Estimada (m ²)	Proporção Estimada na Parcela	Diferença de Área (m ²)	Porcentagem de Diferença de Área	Diferença de Proporção na Parcela
<i>Eucalyptus saligna</i>	7,88	1,97%	8,46	2,12%	0,58	7,36%	0,15%
Plantas Espontâneas	128,78	32,20%	127,59	31,90%	-1,19	-0,92%	-0,30%
Rebrota de <i>Eucalyptus saligna</i>	2,05	0,51%	2,67	0,67%	0,62	30,24%	0,16%

Fonte: Autor. Santa Maria, RS, UFSM, 2022.

Na parcela 2, também presente na Área A, pode-se observar que as plantas espontâneas ocupam 13,56% da parcela, cujo valor estimado é de apenas 0,09% maior (Tabela 24). A diferença de densidade de plantas espontâneas observada e estimada foi apenas 0,04 indivíduos/m² (Tabela 31). No mapa de comparação da classificação observada e estimada (Figura 33), é possível visualizar algumas áreas que deveriam ser plantas espontâneas e foram classificadas como rebrota de *Eucalyptus saligna*.

Figura 33 - Mapa de classificação observada e estimada da parcela 2 – Área A



Fonte: Autor. Santa Maria, RS, UFSM, 2022.

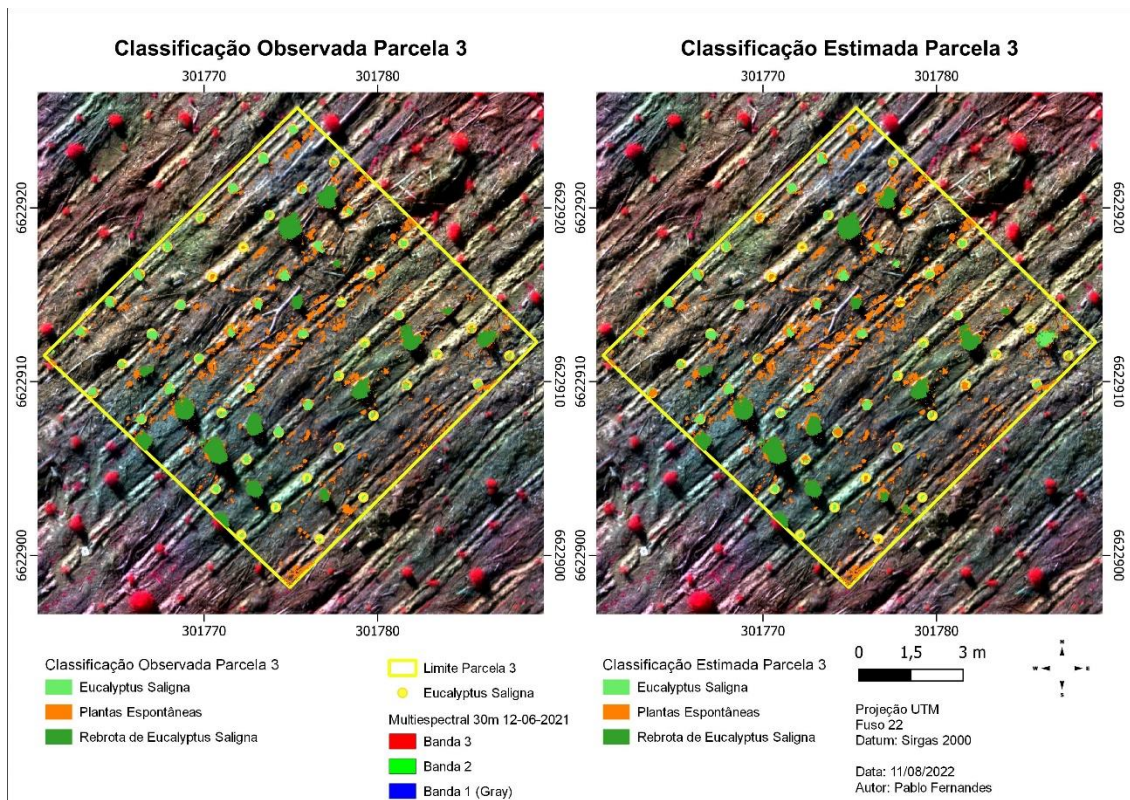
Tabela 24 - Análise de diferença de área na comparação da classificação observada e estimada da parcela 2 – Área A

Classe	Área Observada (m ²)	Proporção Observada na Parcela	Área Estimada (m ²)	Proporção Estimada na Parcela	Diferença de Área (m ²)	Porcentagem de Diferença de Área	Diferença de Proporção na Parcela
<i>Eucalyptus saligna</i>	2,35	0,59%	2,06	0,52%	-0,29	-12,34%	-0,07%
Plantas Espontâneas	54,22	13,56%	54,59	13,65%	0,37	0,68%	0,09%
Rebrota de <i>Eucalyptus saligna</i>	4,58	1,15%	4,5	1,13%	-0,08	-1,75%	-0,02%

Fonte: Autor. Santa Maria, RS, UFSM, 2022.

Na parcela 3, presente na Área B, pode-se observar que as plantas espontâneas ocupam 5,66% da área total (Tabela 25). A área de cobertura estimada para essa classe é de apenas 0,48% maior que os dados de referência. A diferença de densidade de plantas espontâneas observada e estimada foi apenas 0,08 indivíduos/m² (Tabela 31). No mapa (Figura 34) de comparação da classificação observada e estimada, existem algumas áreas de *Eucalyptus saligna* que foram classificadas como plantas espontâneas.

Figura 34 -Mapa de classificação observada e estimada da parcela 3 – Área B



Fonte: Autor. Santa Maria, RS, UFSM, 2022.

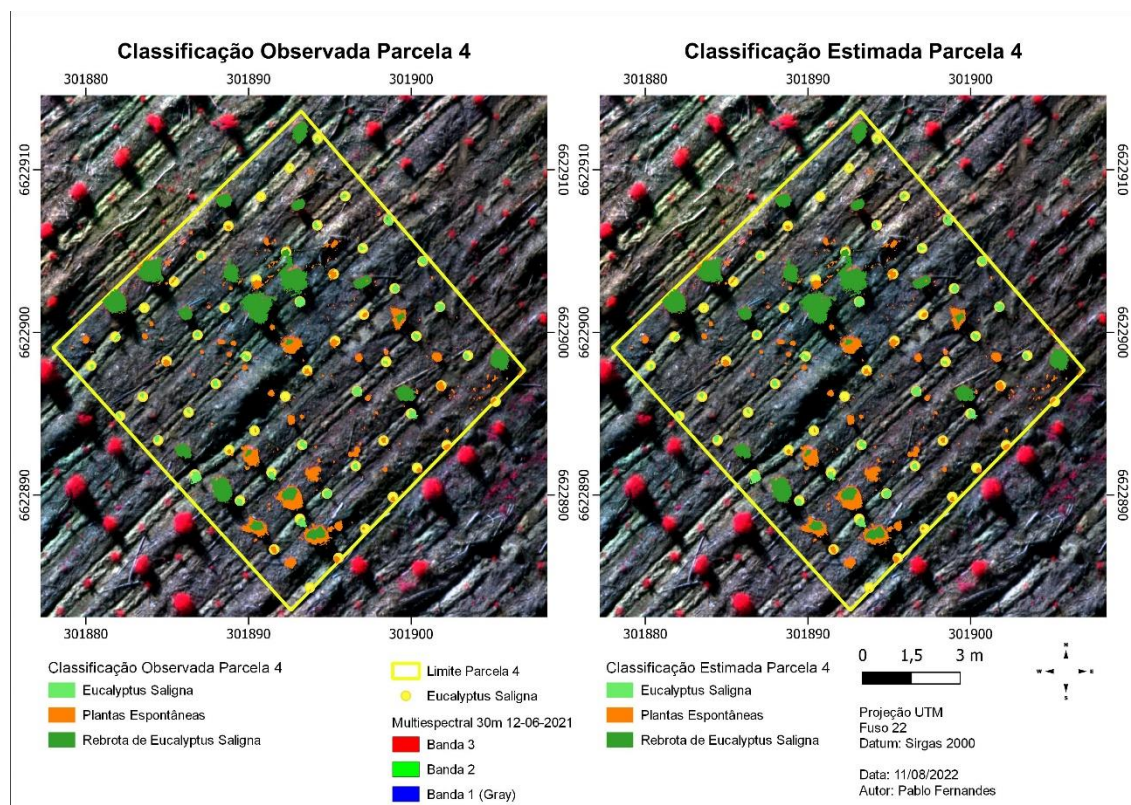
Tabela 25 - Análise de diferença de área na comparação da classificação observada e estimada da unidade amostral 3 – Área B

Classe	Área Observada (m ²)	Proporção Observada na Parcela	Área Estimada (m ²)	Proporção Estimada na Parcela	Diferença de Área (m ²)	Porcentagem de Diferença de Área	Diferença de Proporção na Parcela
<i>Eucalyptus saligna</i>	7,15	1,79%	6,62	1,66%	-0,53	-7,41%	-0,13%
Plantas Espontâneas	22,64	5,66%	24,56	6,14%	1,92	8,48%	0,48%
Rebrota de <i>Eucalyptus saligna</i>	12,69	3,17%	11,29	2,82%	-1,4	-11,03%	-0,35%

Fonte: Autor. Santa Maria, RS, UFSM, 2022.

Na parcela 4, também presente na Área B, pode-se observar que as plantas espontâneas ocupam 2,02% da área da parcela e obteve um acréscimo de 1,31% de área com plantas espontâneas estimadas (Tabela 26). A diferença de densidade de plantas espontâneas observada e estimada foi apenas 0,05 indivíduos/m² (Tabela 31). No mapa de comparação da classificação observada e estimada (Figura 35), existe algumas áreas de *Eucalyptus saligna* que foram classificadas como plantas espontâneas.

Figura 35 - Mapa de classificação observada e estimada da parcela 4 – Área B



Fonte: Autor. Santa Maria, RS, UFSM, 2022.

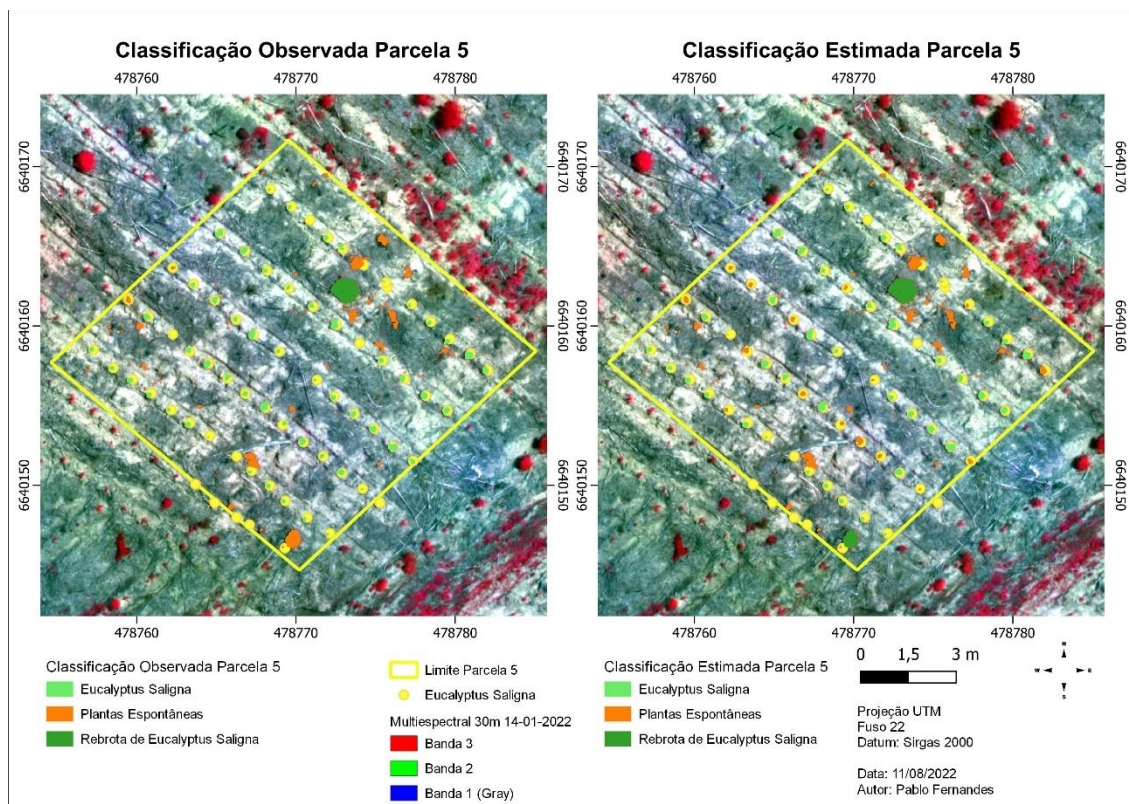
Tabela 26 - Análise de diferença de área na comparação da classificação observada e estimada da unidade amostral 4 – Área B

Classe	Área Observada (m ²)	Proporção Observada na Parcela	Área Estimada (m ²)	Proporção Estimada na Parcela	Diferença de Área (m ²)	Porcentagem de Diferença de Área	Diferença de Proporção na Parcela
<i>Eucalyptus saligna</i>	5,5	1,38%	4,16	1,04%	-1,34	-24,36%	-0,34%
Plantas Espontâneas	8,08	2,02%	13,3	3,33%	5,22	64,60%	1,31%
Rebrota de <i>Eucalyptus saligna</i>	22,34	5,59%	18,46	4,62%	-3,88	-17,37%	-0,97%

Fonte: Autor. Santa Maria, RS, UFSM, 2022.

Na parcela 5, presente na Área C, pode-se observar que as plantas espontâneas ocupam 1,24% da parcela, cujo valor estimado é de apenas 0,07% maior (Tabela 27). A diferença de densidade de plantas espontâneas observada e estimada foi apenas 0,03 indivíduos/m² (Tabela 31). No mapa de comparação da classificação observada e estimada (Figura 36), existe algumas áreas de *Eucalyptus saligna* que foram classificadas como plantas espontâneas. Nesse local, os indivíduos de *Eucalyptus saligna* são mais jovens, apresentam características estruturais passíveis de maior confusão com outras espécies. Além desse fator, de textura mais arenosa, a classificação do solo nessa área é diferente das demais, o que pode alterar a composição da reflectância em razão da mistura espectral e ter reflexos na precisão do modelo.

Figura 36 - Mapa de classificação observada e estimada da parcela 5 – Área C



Fonte: Autor. Santa Maria, RS, UFSM, 2022.

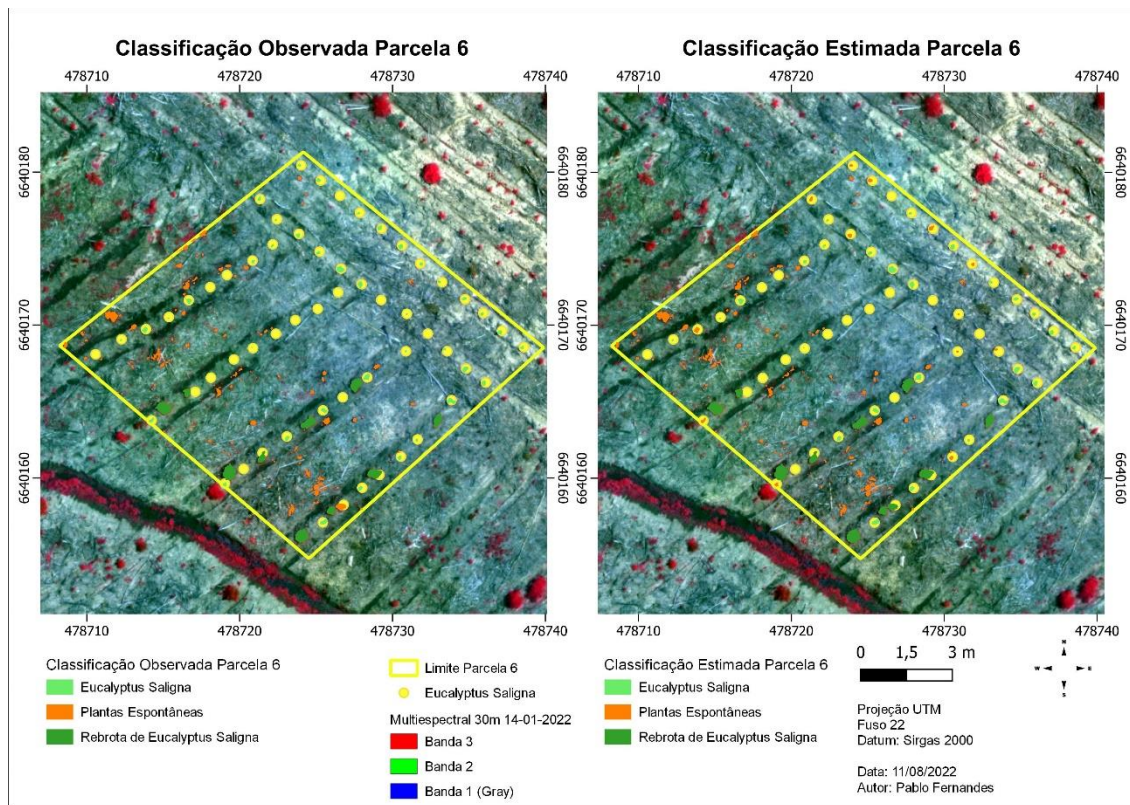
Tabela 27 - Análise de diferença de área na comparação da classificação observada e estimada da unidade amostral 5 – Área C

Classe	Área Observada (m ²)	Proporção Observada na Parcela	Área Estimada (m ²)	Proporção Estimada na Parcela	Diferença de Área (m ²)	Porcentagem de Diferença de Área	Diferença de Proporção na Parcela
<i>Eucalyptus saligna</i>	5,63	1,41%	4,54	1,14%	-1,09	-19,36%	-0,27%
Plantas Espontâneas	4,95	1,24%	5,23	1,31%	0,28	5,66%	0,07%
Rebrota de <i>Eucalyptus saligna</i>	2,1	0,53%	2,91	0,73%	0,81	38,57%	0,20%

Fonte: Autor. Santa Maria, RS, UFSM, 2022.

Na parcela 6, presente na Área C, pode-se observar que as plantas espontâneas ocupam 1,19% da parcela, cujo valor estimado é de apenas 0,11% maior (Tabela 28). A diferença de densidade de plantas espontâneas observada e estimada foi apenas 0,03 indivíduos/m² (Tabela 31). No mapa de comparação da classificação observada e estimada (Figura 37), existe algumas áreas de *Eucalyptus saligna* que foram classificadas como plantas espontâneas.

Figura 37 - Mapa de classificação observada e estimada da parcela 6 - Área C



Fonte: Autor. Santa Maria, RS, UFSM, 2022.

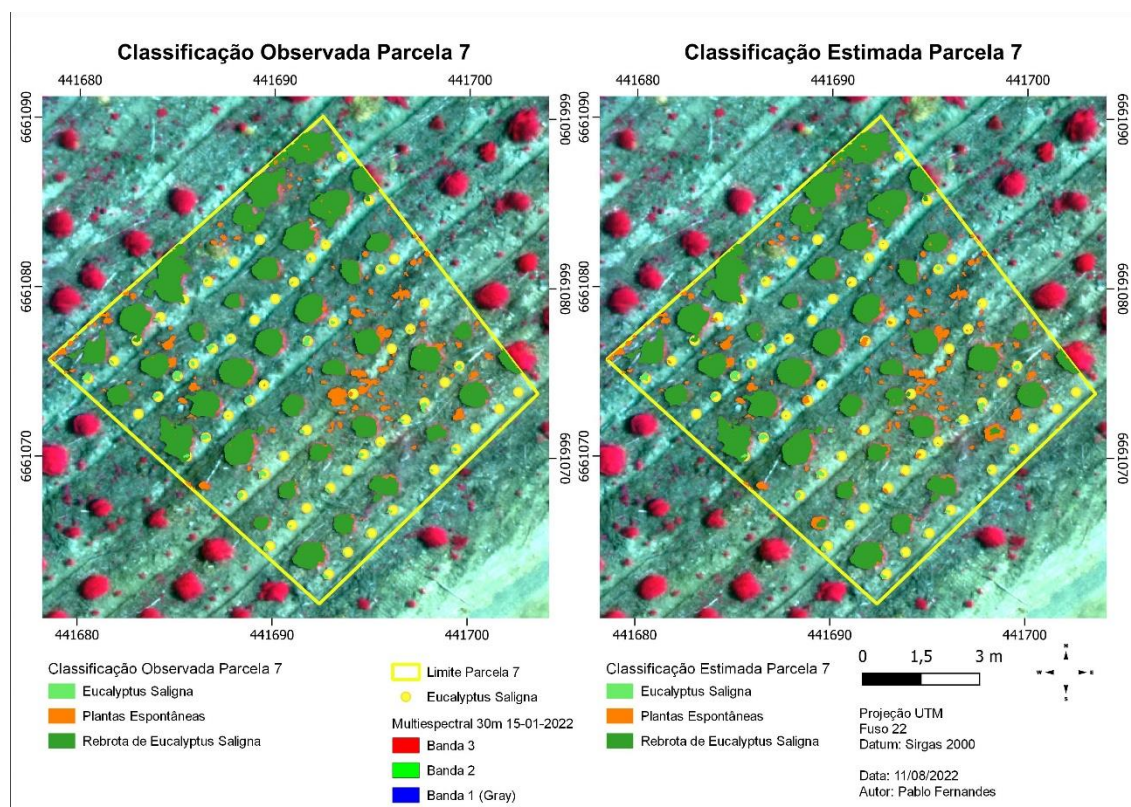
Tabela 28 - Análise de diferença de área na comparação da classificação observada e estimada da unidade amostral 6 – Área C

Classe	Área Observada (m ²)	Proporção Observada na Parcela	Área Estimada (m ²)	Proporção Estimada na Parcela	Diferença de Área (m ²)	Porcentagem de Diferença de Área	Diferença de Proporção na Parcela
<i>Eucalyptus saligna</i>	2,38	0,60%	1,72	0,43%	-0,66	-27,73%	-0,17%
Plantas Espontâneas	4,76	1,19%	5,19	1,30%	0,43	9,03%	0,11%
Rebrota <i>Eucalyptus saligna</i>	4,36	1,09%	4,59	1,15%	0,23	5,28%	0,06%

Fonte: Autor. Santa Maria, RS, UFSM, 2022.

Na parcela 7, presente na Área D, pode-se observar que as plantas espontâneas ocupam 2,22% da parcela, cujo valor estimado é de apenas 0,16% maior (Tabela 29). A diferença de densidade de plantas espontâneas observada e estimada foi apenas -0,01 indivíduos/m² (Tabela 31). No mapa de comparação da classificação observada e estimada (Figura 38), existem algumas áreas das classes *Eucalyptus saligna* e rebrota de *Eucalyptus saligna* que foram classificadas como plantas espontâneas. Embora visíveis, essas manchas não tem impacto na precisão das estimativas de área e densidade de plantas.

Figura 38 - Mapa de classificação observada e estimada da parcela 7 - Área D



Fonte: Autor. Santa Maria, RS, UFSM, 2022.

Tabela 29 - Análise de diferença de área na comparação da classificação observada e estimada da unidade amostral 7 – Área D

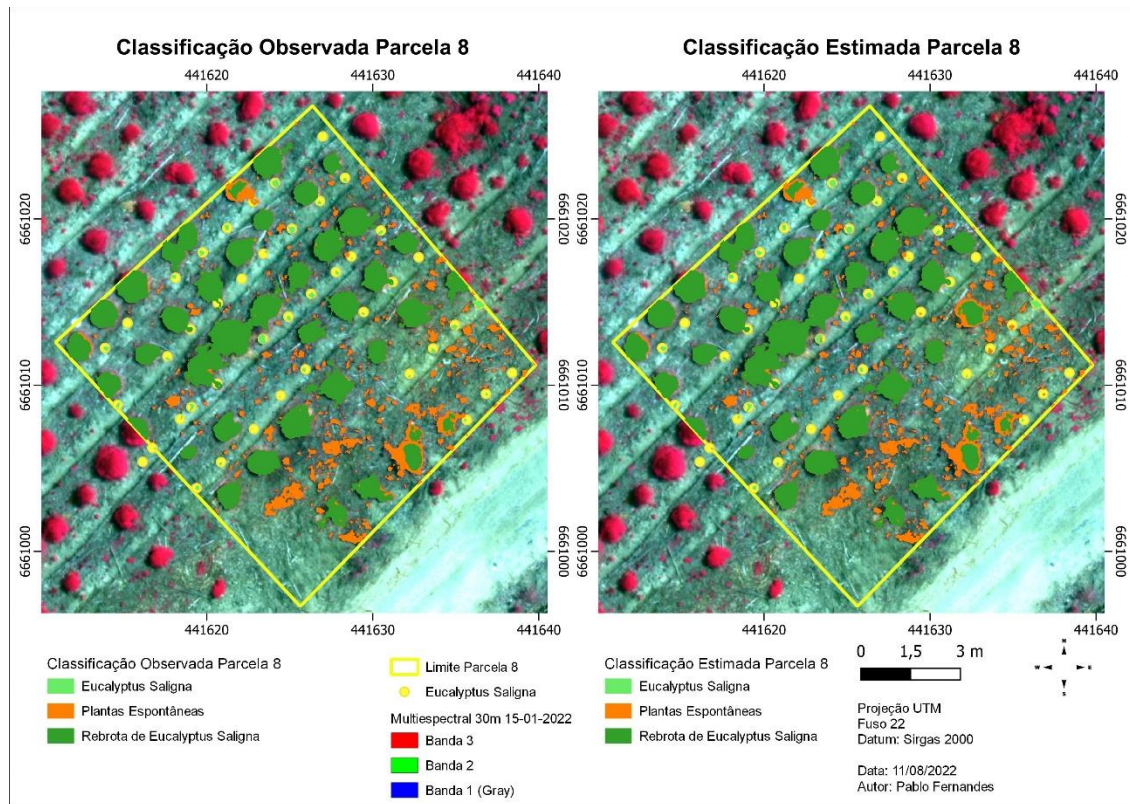
Classe	Área Observada (m ²)	Proporção Observada na Parcela	Área Estimada (m ²)	Proporção Estimada na Parcela	Diferença de Área (m ²)	Porcentagem de Diferença de Área	Diferença de Proporção na Parcela
<i>Eucalyptus saligna</i>	2,26	0,57%	1,71	0,43%	-0,55	-24,34%	-0,14%
Plantas Espontâneas	8,88	2,22%	9,53	2,38%	0,65	7,32%	0,16%
Rebrota de <i>Eucalyptus saligna</i>	61,85	15,46%	61,75	15,44%	-0,1	-0,16%	-0,03%

Fonte: Autor. Santa Maria, RS, UFSM, 2022.

Na parcela 8, também presente na Área D, pode-se observar que as plantas espontâneas ocupam 5,60% da parcela, cujo valor estimado é de apenas 0,33% maior (Tabela 30). A diferença de densidade de plantas espontâneas observada e estimada foi apenas -0,02 indivíduos/m² (Tabela 31). No mapa de comparação da classificação observada e estimada (Figura 39), existem algumas áreas das classes *Eucalyptus saligna* e rebrota de *Eucalyptus saligna* que foram classificadas como plantas espontâneas. Ainda assim, essas manchas não tem impacto na precisão das

estimativas de área e densidade de plantas, já que os indivíduos de rebrota na Área D são mais desenvolvidos e estão em maior número em relação as demais áreas.

Figura 39 - Mapa de classificação observada e estimada da parcela 8 - Área D



Fonte: Autor. Santa Maria, RS, UFSM, 2022.

Tabela 30 - Análise de diferença de área na comparação da classificação observada e estimada da unidade amostral 8 – Área D

Classe	Área Observada (m ²)	Proporção Observada na Parcela	Área Estimada (m ²)	Proporção Estimada na Parcela	Diferença de Área (m ²)	Porcentagem de Diferença de Área	Diferença de Proporção na Parcela
<i>Eucalyptus saligna</i>	1,79	0,45%	1,67	0,42%	-0,12	-6,70%	-0,03%
Plantas Espontâneas	22,39	5,60%	23,69	5,92%	1,3	5,81%	0,33%
Rebrota de <i>Eucalyptus saligna</i>	79,83	19,96%	78,65	19,66%	-1,18	-1,48%	-0,29%

Fonte: Autor. Santa Maria, RS, UFSM, 2022.

A parcela 1, dentro da Área A, é a única na qual a matriz de confusão apresenta um decréscimo na área estimada de plantas espontâneas, em relação ao valor de referência, ou seja, houve uma pequena subestimativa da classe. Ainda

assim, com estimados 31,90% e 12,46 indivíduos/m², de área e densidade de plantas espontâneas respectivamente, a parcela 1, poderia ser enquadrada dentro de uma classe que impacta no desenvolvimento dos indivíduos de eucalipto. De acordo com Toledo et al., (2001) e Dinardo et al. (2003), uma densidade de plantas espontâneas a partir 4 indivíduos/m² em plantio de *Eucalyptus grandis*, já representa perdas significativas no desenvolvimento das mudas. Por outro lado, Pereira et al., (2011), menciona que a presença de plantas espontâneas da espécie *Urochloa decumbens*, a partir 20 indivíduos/m² já interferem significativamente no desenvolvimento da espécie *Corymbia citriodora*.

Tabela 31 - Análise de densidade de plantas espontâneas observadas e estimadas para todas as parcelas levantadas no estudo

	Quantidade Observada	Densidade Observada (indivíduos/m ²)	Quantidade Estimada	Densidade Estimada (indivíduos/m ²)	Diferença de Densidade (indivíduos/m ²)
Parcela 1	4977	12,44	4983	12,46	0,01
Parcela 2	1003	2,51	1019	2,55	0,04
Parcela 3	3756	9,39	3788	9,47	0,08
Parcela 4	481	1,20	500	1,25	0,05
Parcela 5	102	0,26	115	0,29	0,03
Parcela 6	209	0,52	222	0,56	0,03
Parcela 7	267	0,67	264	0,66	-0,01
Parcela 8	570	1,43	564	1,41	-0,02

Fonte: Autor. Santa Maria, RS, UFSM, 2022.

De maneira geral, analisando todas as áreas, o acréscimo médio de área de plantas espontâneas causada pelo erro esperado na classificação foi apenas de 0,28%, e um média de acréscimo na densidade de plantas espontâneas de 0,03 indivíduos/m². O *Eucalyptus saligna* apresentou um decréscimo médio de -0,13% e a rebrota de *Eucalyptus saligna* apresentou um decréscimo médio de -0,16% em relação as áreas das parcelas.

Depreende-se que o erro encontrado no modelo gerado pelo algoritmo de inteligência artificial aplicado na determinação da densidade de plantas espontâneas, na prática, não impacta o manejo e controle das plantas espontâneas, uma vez que o modelo gerou estimativas de densidade com precisão aceitável. Nesse sentido foi possível realizar a aplicação do modelo gerado para fora das parcelas amostradas, como pode ser visto nas Figuras 40, 41,42 e 43, o mapa que

representa a densidade de plantas espontâneas em fragmentos das áreas do estudo.

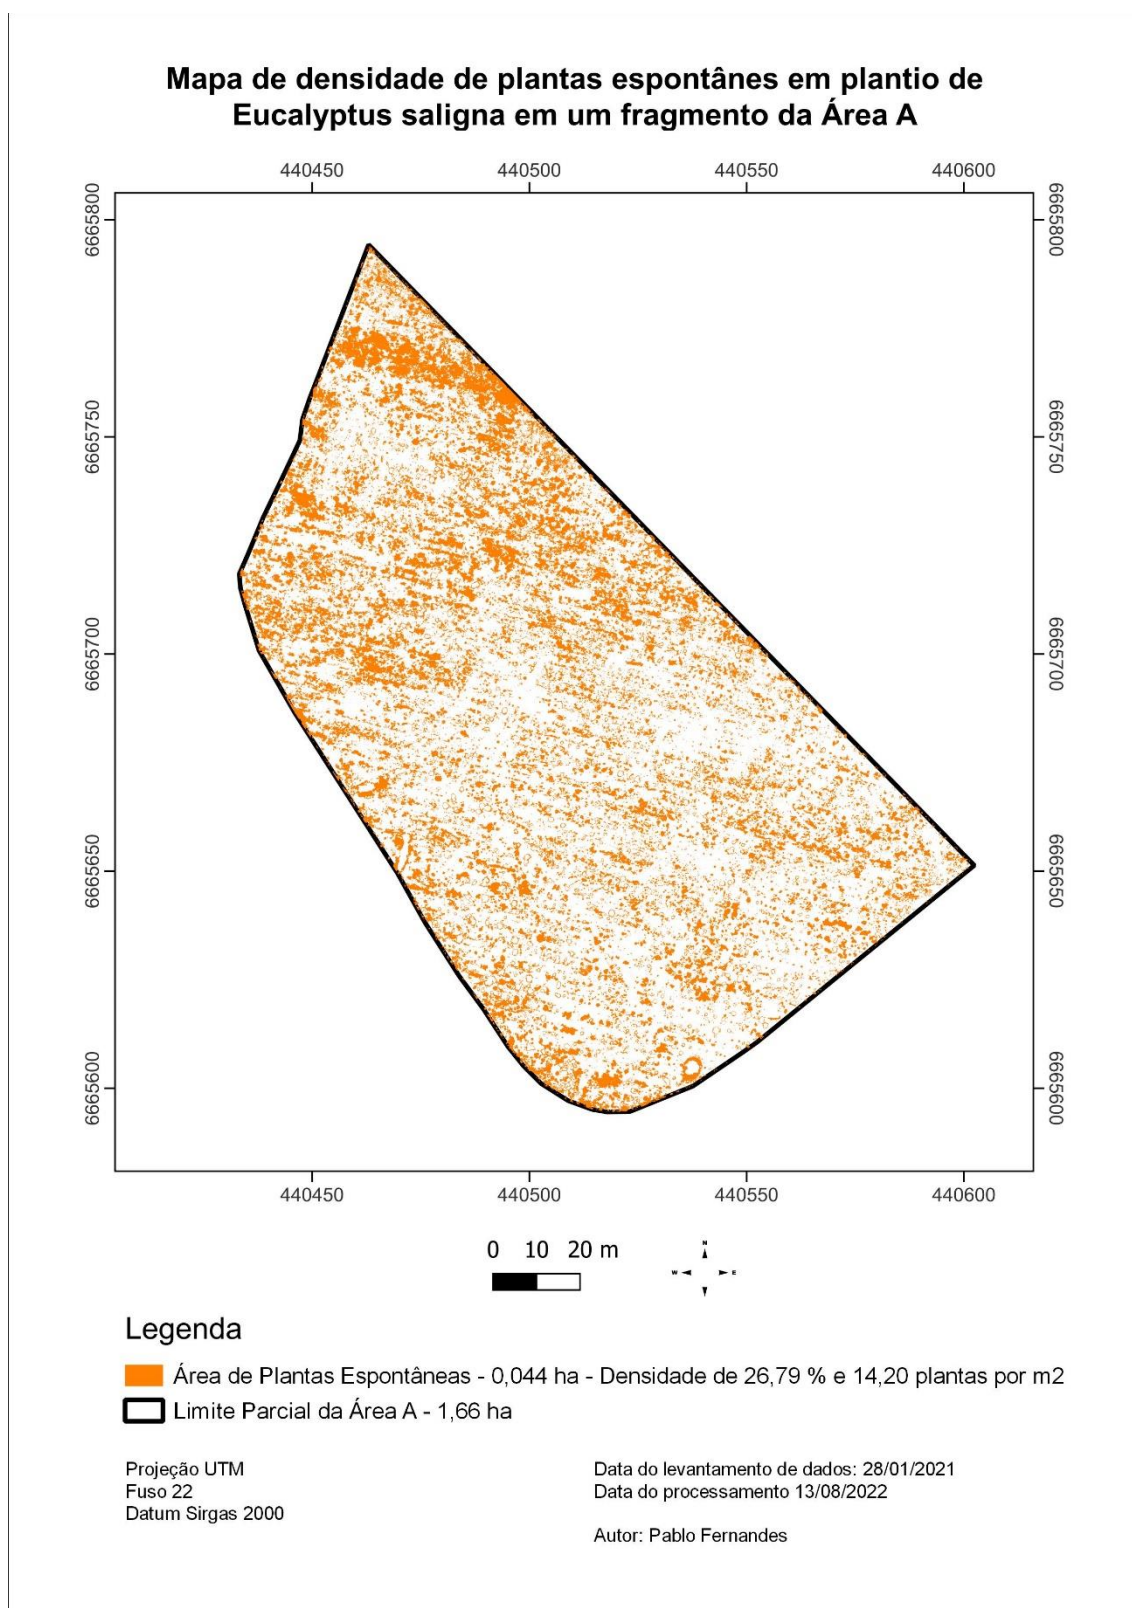
O fragmento da Área A apresentou a maior densidade de plantas espontâneas, 14,20 indivíduos/m², ocupando 26,79% da área, conforme a Figura 40. O fragmento da Área B, apresentou uma área de 5,56% ocupada por plantas espontâneas e uma densidade de 2,12 indivíduos/m², conforme a Figura 41. No fragmento da Área C, as plantas espontâneas ocupam 4,47% da área e uma densidade de 0,51 indivíduos/m², conforme a Figura 42, a menor densidade entre as áreas. Já o fragmento da Área D apresentou apenas 3,28% de cobertura de plantas espontâneas, e uma densidade de 1,14 indivíduos/m², conforme a Figura 43.

Extrapolando o critério estabelecido por Toledo et al., (2001) e Dinardo et al. (2003) para o *Eucalyptus saligna* e, conforme as estimativas, nas áreas B, C e D não seria necessário nenhum tipo de controle. Já para o fragmento A, a densidade de plantas espontâneas registradas determina a intervenção para evitar prejuízo a cultura.

A abordagem proposta no presente estudo, a qual usa diferentes índices de vegetação e bandas espectrais, agregado a um segmentador e um algoritmo de inteligência artificial (*Random Forest – RF*) na classificação das imagens, vai ao encontro dos métodos utilizados pela comunidade científica em estudos de identificação de plantas espontâneas em culturas agrícolas. Kawamura et al. (2021), obtiveram uma precisão de 91,5% em seus resultados ao abordar a classificação de plantas espontâneas na cultura de arroz utilizando imagens de alta resolução submetidas ao algoritmo de classificação RF associado ao segmentador *Simple linear iterative clustering (SLIC)*. Na mesma linha, Gao et al. (2018), utilizando análise orientada a objeto (OBIA) e RF para classificação de plantas espontâneas na cultura do milho, atingiu 94,5% de precisão.

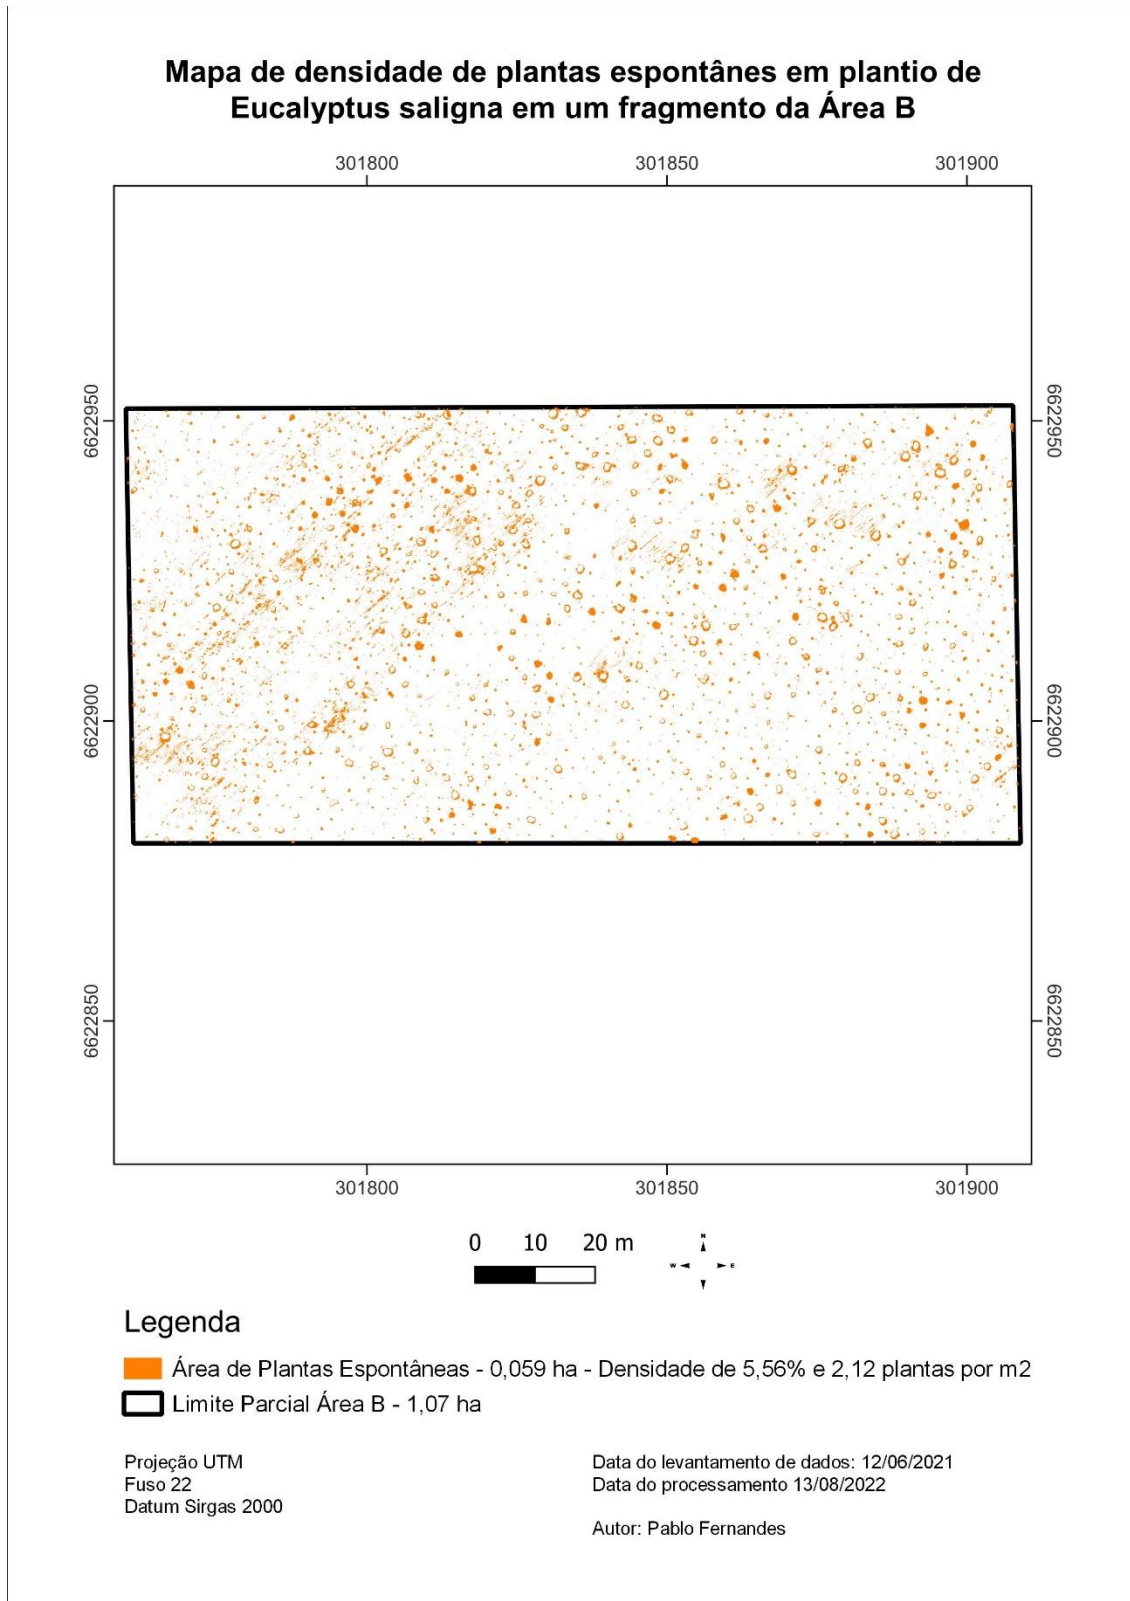
Por outro lado, Watt et al. (2017), ao utilizar imagens multiespectrais provenientes de RPAS e modelos de regressão múltipla utilizando índices de vegetação, obteve uma precisão de 56% para estimativa de porcentagem de cobertura total de plantas espontâneas em povoamentos florestais de Pinus. Os autores atingiram ainda 79% de precisão para determinar a altura das plantas espontâneas e 71% de precisão para estimar o índice de competição das plantas espontâneas com o povoamento de Pinus.

Figura 40 - Mapa de densidade plantas espontâneas da Área A



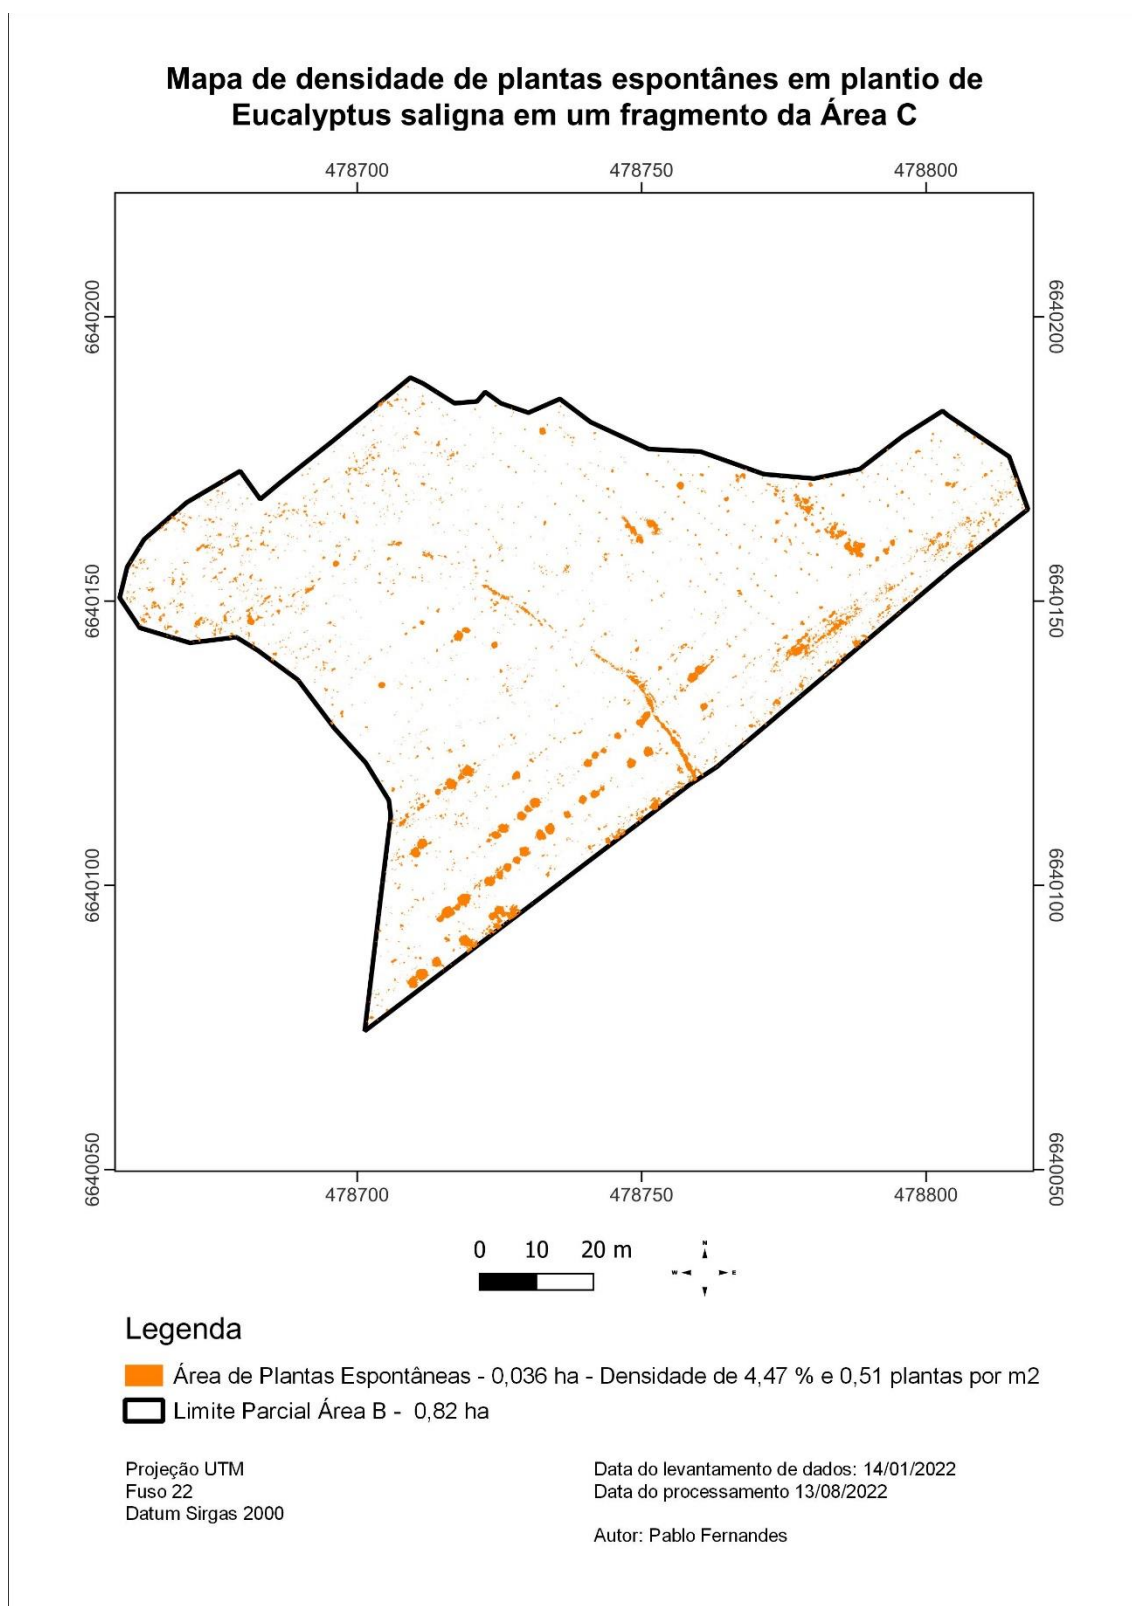
Fonte: Autor. Santa Maria, RS, UFSM, 2022.

Figura 41 - Mapa de densidade plantas espontâneas da Área B



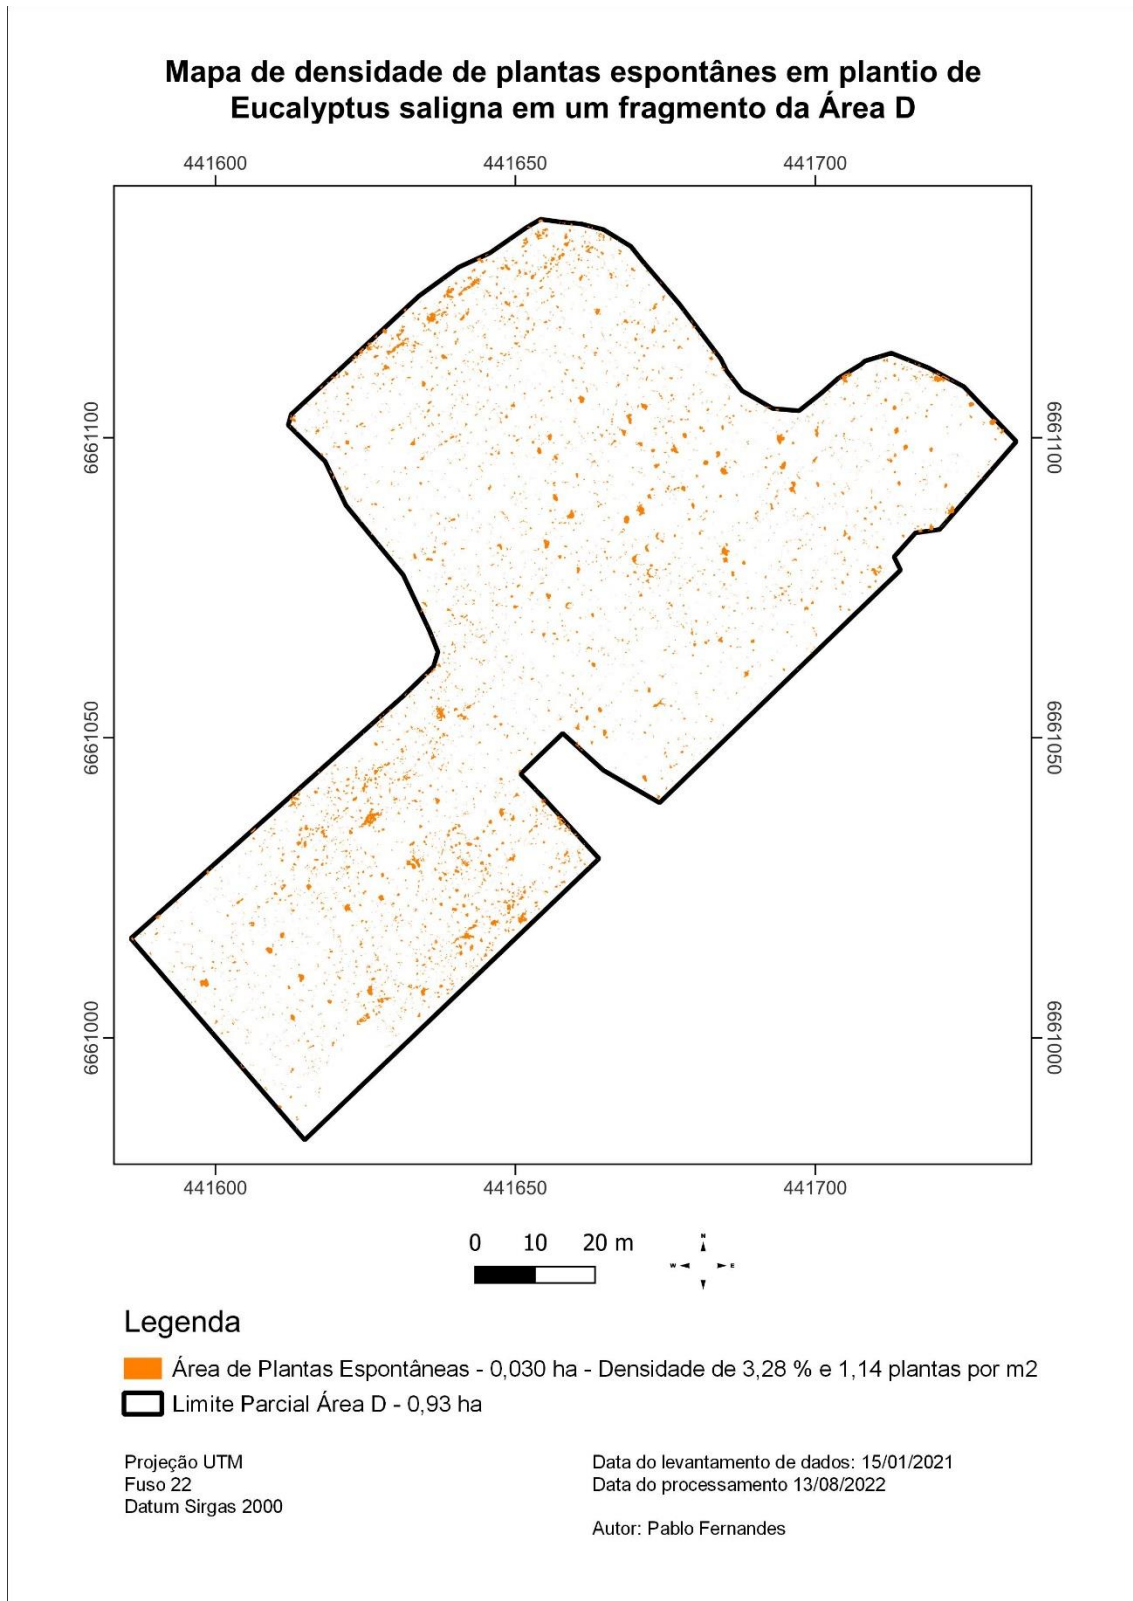
Fonte: Autor. Santa Maria, RS, UFSM, 2022.

Figura 42 - Mapa de densidade plantas espontâneas da Área C



Fonte: Autor. Santa Maria, RS, UFSM, 2022.

Figura 43 - Mapa de densidade plantas espontâneas da Área D



Fonte: Autor. Santa Maria, RS, UFSM, 2022.

6.4 CONCLUSÃO

Conclui-se que ao combinar imagens multiespectrais, provenientes de RPAS e algoritmos de inteligência artificial, como o *Random Forest*, que obteve uma precisão de 95,49%, é possível determinar a densidade de plantas espontâneas em plantio de *Eucalyptus saligna*.

Os mapas gerados por essa técnica são de suma importância para gerenciamento, manejo e controle de plantas espontâneas em plantios de *Eucalyptus saligna*. Eles são capazes de indicar a necessidade de realizar ou não o controle das plantas espontâneas na área.

6.5 REFERÊNCIAS

- BARNES, E. M., CLARKE, T. R., RICHARDS, S. E., COLAIZZI, P. D., HABERLAND, J., KOSTRZEWSKI, M., WALLER, P., CHOI, C., RILEY, E., THOMPSON, T., LASCANO, R. J., LI, H., MORAN, M. S. **Coincident detection of crop water stress, nitrogen status and canopy density using ground based multispectral data**. In PROCEEDINGS 5TH INTERNATIONAL CONFERENCE ON PRECISION AGRICULTURE. Bloomington, 2000. Annals[...] p. 1-15.
- BONETE, I.P.,K.H.P.; DEUS, C.C.; BENIN, A.T.A.; GARRETT, A.N.DIAS, WATZLAWICK, L.F. Identify of hypsometric and volumetric models for *Eucalyptus benthamii* grouped by planting spacing. **Australian Journal of Basic and Applied Sciences**, 10(13): 101-107, 2016.
- CARRASCOSA, F. J. M.; TORRES-SÁNCHEZ, J.; CLAVERO-RUMBAO, I.; et al. Assessing optimal flight parameters for generating accurate multispectral orthomosaics by uav to support site-specific crop management. **Remote Sensing**, v. 7, n. 10, p. 12793–12814, 2015.
- COOK, S. E.; BRAMLEY, R. G. V. Precision agriculture - Opportunities, benefits and pitfalls of site-specific crop management in Australia. **Australian Journal of Experimental Agriculture**, v. 38, n. 7, p. 753–763, 1998.
- Daughtry, C. S. T.; Walthall, C. L.; Kim, M. S.; de Colstoun, E. Brown; McMurtrey Iii, J. E. Estimating Corn Leaf Chlorophyll Concentration from Leaf and Canopy Reflectance. **Remote Sensing of Environment**. 2000.volume 74. Pagina 229-239.
- DE CASTRO, A. I.; TORRES-SÁNCHEZ, J.; PEÑA, J. M.; et al. An automatic random forest-OBIA algorithm for early weed mapping between and within crop rows using UAV imagery. **Remote Sensing**, v. 10, n. 2, 2018.
- DINARDO, W.; TOLEDO, R. E. B.; ALVES, P. L. C. A.; PITELLI, R. A. Efeito da densidade de plantas de *Panicum maximum* Jacq. sobre o crescimento inicial de *Eucalyptus grandis* W. Hill ex Maiden. **Scientia Forestalis**, n. 64, p. 59-69, 2003.

DJI - **General Specifications Phantom 4**. Disponível em: [https://terra-1-g.djicdn.com/851d20f7b9f64838a34cd02351370894/Phantom%E7%B3%BB%E5%88%97/Phantom_4_Pro_Pro_Plus_User_Manual_PT\(1\).pdf](https://terra-1-g.djicdn.com/851d20f7b9f64838a34cd02351370894/Phantom%E7%B3%BB%E5%88%97/Phantom_4_Pro_Pro_Plus_User_Manual_PT(1).pdf). Acesso em 20 de mai 2021.

EUGENIO, F. C.; BADIN, T. L.; FERNANDES, P.; et al. Remotely Piloted Aircraft Systems (RPAS) and machine learning: A review in the context of forest science. **International Journal of Remote Sensing**, v. 42, n. 21, p. 8207–8235, 2021.

EUGENIO, F. C.; GROHS, M.; VENANCIO, L. P.; et al. Estimation of soybean yield from machine learning techniques and multispectral RPAS imagery. **Remote Sensing Applications: Society and Environment**, v. 20, p. 100397, 2020.

GAO, J.; LIAO, W.; NUYTENS, D.; et al. Fusion of pixel and object-based features for weed mapping using unmanned aerial vehicle imagery. **International Journal of Applied Earth Observation and Geoinformation**, v. 67, p. 43–53, 2018.

GAŠPAROVIĆ, M.; SELETKOVIĆ, A.; BERTA, A.; BALENOVIĆ, I. The evaluation of photogrammetry-based DSM from low-cost UAV by LiDAR-based DSM. **South-East European Forestry**, v. 8, n. 2, p. 117–125, 2017. Croatian Forest Research Institute. Acesso em: 18/8/2022.

GITELSON AA, KAUFMAN YJ, MERZLYAK MN. Use of a green channel in remote sensing of global vegetation from EOS-MODIS. **Remote Sens Environ**. 1996; 58: 289–298.

JIMÉNEZ-BRENES, F. M.; LÓPEZ-GRANADOS, F.; TORRES-SÁNCHEZ, J.; et al. Automatic UAV-based detection of *Cynodon dactylon* for site-specific vineyard management. PLoS ONE, v. 14, n. 6, 2019. Public Library of Science.

MOTOHKA, T., NASAHARA, K. N., OGUMA, H., & TSUCHIDA, S. Applicability of green-red vegetation index for remote sensing of vegetation phenology. **Remote Sensing**, 2(10), 2369, 2010.

MINK, R.; LINN, A. I.; SANTEL, H. J.; GERHARDS, R. Sensor-based evaluation of maize (*Zea mays*) and weed response to post-emergence herbicide applications of Isoxaflutole and Cyprosulfamide applied as crop seed treatment or herbicide mixing partner. **Pest Management Science**, v. 76, n. 5, p. 1856–1865, 2019.

PARROT, Devices - **General Specifications Sequoia and Sunshine sensor**. Disponível em :<https://www.parrot.com/business-solutions-us/parrot-professional/parrot-sequoia> Acesso em 21 de mai de 2021.

PEÑA, J. M.; TORRES-SÁNCHEZ, J.; SERRANO-PÉREZ, A.; DE CASTRO, A. I.; LÓPEZ-GRANADOS, F. Quantifying efficacy and limits of unmanned aerial vehicle (UAV) technology for weed seedling detection as affected by sensor resolution. **Sensors** (Switzerland), v. 15, n. 3, p. 5609–5626, 2015.

PEREIRA, M. R. R.; SOUZA, G. S. F.; SILVA, J. I. C.; MARTINS, D. Densidades de

plantas de *Urochloa decumbens* em convivência com *Corymbia citriodora*. **Semina: Ciências Agrárias**, v. 32, p. 1803-1812, 2011.

PEREZ-ORTIZ, M.; GUTIERREZ, P. A.; PENA, J. M.; et al. Machine learning paradigms for weed mapping via unmanned aerial vehicles. **2016 IEEE Symposium Series on Computational Intelligence, SSCI 2016**, 2017. Institute of Electrical and Electronics Engineers Inc. Acesso em: 18/8/2022.

KAWAMURA, K.; ASAI, H.; YASUDA, T.; SOISOUVANH, P.; PHONGCHANMIXAY, S. Discriminating crops/weeds in an upland rice field from UAV images with the SLIC-RF algorithm. **Plant Production Science**, v. 24, n. 2, p. 198–215, 2021.

RESENDE, A. S. DE; LELES, P. S. DOS S. **Controle de plantas daninhas em restauração florestal**. Brasília, DF : Embrapa, 2017. 107 p.

Rouse J, Haas RH, Schell JA, Deering DW. Monitoring vegetation systems in the Great Plains with ERTS. **Proc Third ERTS Symp Wash DC**. 1974; 309–317.

SA, I.; POPOVIĆ, M.; KHANNA, R.; et al. WeedMap: A large-scale semantic weed mapping framework using aerial multispectral imaging and deep neural network for precision farming. **Remote Sensing**, v. 10, n. 9, 2018.

SERRANO, B. I.; PEÑA, J. M.; TORRES-SÁNCHEZ, J.; MESAS-CARRASCOSA, F. J.; LÓPEZ-GRANADOS, F. Spatial quality evaluation of resampled unmanned aerial vehicle-imagery for weed mapping. **Sensors (Switzerland)**, v. 15, n. 8, p. 19688–19708, 2015.

STROPPIANA, D.; VILLA, P.; SONA, G.; et al. Early season weed mapping in rice crops using multi-spectral UAV data. **International Journal of Remote Sensing**, v. 39, n. 15–16, p. 5432–5452, 2018. Taylor and Francis Ltd.

TOLEDO, R. E. B.; DINARDO, W.; BEZUTTE, A. J.; ALVES, P. L. C. A.; PITELLI, R. A. Efeito da densidade de plantas de *Brachiaria decumbens* Stapf. sobre o crescimento inicial de mudas de *Eucalyptus grandis* W. Hill ex Maiden. **Scientia Forestalis**, n. 60, p.109-117, 2001.

TOLEDO, R.E.B. de; VICTORIA FILHO, R.; BEZUTTE, A.J.; PITELLI, R.A; ALVES, P.L. da C.A.; VALLE, C.F. do; ALVARENGA, S.F. Períodos de controle de *Brachiaria sp.* e seus reflexos na produtividade de *Eucalyptus grandis*. **Scientia Forestalis**, n.63, p.221-232, 2003.

TREVISAN, R.,C.R.HASELEIN, E.ELOY, B.O. CARON, R.BALBINOT. Dendrometric characteristics of *Eucalyptus grandis* submitted to thinning. **Australian Journal of Basic and Applied Sciences**, 10(10): 45-51, 2016.

WATT, M. S.; HEAPHY, M.; DUNNINGHAM, A.; ROLANDO, C. Use of remotely sensed data to characterize weed competition in forest plantations. **International Journal of Remote Sensing**, v. 38, n. 8–10, p. 2448–2463, 2017.

7 CONSIDERAÇÕES FINAIS

Diante do exposto, retomando a principal questão do estudo, de que, a utilização de imagens multiespectrais advindas de RPAS combinada ao uso de algoritmos de inteligência artificial é capaz de mapear e quantificar a densidade de plantas espontâneas em plantios de *Eucalyptus saligna*, nas condições do presente estudo, conclui-se que a afirmação é verdadeira, pois com a metodologia utilizada obteve-se uma precisão de 95,49% na determinação plantas espontâneas em plantios de *Eucalyptus saligna*.

Na revisão bibliométrica voltada a caracterizar o estado da arte de pesquisas científicas utilizando técnicas de inteligência artificial e RPAS na identificação de plantas espontâneas em culturas agrícolas e florestais, foi encontrado um único artigo aplicado à área florestal, no qual o próprio autor menciona a dificuldade de realizar uma comparação técnica com outros trabalhos e avaliar o desempenho do modelo proposto.

Entretanto, muitos trabalhos encontrados apresentaram bons resultados na identificação de plantas espontâneas com a utilização de algoritmos de inteligência artificial aliados a imagens de altíssima resolução, norteando assim a determinação da metodologia a ser desenvolvida no presente estudo. Nesse sentido, observou-se que nos trabalhos os sensores utilizados para realizar o imageamento com RPAS são sensores amplamente difundidos, ou seja, sensores comerciais que são capazes de atender a uma gama de diferentes aplicações e que, portanto, os intervalos de comprimento de onda eram limitados.

Sendo assim, fez-se necessário conhecer e compreender o comportamento espectral das espécies de plantas espontâneas encontradas nas áreas do estudo e assim determinar quais os comprimentos de maior relevância para discrimina-las. Dessa forma o presente trabalho chegou nos seguintes intervalos: 510 a 589 nm, 400 a 423 nm, 674 a 731 nm e 886 a 900 nm. No entanto, a disponibilidade de um sensor multiespectral para realizar o estudo ficou restrito à câmera Parrot Sequioa. Dessa forma, foram estudados/comparados os intervalos de comprimento de onda da câmera com os dados de leitura do espectrorradiômetro FieldSpec® 3. Embora tenha havido uma certa queda na precisão, devido a resolução espectral menor, o modelo utilizando como referência as bandas da câmera, foi capaz de classificar as plantas espontâneas com uma precisão de 93,05%.

Ao transpor para o imageamento prático, realizando o imageamento de áreas de plantios de *Eucalyptus saligna*, observou-se que o algoritmo de inteligência artificial foi capaz de modelar a identificação de plantas espontâneas com uma alta precisão e isso só foi possível pois as imagens são de altíssima resolução, facilitando a distinção dos objetos e fornecendo informações espectrais precisas, compondo os preditores dos modelos.

A partir desses resultados foi possível aplicar o modelo treinado e validado e desenvolver produtos temáticos relacionado as plantas espontâneas, contemplando o percentual de cobertura bem como a densidade de plantas espontâneas/m². Com essas informações contida nos mapas foi possível inferir que uma área do estudo já requeria uma intervenção de controle de plantas espontâneas, pois possuía um índice maior do que o limiar encontrado na literatura.

Cabe salientar que, diante da classificação das imagens com os algoritmos de inteligência artificial, as plantas espontâneas foram classificadas com elevada precisão e pouquíssimas plantas espontâneas foram confundidas com *Eucalyptus saligna*. No entanto a precisão de classificação do *Eucalyptus saligna* não obteve bons índices de precisão, ou seja, algumas plantas de *Eucalyptus saligna* foram classificadas como plantas espontâneas, podendo haver uma superestimativa dessas plantas em relação à realidade. Apesar disso, considerando a finalidade de determinar a densidade de plantas, a tomada final de decisões técnicas não é impactada.

Como recomendação visando ampliar o tema estudado, sugere-se avaliar o desempenho do algoritmo com uma intensidade amostral maior para as classes *Eucalyptus saligna* e a rebrota. Da mesma forma, ampliar o contexto das áreas amostrais, com diferentes tipos de solo, condições climáticas e, ampliar o período de dias pós plantio do *Eucalyptus saligna* para coleta de dados, visando fortalecer o treinamento do modelo. Sugere-se ainda, utilizar sensores com comprimento de onda propostos no Capítulo II da presente tese.

8 REFERÊNCIAS BIBLIOGRÁFICAS GERAL

BALAGUER, J. M. E., Caminho. 1939. Disponível em:<<https://www.escrivaworks.org.br/book/caminho-capitulo-1.htm>>. Acesso em: 28 de out. 2022.

BERGER, R. et al. Efeito do espaçamento e da adubação no crescimento de um clone de *Eucalyptus saligna* Smith. **Ciência Florestal**, v. 12, n. 2, p. 75-87, 2002.

BORREGAARD, T.; NIELSENA, H; NØRGAARD, L.; HAVE, H. Crop weed discrimination by line imaging spectroscopy. **Journal of Agricultural Engineering Research**, v. 75, n. 4, p. 389-400, 2000.

COLLINS. **Collins English Dictionary**. 2018. Disponível em:<<https://www.collinsdictionary.com/dictionary/english/artificial-intelligence>>. Acesso em: 20 de mai. 2020.

DE CASTRO, A. I.; TORRES-SÁNCHEZ, J.; PEÑA, J. M.; JIMÉNEZ-BRENES, F. M.; CSILLIK, O.; LÓPEZ-GRANADOS, F. An automatic random forest-OBIA algorithm for early weed mapping between and within crop rows using UAV imagery. **Remote Sensing**, v. 10, n. 2, p. 285, 2018.

DJI - **General Specifications Phantom 4**. Disponível em: [https://terra-1-g.djicdn.com/851d20f7b9f64838a34cd02351370894/Phantom%E7%B3%BB%E5%88%97/Phantom_4_Pro_Pro_Plus_User_Manual_PT\(1\).pdf](https://terra-1-g.djicdn.com/851d20f7b9f64838a34cd02351370894/Phantom%E7%B3%BB%E5%88%97/Phantom_4_Pro_Pro_Plus_User_Manual_PT(1).pdf). Acesso em 20 de mai 2021.

ELLI, E. F.; SENTELHAS, C.; FREITAS, C. H.; CARNEIRO, L. R.; ALVARES, A. C. Assessing the growth gaps of *Eucalyptus* plantations in Brazil – Magnitudes, causes and possible mitigation strategies. **Forest Ecology and Management**, v. 451, p. 117464, 2019.

IBÁ. Indústria Brasileira de Árvores. **Relatório anual 2016**. Brasília, DF, 2016. 100 p.

IBÁ. **Indústria Brasileira de Árvores**. Relatório 2020. Disponível em: <<https://iba.org/datafiles/publicacoes/relatorios/relatorio-iba-2020.pdf>>. Acesso em: 19 de mai. 2021.

FACELI, K. et al. **Inteligência Artificial: Uma abordagem de Aprendizado de Máquina**. Rio de Janeiro: LTC, 2011.

FISHER, R, F.; BINKLEY, D. Ecology and management of forest soils. New York: wiley, 2001. 489p.

GOLDSCHIMIDT, R. R. **Inteligência Computacional**. 1ª ed. Rio de Janeiro: Instituto Superior de Tecnologia - Rio, 2010. 143 p.

IPEF. INSTITUTO DE PESQUISA E ESTUDOS FLORESTAIS. **Indicações para a escolha de espécies de *Eucalyptus***. 2005. Disponível em:

<<http://www.ipef.br/identificacao/eucalyptus/indicacoes.asp>>. Acesso em: 19 mai. 2021.

MALENOVSKÝ, Z.; LUCIEER, A.; KING, D. H.; TURNBULL, J. D.; ROBINSON, S. A. Unmanned aircraft system advances health mapping of fragile polar vegetation. **Methods Ecol Evol.**, v. 8, n. 12, p. 1842-1857, 2017.

MORA, A. L.; GARCIA, C. H. **Acultura do eucalipto no Brasil**. São Paulo: SBS, 2000. 112p.

PANTAZI, X. E.; MOSHOU, D.; BOCHTIS, D. **Artificial intelligence in agriculture: Intelligent Data Mining and Fusion Systems in Agriculture**. San Diego, United States, 2020, 101.

PARROT, Devices - **General Specifications Sequoia and Sunshine sensor**. Disponível em :<https://www.parrot.com/business-solutions-us/parrot-professional/parrot-sequoia> Acesso em 21 de mai de 2021.

PEREIRA, M. R. R.; SOUZA, G. S. F.; FONSECA, E. D.; MARTINS, D. Subdoses de glyphosate no desenvolvimento de espécies arbóreas nativas. **Bioscience Journal**, v. 31, n. 2, p. 326-332, 2015.

PEREZ-ORTIZ, M. et al. Machine learning paradigms for weed mapping via unmanned aerial vehicles. **2016 IEEE Symposium Series on Computational Intelligence, SSCI 2016**, 2017.

RASMUSSEN, J.; NIELSEN, J.; STREIBIG, J. C.; JENSEN, J. E.; PEDERSEN, K. S.; OLSEN, S. I. Pre-harvest weed mapping of *Cirsium arvense* in wheat and barley with off-the-shelf UAVs. **Precision Agriculture**, v. 20, n. 5, p. 983–999, 2019.

RESENDE, A. S.; LELES, P. S. S. O problema do controle de plantas daninhas na restauração florestal. In: **Controle de plantas daninhas em restauração florestal**. Seropédica: Embrapa Agrobiologia, p. 13-27, 2017.

SIMON, P. **Too Big to Ignore: The Business Case for Big Data**. 1. ed. Hoboken, Wiley: [s.n.], 2013.

STRECK, E. ET AL. **Solos do Rio Grande do Sul**. 2.ed. Porto Alegre:EMATER/RS, 2008. 222 P..

TOLEDO, R. E. B. Faixas de controle de plantas daninhas e seus reflexos no crescimento de plantas de eucalipto. **Scientia Florestalis**, v. 64, p. 78-92, 2003.

WANG, S., LIU, H.; HAN, Y.; CHEN, J.; PAN, Y.; CAO, Y.; ZHENG, Y. (2018). Low-altitude remote sensing based on convolutional neural network for weed classification in ecological irrigation área. **IFAC-PapersOnLine**, v. 51, n. 17, p. 298-303, 2018.