

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

Sally Deborah Pereira da Silva

**FLORESTA DE PRECISÃO NA IDENTIFICAÇÃO DE ESPÉCIES
FLORESTAIS EXÓTICAS INVASORAS**

Santa Maria, RS
2022

Sally Deborah Pereira da Silva

**FLORESTA DE PRECISÃO NA IDENTIFICAÇÃO DE ESPÉCIES FLORESTAIS
EXÓTICAS INVASORAS**

Dissertação apresentada ao curso de mestrado do Programa de Pós-Graduação em Engenharia Florestal, área de Concentração em Manejo Florestal, da Universidade Federal de Santa Maria (UFSM - RS), como requisito parcial para a obtenção do grau de **Mestre em Engenharia Florestal**.

Orientador: Prof^o. Dr^o. Fernando Coelho Eugenio
Coorientador: Prof^o. Dr^o. Rudiney Soares Pereira

Santa Maria, RS
2022

da Silva, Sally Deborah Pereira
Floresta de precisão na identificação de espécies
florestais exóticas invasoras / Sally Deborah Pereira da
Silva.- 2022.

112 p.; 30 cm

Orientador: Fernando Coelho Eugenio

Coorientador: Rudiney Soares Pereira

Dissertação (mestrado) - Universidade Federal de Santa
Maria, Centro de Ciências Rurais, Programa de Pós
Graduação em Engenharia Florestal, RS, 2022

1. Inteligência artificial 2. Invasão Biológica 3.
Sensoriamento Remoto com RPAS I. Eugenio, Fernando
Coelho II. Pereira, Rudiney Soares 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, SALLY DEBORAH PEREIRA DA SILVA, para os devidos fins e sob as penas da lei, que a pesquisa constante neste trabalho de conclusão de curso (Dissertação) 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.

Sally Deborah Pereira da Silva

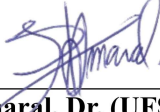
**FLORESTA DE PRECISÃO NA IDENTIFICAÇÃO DE ESPÉCIES
FLORESTAIS EXÓTICAS INVASORAS**

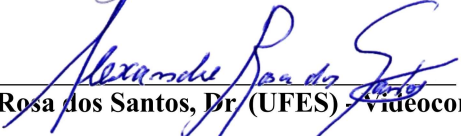
Dissertação apresentada ao curso de mestrado do Programa de Pós-Graduação em Engenharia Florestal, área de Concentração em Manejo Florestal, da Universidade Federal de Santa Maria (UFSM - RS), como requisito parcial para a obtenção do grau de **Mestre em Engenharia Florestal**.

Aprovado em 22 de fevereiro de 2022:

Documento assinado digitalmente
 Fernando Coelho Eugenio
Data: 17/03/2022 21:34:13-0300
Verifique em <https://verificador.itl.br>

Fernando Coelho Eugenio, Dr. (UFSM) - Videoconferência
(Presidente/Orientador)


Lúcio de Paula Amaral, Dr. (UFSM) - Videoconferência
Lúcio de Paula Amaral
SIAPE 1054438
Dep. de Eng. Rural/CCR UFSM


Alexandre Rosa dos Santos, Dr. (UFES) - Videoconferência


Prof. Dr. Alexandre Rosa dos Santos
Departamento de Engenharia Rural
CCAE-UFES

Santa Maria, RS
2022

DEDICATÓRIA

A meu pai, Severino Pereira da Silva (*in memoriam*), dedico.

AGRADECIMENTOS

Reconhecer que ninguém voa sozinho é o primeiro passo para tudo na vida. Reconhecer que não voei sozinha ao longo desse mestrado é o ponto de partida para estes agradecimentos, que reúnem pessoas, lugares, decolagens e pousos que me trouxeram até aqui.

A mulher incrível e guerreira que é a minha mãe, Dileusa Silva, pois sempre acreditou em mim, encorajou a seguir meus sonhos e me fez manter a fé. A meus irmãos Samyr, Larissa e meu sobrinho Armin, agradeço pela existência de vocês em minha vida. A meu padrasto Mazin, por todo o esforço e ajuda. A toda minha família (tios, tias e meus avós), por me ajudarem sempre que precisei.

A meu orientador Dr. Fernando Coelho Eugenio, minha gratidão por ter acreditado no meu potencial, por compartilhar seus conhecimentos, experiências, conselhos acadêmicos e pessoais, ter fornecido todos os meios para que eu realizasse esse trabalho, ter sempre respondido as minhas dúvidas e apoiado minhas decisões. Muito obrigada!

A Caroline Mallmann e toda a equipe do PEQC, por disponibilizarem seu tempo, conhecimento, apoio e todo suporte nas idas ao parque para realização desse trabalho.

A Roberta Fantinel e Fernanda Dias, por disponibilizarem seu tempo e ajuda durante a coleta de campo. Vocês foram demais, obrigada!

A meu namorado, Lucas Rigon, que trouxe amor e tranquilidade, principalmente nos dias mais difíceis, acreditou e me apoiou em todos os momentos, a você e Pandora, obrigada por tudo!

As minhas amigas que, conhecendo de perto o caminho que trilhei, nunca negaram amizade, solidariedade, sorrisos e incentivos, em especial: Patrícia Reis, Cláudia Souza, Moara Porpino e Kássya Oliveira. Aos amigos que me acolheram em SM, obrigada por tudo que fizeram: Victor Machado, Jesomi Abreu e Renata Machado!

A Universidade Federal de Santa Maria, por meio do Programa de Pós-Graduação em Engenharia Florestal, possibilitou prosseguir meus estudos, desejo que a UFSM continue pública, gratuita e socialmente referenciada. Aos docentes que compartilharam o seu conhecimento, contribuindo para que pudesse alcançar o meu objetivo. Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pelo apoio financeiro, através da concessão de bolsa de estudos.

Agradeço aos membros da banca avaliadora.

A Deus. A todos vocês, os meus sinceros agradecimentos.

“Não quero dizer, porém, que, porque esperançoso, atribuo à minha esperança o poder de transformar a realidade e, assim, convencido, parto para o embate sem levar em consideração os dados concretos, materiais, afirmando que minha esperança basta. Minha esperança é necessária, mas não é suficiente. Ela, só, não ganha a luta, mas sem ela, a luta fraqueja e titubeia. Precisamos da esperança crítica, como o peixe necessita de água despoluída.”

Paulo Freire

RESUMO

FLORESTA DE PRECISÃO NA IDENTIFICAÇÃO DE ESPÉCIES FLORESTAIS EXÓTICAS INVASORAS

AUTORA: Sally Deborah Pereira da Silva
ORIENTADOR: Fernando Coelho Eugenio

As espécies florestais exóticas invasoras (EFEI's) têm potencial de transformar a estrutura e formação dos ecossistemas, devido a sua capacidade de excluir espécies nativas e destruir características que a biodiversidade local proporciona. Diante da preocupação que as EFEI's trazem, sua identificação e acompanhamento são necessários, no entanto, tais tarefas em áreas protegidas são complexas, devido a grande dimensão territorial, dificuldade de acesso e custos elevados para inventariar essas espécies em campo. Dessa forma, o sensoriamento remoto por meio de plataformas aéreas, tais como o RPAS (Sistemas de Aeronaves Remotamente Pilotadas), destacam-se como uma abordagem importante para identificar e monitorar as EFEI's, uma vez que permitem mapeamento rápido e frequente em conjunto com as técnicas de aprendizado de máquina (AM) para incorporação de conhecimentos especializados no processamento. Portanto, a presente pesquisa teve por objetivo avaliar a combinação do uso de imagens obtidas por RPAS e algoritmos de aprendizado de máquina para identificar espécies florestais exóticas invasoras no Parque Estadual Quarta Colônia, Rio Grande do Sul, Brasil. Os dados de campo foram obtidos em duas áreas amostrais distintas, onde foi realizado o censo das EFEI's *Hovenia dulcis* e *Psidium guajava*, sendo mensuradas as variáveis CAP ≥ 5 cm, altura, e coletadas as coordenadas geográficas com GPS. Para obtenção dos dados remotos foi utilizado um RPAS acoplado a uma câmera multispectral *Parrot Sequoia*. Posteriormente, realizou-se o processamento das imagens no aplicativo *Pix4D*® para geração dos mapas de reflectância, e o Sistema de Informação geográfica (SIG) *ArcMap*® 10.8 para geração de índices de vegetação e também a distribuição espacial das espécies inventariadas, a qual foi feita a partir da fotointerpretação manual. Em sequência, para o processo de treinamento dos modelos, no SIG *ArcGis Pro*® 2.8, foram definidas quatro classes de interesse, sendo para área amostral I (*H. dulcis*) e área amostral II (*P. guajava*) e as classes espécie similar, sombra e demais espécies aplicadas a ambas as áreas. O processo de classificação supervisionada envolveu duas abordagens (*pixel a pixel* e análise baseada em objeto – OBIA) e dois algoritmos de AM em comparação (*Random Forest – RF* e *Support Vector Machine – SVM*). As amostras foram separadas em 90% para treinamento/teste e 10% para validação dos modelos. Para análise de desempenho, foram calculadas as métricas de acurácia global e índice de Kappa. Os resultados demonstram que o algoritmo *RF* na abordagem *pixel a pixel* teve o melhor desempenho em classificar a EFEI *H. dulcis*, obtendo um kappa de 0,87 e acurácia global de 91,5%. Para a EFEI *P. guajava*, com a composição de imagens RGB, o melhor resultado foi obtido no método OBIA e o algoritmo *RF* (Kappa de 0,89 e acurácia global 92,5%). A composição multispectral RGCV mostrou-se excelente em diferenciar padrão da EFEI *P. guajava* em abordagem OBIA com o algoritmo *RF* (Kappa 0,90 e acurácia global 93%). Diante dos resultados obtidos, o presente estudo possui uma nova e importante metodologia para identificação das EFEI's *Hovenia dulcis* e *Psidium guajava* em áreas de Floresta Estacional Decidual, uma vez que pode ser usado em estratégias de manejo adequadas ao controle e erradicação dessas espécies.

Palavras-chave: Inteligência artificial. Invasão Biológica. Sensoriamento Remoto com RPAS.

ABSTRACT

PRECISION FOREST IN IDENTIFICATION OF INVASIVE EXOTIC FOREST SPECIES

AUTHOR: Sally Deborah Pereira da Silva
ADVISOR: Fernando Coelho Eugenio

Invasive Exotic Forest Species (IEFE) have the potential to transform the structure and formation of ecosystems, due to their ability to exclude native species and destroy characteristics that local biodiversity provides. Given the concern that IEFE bring, their identification and monitoring are necessary, however, such tasks in protected areas are complex, due to the large territorial dimension, difficulty of access and high costs to inventory these species in the field. In this way, remote sensing through aerial platforms, such as RPAS (Remotely Piloted Aircraft Systems), stands out as an important approach to identify and monitor IEFE, since they allow fast and frequent mapping together with the machine learning (ML) techniques for incorporating specialized knowledge into processing. Therefore, the present research aimed to evaluate the combination of the use of images obtained by RPAS and machine learning algorithms to identify invasive exotic forest species in the Quarta Colônia State Park, Rio Grande do Sul, Brazil. Field data were obtained in two different sampling areas, where the IEFE *Hovenia dulcis* and *Psidium guajava* census was carried out, measuring the variables $CAP \geq 5$ cm, height, and geographic coordinates collected with GPS. To obtain the remote data, an RPAS coupled to a Parrot Sequoia multispectral camera was used. Subsequently, the images were processed using the Pix4D® application to generate reflectance maps, and the ArcMap® 10.8 Geographic Information System (GIS) to generate vegetation indices and also the spatial distribution of the inventoried species, which was made from manual photointerpretation. In sequence, for the training process of the models, in the GIS ArcGis Pro® 2.8, four classes of interest were defined, being for sample area I (*H. dulcis*) and sample area II (*P. guajava*) and the classes similar species, shade and other species applied to both areas. The supervised classification process involved two approaches (pixel-by-pixel and object-based analysis – OBIA) and two ML algorithms in comparison (Random Forest – RF and Support Vector Machine – SVM). The samples were separated into 90% for training/testing and 10% for model validation. For performance analysis, overall accuracy and Kappa index metrics were calculated. The results demonstrate that the RF algorithm in the pixel-by-pixel approach had the best performance in classifying the IEFE *H. dulcis*, obtaining a kappa of 0.87 and an overall accuracy of 91.5%. For IEFE *P. guajava*, with the composition of RGB images, the best result was obtained using the OBIA method and the RF algorithm (Kappa of 0.89 and overall accuracy of 92.5%). The RGCV multispectral composition proved to be excellent in differentiating the IEFE *P. guajava* pattern in the OBIA approach with the RF algorithm (Kappa 0.90 and overall accuracy 93%). In view of the results obtained, the present study has a new and important methodology for identifying the IEFE *Hovenia dulcis* and *Psidium guajava* in areas of Seasonal Deciduous Forest, since it can be used in management strategies suitable for the control and eradication of these species.

Keywords: Artificial intelligence. Biological Invasion. Remote Sensing with RPAS.

LISTA DE ILUSTRAÇÕES

FIGURA 1 - Sequência de eventos que descrevem a invasão biológica, da introdução à invasão. As principais barreiras que limitam a propagação de plantas exóticas introduzidas (geográfica, ambiental, reprodutiva, dispersão, habitats naturais e perturbados).....	35
FIGURA 2 - Espectro eletromagnético.....	41
FIGURA 3 - Curva da reflectância espectral da vegetação.....	42
FIGURA 4 - Domínios da Inteligência Artificial.....	49
FIGURA 5 - Hierarquia do aprendizado de máquina.....	50
FIGURA 6 - Mapa de localização do Parque Estadual Quarta Colônia, RS, Brasil.....	55
FIGURA 7 - Mapa de localização das áreas de estudo no Parque Estadual Quarta Colônia, RS, Brasil.	57
FIGURA 8 – Vista interior (a), vista frontal (b) e vista aérea usando a câmera RGB do RPAS (c) da área amostral I. Vista interior (d), vista frontal (e) e vista aérea usando a câmera RGB do RPAS (f) da área amostral II.....	60
FIGURA 9 - Geolocalização das espécies alvo nas áreas amostrais I e II, Parque Estadual da Quarta Colônia, RS, Brasil.	64
FIGURA 10 - Sequência metodológica empregada na obtenção do modelo RGB para identificação de EFEI's <i>H. dulcis</i> e <i>P. guajava</i> no PEQC, RS, Brazil.	72
FIGURA 11 - Sequência metodológica empregada na obtenção do modelo multiespectral para identificação de EFEI's <i>H. dulcis</i> e <i>P. guajava</i> no PEQC, RS, Brazil.....	73
FIGURA 12 – Representação da EFEI <i>hovenia dulcis</i> localizadas na área amostral I.....	75
FIGURA 13 - Resultado das classificações <i>pixel a pixel</i> (a) e OBIA (b), ambos com o algoritmo RF, para <i>H. dulcis</i> no PEQC, RS, Brasil.....	75
FIGURA 14 - Resultado da classificação <i>pixel a pixel</i> (a) e OBIA (b), ambos com o algoritmo SVM, para <i>H. dulcis</i> no PEQC, RS, Brasil.....	76
FIGURA 15 - Representação da EFEI <i>Psidium guajava</i> localizadas na área amostral II no PEQC, RS, Brasil.....	80
FIGURA 16 – Resultado da classificação <i>pixel a pixel</i> (a) e OBIA (b), ambos com o algoritmo RF utilizando a composição de imagens RGB, para <i>P. guajava</i> no PEQC, RS, Brasil.....	81
FIGURA 17 - Resultado da classificação <i>pixel a pixel</i> (a) e OBIA (b), ambas om o algoritmo SVM utilizando a composição de imagens RGB, para <i>P. guajava</i> no PEQC, RS, Brasil.....	82
FIGURA 18 – Resultado da correlação de Spearman entre os preditores e as variáveis respostas relacionadas a espécie invasora <i>Psidium guajava</i> no PEQC, RS, Brasil.....	84

FIGURA 19 - Resultado da classificação *pixel a pixel* (a) e OBIA (b), ambas com o algoritmo RF utilizando a composição de imagens RGCV para *P. guajava* no PEQC, RS, Brasil.....87

FIGURA 20 - Resultado da classificação *pixel a pixel* (a) e OBIA (b), ambas com o algoritmo SVM utilizando a composição de imagens RGCV para *P. guajava* no PEQC, RS, Brasil.....88

LISTA DE TABELAS

TABELA 1 - Termos recomendados em ecologia de invasão de plantas.....	34
TABELA 2 - Exemplos de uso de RPAS na identificação de espécies florestais exóticas invasoras.....	47
TABELA 3 - Informações sobre os voos realizados nas áreas de estudo.....	62
TABELA 4 - Índices de Vegetação utilizados no estudo.....	65
TABELA 5 – Parâmetros utilizados no algoritmo <i>Random Forest</i> para o processo de classificação supervisionada.....	69
TABELA 6 - Parâmetro utilizado no algoritmo <i>Support Vector Machine</i> para o processo de classificação supervisionada.....	69
TABELA 7 - Nível de exatidão da classificação, conforme o valor do Índice Kappa.....	70
TABELA 8 – Resultado dos valores de Acurácia global e Índice Kappa para as classificações realizadas a partir das abordagens <i>pixel a pixel</i> e OBIA para <i>H. dulcis</i> no PEQC, RS, Brasil.....	77
TABELA 9 - Resultado dos valores de Acurácia global e Índice Kappa para as classificações realizadas a partir das abordagens <i>pixel a pixel</i> e OBIA com a composição de imagens RGB para <i>P. guajava</i> no PEQC, RS, Brasil.....	82
TABELA 10 - Resultado dos valores de Acurácia global e Índice Kappa para as classificações realizadas a partir das abordagens <i>pixel a pixel</i> e OBIA, com a composição de imagens RGCV, para <i>P. guajava</i> no PEQC, RS, Brasil.....	85
TABELA 11 - Matriz de confusão do desempenho da classificação <i>pixel a pixel</i> com o algoritmo <i>Random Forest</i>	107
TABELA 12 - Matriz de confusão do desempenho da classificação OBIA com o algoritmo <i>Random Forest</i>	107
TABELA 13 - Matriz de confusão do desempenho da classificação <i>pixel a pixel</i> com o algoritmo <i>Support Vector Machine</i>	108
TABELA 14 - Matriz de confusão do desempenho da classificação OBIA com o algoritmo <i>Support Vector Machine</i>	108
TABELA 15 - Matriz de confusão do desempenho da classificação <i>pixel a pixel</i> com o algoritmo <i>Random Forest</i> utilizando a composição de imagens RGB.....	109
TABELA 16 - Matriz de confusão do desempenho da classificação OBIA com o algoritmo <i>Random Forest</i> utilizando a composição de imagens RGB.....	109

TABELA 17 - Matriz de confusão do desempenho da classificação <i>pixel a pixel</i> com o algoritmo <i>Support Vector Machine</i> utilizando a composição de imagens RGB.....	110
TABELA 18 - Matriz de confusão do desempenho da classificação OBIA com o algoritmo <i>Support Vector Machine</i> utilizando a composição de imagens RGB.....	110
TABELA 19 - Matriz de confusão do desempenho da classificação <i>pixel a pixel</i> com o algoritmo <i>Random Forest</i> utilizando a composição de imagens RGCV.....	111
TABELA 20 - Matriz de confusão do desempenho da classificação OBIA com o algoritmo <i>Random Forest</i> utilizando a composição de imagens RGCV.....	111
TABELA 21 - Matriz de confusão do desempenho da classificação <i>pixel a pixel</i> com o algoritmo <i>Support Vector Machine</i> utilizando a composição de imagens RGCV.....	112
TABELA 22 - Matriz de confusão do desempenho da classificação OBIA com o algoritmo <i>Support Vector Machine</i> utilizando a composição de imagens RGCV.....	112

LISTA DE QUADROS

QUADRO 1 - Descrição da espécie <i>Hovenia dulcis</i> Thumb.....	58
QUADRO 2 - Descrição da espécie <i>Psidium guajava</i> L.	59
QUADRO 3 - Especificações técnicas do Sensor <i>Parrot Sequoia</i>	61
QUADRO 4 - Definição das classes de interesse para a área amostral I.	67
QUADRO 5 - Definição das classes de interesse para a área amostral II.	67

LISTA DE EQUAÇÕES

EQUAÇÃO 1.....	70
EQUAÇÃO 2.....	70

LISTA DE SIGLAS

AM	Aprendizado de Máquina
ANAC	Agência Nacional de Aviação Civil
APP	Área de Preservação Permanente
ANATEL	Agência Nacional de Telecomunicações
CAP	Circunferência a Altura do Peito
CDB	Convenção da Diversidade Biológica
CFA	Subtropical úmido
CNN	<i>Convolutional Neural Network</i>
CVI	<i>Chlorophyll Vegetation Index</i>
DAP	Diâmetro à Altura do Peito
DECEA	Departamento de Controle do Espaço Aéreo
DL	<i>Deep Learning</i>
E EI	Espécie Exótica Invasora
EFEI	Espécie Florestal Exótica Invasora
EVI	<i>Enhanced Vegetation Index</i>
GNDVI	<i>Green Normalized Difference Vegetation Index</i>
GPS	Sistema de Posicionamento Global
GSD	<i>Ground Sample Distance</i>
GWDRVI	<i>Green Wide Dynamic Range Vegetation Index</i>
IA	Inteligência Artificial
IAF	Índice de Área Foliar
IV	Índice de Vegetação
MCARI	<i>Modified Chlorophyll Absorption in Reflectance Index</i>
ML	<i>Machine Learning</i>
MS	<i>Mean Shift</i>
MSAVI	<i>Modified Soil Adjusted Vegetation Index</i>
MTVI	<i>Modified Triangular Vegetation Index</i>
NDVI	<i>Normalized Difference Vegetation Index</i>
NDWI	<i>Normalized Difference Wide Index</i>
NN	<i>Nearest Neighbor</i>
OBIA	<i>Object-based Image Analysis</i>
OSAVI	<i>Optimized Soil Adjusted Vegetation Index</i>

PEQC	Parque Estadual Quarta Colônia
PIXEL	<i>Picture element</i>
REM	Radiação Eletromagnética
RF	<i>Random Forest</i>
RL	Regressão Logística
RPAS	<i>Remotely Piloted Aircraft System</i>
RS	Rio Grande do Sul
SAVI	<i>Soil-Adjusted Vegetation Index</i>
SBCS	Sistema Brasileiro de Classificação de Solos
SEMA	Secretaria do Meio Ambiente e Infraestrutura
SIG	Sistema de Informação Geográfica
SNUC	Sistema Nacional de Unidades de Conservação
SR	Sensoriamento Remoto
SVM	<i>Support Vector Machine</i>
TCARI	<i>Transformed Chlorophyll Absorption in Reflectance Index</i>
TVI	<i>Transformed Vegetation Index</i>
UC	Unidade de Conservação
UE	União Europeia
WDRVI	<i>Wide Dynamic Range Vegetation Index</i>
WGS	<i>World Geodetic System</i>

SUMÁRIO

1 INTRODUÇÃO	29
1.1 OBJETIVOS	31
1.1.1 Objetivo Geral	32
1.1.2 Objetivos Específicos	32
2 REVISÃO DE LITERATURA	33
2.1 ESPÉCIES EXÓTICAS INVASORAS (EEI's)	33
2.1.1 Espécies Exóticas Invasoras no Rio Grande do Sul	38
2.2 SENSORIAMENTO REMOTO DA VEGETAÇÃO: CONCEITOS E APLICAÇÕES.....	40
2.2.1 Sensoriamento Remoto de Alta Resolução	43
2.2.1.1 Uso de RPAS para identificação de espécies florestais.....	46
2.3 INTELIGÊNCIA ARTIFICIAL.....	48
2.3.1 Aprendizado de máquina - <i>Machine learning</i>	49
2.3.1.1 Aprendizado Não supervisionado.....	50
2.3.1.1.1 Segmentação de imagens	51
2.3.1.2 Aprendizado Supervisionado.....	52
2.3.1.2.1 Support Vector Machine (SVM)	52
2.3.1.2.2 Random Forest (RF)	53
3 MATERIAL E MÉTODOS	55
3.1 LOCALIZAÇÃO E CARACTERIZAÇÃO DA ÁREA DE ESTUDO	55
3.1.1 Área amostral	56
3.2 AQUISIÇÃO DOS DADOS DE CAMPO	57
3.2.1 Descrição das espécies alvo	57
3.2.1.1 <i>Hovenia dulcis</i> Thumb.	58
3.2.1.2 <i>Psidium guajava</i> L.	59
3.2.2 Levantamento Florístico	59
3.3 AQUISIÇÃO DOS DADOS REMOTOS.....	60
3.3.1 Aquisição das imagens	60
3.4 PROCESSAMENTO DOS DADOS	62
3.4.1 Criação do <i>shapefile</i> das EFEI's	62
3.4.2 Geração do ortofotomosaico	63
3.4.3 Georreferenciamento das imagens	63
3.4.4 Geolocalização das espécies alvos	63
3.4.5 Índices de Vegetação	64

3.5	SELEÇÃO DAS VARIÁVEIS DE ENTRADA PARA APRENDIZADO DE MÁQUINA.....	66
3.6	MODELO DE CLASSIFICAÇÃO	66
3.6.1	Criação das amostras de treinamento	66
3.6.2	Processo de Classificação.....	68
3.6.3	Aprendizado de Máquina no SIG <i>ArcGis Pro</i>	68
3.6.4	Avaliação da Precisão	70
3.6.5	Escolha do Modelo	71
4	RESULTADOS E DISCUSSÃO.....	74
4.1	IDENTIFICAÇÃO DA ESPÉCIE FLORESTAL EXÓTICA INVASORA <i>Hovenia dulcis</i>	74
4.1.1	Validação e seleção do modelo	79
4.2	IDENTIFICAÇÃO DA ESPÉCIE FLORESTAL EXÓTICA INVASORA <i>Psidium guajava</i>	80
4.2.1	Validação e seleção do modelo	88
5	CONSIDERAÇÕES FINAIS.....	89
	REFERÊNCIAS.....	91
	APÊNDICE A – MATRIZ DE CONFUSÃO GERADAS PARA ESPÉCIE <i>H. DULCIS</i>	107
	APÊNDICE B – MATRIZ DE CONFUSÃO GERADAS PARA ESPÉCIE <i>P. GUAJAVA</i> COM A COMPOSIÇÃO DE IMAGENS RGB..	109
	APÊNDICE C – MATRIZ DE CONFUSÃO GERADAS PARA ESPÉCIE <i>P. GUAJAVA</i> COM A COMPOSIÇÃO DE IMAGENS RGCV	111

1 INTRODUÇÃO

A invasão biológica é considerada uma das principais causas associadas às mudanças ambientais em escala global, cujos impactos afetam direta e indiretamente a biodiversidade, os serviços ecossistêmicos, à saúde humana, e à economia. As espécies exóticas invasoras (EEI's) possuem grande potencial de transformar a estrutura e formação original dos ecossistemas naturais devido a sua capacidade de excluir espécies nativas, homogeneizar os ambientes, destruir e descaracterizar a biodiversidade local (PAZ-KAGAN et al., 2019; SALA et al., 2000).

A preocupação com os impactos causados pela invasão biológica não é recente, sendo discutido pela primeira vez em conjunto com a comunidade internacional, durante a Convenção da Diversidade Biológica (CDB), realizada em 1992, onde acordos foram sancionados em função da necessidade de controle e/ou contenção da disseminação e avanço da invasão biológica nos diferentes biomas do globo (CDB, 1992). Para o cumprimento destes acordos, faz-se necessários dados de observação em todos os níveis, sejam eles local, regional ou global, com o objetivo de auxiliar o sistema de áreas protegidas, compreender os processos, serviços e alterações ecossistêmicas (MUCHONEY, 2008).

Em ambientes alterados há uma maior facilitação no estabelecimento das EEI's, posto que, quanto menor a diversidade de espécies nativas, maior será a vantagem competitiva da invasora sobre o ecossistema local. Estas espécies apresentam atributos funcionais adaptados a tais fatores de degradação (MISSIO e LONGHI, 2019). Entretanto, devido aos aspectos invasivos, é possível que as EEI's consigam se estabelecer em áreas não antropizadas, tais como as áreas protegidas, em especial as Unidades de Conservação (UC's), como já relatado por diversos pesquisadores (GISP, 2007; MIELKE et al., 2015; INSTITUTO HÓRUS, 2021).

As UC's, no Brasil, regulamentadas pela Lei nº 9.985/2000, são consideradas primordiais e estratégicas para a preservação e manutenção da biodiversidade (BRASIL, 2019). Contudo, estas áreas permanecem suscetíveis às mudanças antrópicas, seja pela fragmentação de habitats ou presença de ambientes perturbados e áreas degradadas, gerando graves consequências à biota, como a introdução (acidental ou não) de EEI's (SPEAR et al., 2013). Sampaio e Schimidt (2013) descreveram o cenário das EEI's em UC's brasileiras, onde apontaram 106 diferentes espécies de plantas invasoras registradas.

Programas que visam o manejo das EEI's são de fundamental importância para a conservação das UC's, onde pode-se citar o Parque Estadual da Quarta Colônia (PEQC), localizado na região central do Estado do Rio Grande do Sul. O parque é um exemplo de UC que possui seu território comprometido e afetado por EEI's, estabelecidas pelos longos

processos de perturbação ligados ao histórico de uso e cobertura da terra (MALLMANN et al., 2015). Diante da preocupação que as EEI's trazem, é necessário sua identificação e acompanhamento, entretanto, tais tarefas em áreas protegidas são complexas, devido à grande dimensão territorial, dificuldade de acesso no interior da unidade e custos elevados para inventariar essas espécies em campo. Dessa maneira, o uso de tecnologias, como o Sensoriamento Remoto (SR), apresenta grande potencial para detectar, mapear e prever a propagação espacial das EEI's (LEHMANN et al., 2015).

O surgimento de diferentes sensores e instrumentos, resultaram no desenvolvimento de métodos e técnicas para obtenção de informações sobre a vegetação, a partir de dados de SR, onde imagens de satélite e sensores aerotransportados têm sido utilizados para diversas aplicações florestais, como por exemplo, inventário, gestão, ecologia, proteção, saúde, entre outros (LECHNER et al., 2020). Essas tecnologias abriram a possibilidade de desenvolver ferramentas para a identificação e detecção de espécies florestais invasoras, em diferentes tipologias florestais (PAZ-KAGAN et al., 2019).

A exemplo disso, Somodi et al. (2012), utilizaram imagens do satélite Landsat ETM, com 30m de resolução espacial para detectar a espécie invasora *Robinia pseudacacia*. Por sua vez, Müllerová et al. (2013), usaram imagens do satélite *RapidEye* (5m de resolução espacial), para identificar a espécie invasora *Heracleum mantegazzianum*. Carter et al. (2009) utilizaram dados *Quickbird* (resolução espacial 2,44 m) para detectar a EEI *Tamarix* spp, atingindo uma precisão de classificação de 91%.

Apesar de os dados obtidos por satélites fornecerem uma base importante para os esforços de controle das EEI's, o mapeamento preciso dessas espécies ainda é um desafio, principalmente devido à resolução espacial das imagens orbitais disponíveis gratuitamente não serem altas o suficiente para facilitar a detecção de indivíduos isolados, ou mesmo de pequenas populações. Em contraste, as imagens obtidas por Sistemas de Aeronaves Remotamente Pilotadas (*Remotely Piloted Aircraft Systems - RPAS*) introduzem uma nova técnica de SR, sendo uma alternativa aplicável e acessível em relação às abordagens convencionais, pois reduzem custos, assim como possuem melhor resolução espacial, espectral e temporal (LEHMANN et al., 2015). Conforme destacado por Müllerová et al. (2017), os RPAS são adequados principalmente para o monitoramento direcionado, como de áreas protegidas, que estão propensas à introdução de EEI's, ou as áreas recentemente manejadas, onde são utilizados para verificar a efetividade da erradicação das invasoras.

Paralelamente ao desenvolvimento do RPAS, o uso do Aprendizado de Máquina (AM) em SR se intensificou nos últimos anos, uma vez que as abordagens de AM apresentam

vantagens quando comparadas às estatísticas convencionais, principalmente em cenários complexos com grandes conjuntos de dados, de grande dimensão e variáveis não normalmente distribuídas (ZOU et al., 2019; SOTHE et al., 2019).

As abordagens que incluem RPAS e técnicas de AM, estão cada vez mais utilizadas pelos pesquisadores, tal que Eugenio et al. (2021 a), apresentam uma revisão da aplicação de RPAS e AM no contexto florestal, onde constaram os três maiores usos em métodos de *deep learning*, e algoritmos como *Random Forest* (RF) e *Support Vector Machine* (SVM). Dessa forma, as relações entre inteligência artificial, visão computacional e SR, geram um ambiente multidisciplinar muito promissor na extração de informações, onde fornecem resultados acurados no reconhecimento de diferentes espécies florestais (CALVARIO et al., 2017; DEUR et al., 2020; WESSEL et al., 2018). Nesse contexto, a combinação de imagens obtidas por RPAS e algoritmos de AM, podem fornecer métodos de alta precisão para a identificar espécies florestais exóticas invasoras.

Diante do exposto, é possível observar uma “lacuna” de estudos que correlacione imagens obtidas por RPAS para identificação de espécies invasoras em UC’s no Brasil. Uma vez que são técnicas fundamentais para serem aplicadas em mapeamento de EEI’s, na caracterização dos riscos e impactos associados, podendo identificar, avaliar e prever a distribuição espacial e temporal do risco de invasão em áreas protegidas, subsidiando tomadas de decisão e medidas de planejamento.

1.1 OBJETIVOS

1.1.1 Objetivo Geral

Avaliar a combinação do uso de imagens obtidas por sensores embarcados em RPAS e algoritmos de aprendizado de máquina para identificar espécies florestais exóticas invasoras no Parque Estadual Quarta Colônia, Rio Grande do Sul, Brasil.

1.1.2 Objetivos Específicos

- Localizar e identificar *in loco* as espécies florestais exóticas invasoras *Psidium guajava* e *Hovenia dulcis*.
- Coletar imagens com uso de RPAS a fim de subsidiar o estudo para identificação das espécies florestais exóticas invasoras;
- Avaliar o desempenho do uso de segmentação baseada em objeto mediante a utilização de dois algoritmos de aprendizado de máquina;
- Selecionar o algoritmo com melhor desempenho para identificação das espécies florestais exóticas invasoras, e;
- Validar o modelo obtido para identificar espécies florestais exóticas invasoras por meio de imagens obtidas via RPAS.

2 REVISÃO DE LITERATURA

2.1 ESPÉCIES EXÓTICAS INVASORAS (EEI's)

As regiões ocupadas pelas espécies estão limitadas por barreiras, tanto climáticas como geológicas, que não são domináveis pelos organismos de dada espécie, estabelecendo padrões de evolução diversos em cada área do mundo (PRIMACK e RODRIGUES, 2000). A espécie humana, no entanto, modificou este padrão transportando espécies pelo mundo, para que os colonizadores se sentissem em ambiente familiar. As espécies da flora foram introduzidas para fins de ornamentação, agricultura e pastagem, assim como o transporte acidental também auxiliou na introdução de EEI's em diversas localidades (PRIMACK e RODRIGUES 2000; ZENNI e ZILLER 2011).

As invasões biológicas são relatadas há séculos, e consideradas, conforme Pimentel et al. (2001), uma das "cinco grandes" questões ambientais de interesse público, em conjunto com o desflorestamento, mudanças climáticas, aumento das emissões de CO₂ e deposição de nitrogênio, integrando os principais fatores de mudanças na biodiversidade de ecossistemas terrestres.

São relatadas na literatura diferentes termos para denominar as espécies invasoras. Estes conceitos, na maioria das vezes, estão vinculados ao impacto dessas espécies sobre a biodiversidade, economia ou saúde. De acordo com a CDB (1992), "espécie exótica" é toda espécie que se encontra fora de sua área de distribuição natural e "espécie exótica invasora" é definida como aquela que ameaça ecossistemas, habitats e outras espécies nativas. Para IUCN (2000), "espécie invasora" é uma espécie exótica estabelecida em ecossistemas e habitats naturais e/ou seminaturais, que ameaça e provoca mudanças a diversidade biológica nativa. Rafferty (2019), define as "espécies invasoras" como espécies introduzidas ou exóticas, a qual seriam qualquer espécie não nativa que modifica ou perturba os ecossistemas que coloniza. Por sua vez, Richardson et al. (2000), relatam que o termo "invasor" deve ser usado em referência ao status biogeográfico/demográfico de uma espécie, sem nenhuma conotação ao impacto produzido. Na Tabela 1 é possível observar de modo descritivo as principais terminologias recomendadas por Richardson et al. (2000).

Tabela 1 - Termos recomendados em ecologia de invasão de plantas.

Termos	Sinônimos	Conceitos
Planta Exótica	Plantas alienígenas; plantas não-nativas; plantas não-indígenas.	São táxons cuja presença em uma determinada área ocorre por introdução intencional ou acidental como resultado direto da ação do homem.
Plantas exóticas casuais	-	São plantas que podem florescer e até reproduzir ocasionalmente em uma área, mas não formam populações viáveis.
Plantas naturalizadas	Plantas alienígenas casuais	São espécies exóticas que se reproduzem e sustentam populações ao longo de muitos ciclos de vida sem intervenção humana direta. Contudo, não invadem ecossistemas naturais, seminaturais ou antropogênicos.
Plantas invasoras	-	São plantas naturalizadas que produzem descendentes reprodutivos, geralmente em números muito grandes, a uma distância considerável das plantas progenitoras, possuindo o potencial de se espalhar por uma área considerável.
Plantas daninhas	Ervas daninhas	São plantas que crescem em locais onde não são desejadas e possuem características econômicas ou ambientais negativas.
“Transformers”	-	Subconjunto de plantas invasoras que alteram as condições, formas ou natureza dos ecossistemas em uma área substancial em relação à sua abrangência.
Espécies florestais exóticas invasoras*		Espécies florestais que afetam os processos dos ecossistemas, como a ciclagem de nutrientes, produtividade vegetal, dispersão de sementes e a sucessão ecológica, interferindo na densidade das espécies nativas.

Fonte: Adaptado de Richardson et al. (2000). *Definição elaborada pela presente autora.

Richardson et al. (2000) definiram, também, um conjunto de termos-chave relacionados a um esquema que conceitualiza o processo de naturalização / invasão. Para os autores, quando uma espécie é introduzida, significa que a planta (ou seu propágulo) foi transportado por seres humanos através de uma barreira geográfica relativamente grande. A maioria das espécies exóticas que são introduzidas permanecem apenas como casuais, não chegando a estabelecer populações duradouras, entretanto, algumas espécies apresentam indivíduos que sobrevivem após a introdução e que superam os obstáculos de reprodução, sustentando diversas gerações sem a necessidade de intervenção humana. Quando isto ocorre, inicia-se o processo de Naturalização, que é quando as barreiras abióticas e bióticas à sobrevivência são superadas. Somente uma parte das plantas naturalizadas serão invasoras. A invasão exige que as plantas introduzidas reproduzam fora da primavera em áreas distantes dos locais de introdução. Nessa

etapa, somente aquelas que se disseminarem em abundância e densidade, e causarem impactos negativos à biota local (substituição de espécies ou alteração da estrutura do ecossistema), terão sucesso na invasão. A sequência de eventos que descrevem a invasão, pode ser melhor explicado pela figura 1.

Figura 1 - Sequência de eventos que descrevem a invasão biológica, da introdução à invasão. As principais barreiras que limitam a propagação de plantas exóticas introduzidas (geográfica, ambiental, reprodutiva, dispersão, habitats naturais e perturbados).



Fonte: Adaptado de Richardson et al. (2000); Mallmann (2021).

Todavia, as EEI's são responsáveis por influenciar os padrões de diversidade florística nas mais diversas regiões do globo, dentre elas destacam-se as originárias dos continentes Asiático e Europeu, que se tornaram promotores da internacionalização das florestas, em especial no continente Americano (STOHLGREN et al., 2011). McGeoch et al. (2010), ao avaliarem os indicadores de invasão biológica em escala global, constataram que há uma

tendência de diminuição da diversidade de espécies nativas provocadas pelo aumento da introdução de EEI's. Outro ponto destacado pelos autores é o impacto geral da invasão biológica, que mesmo em países signatários da CDB, aumentou nas últimas décadas. O que corrobora com o estudo de Bellard et al. (2018), que realizam uma modelagem para avaliar como as mudanças climáticas afetam a geografia das EEI's, os autores demonstraram em seus resultados que este fator impulsionará cada vez mais a distribuição de EEI's pelo mundo.

Apesar da criação de políticas voltadas ao controle da invasão biológica, tal ação não foi suficiente ou, não foi implementada da maneira correta, para alcançar uma redução no impacto sobre a biodiversidade em diferentes biomas do globo. Portanto, após a ocupação pelas EEI's, os prejuízos econômicos para realizar o manejo e erradicar essas espécies são elevados. Neste contexto, até 2010 a União Europeia (UE) investiu 3,4 milhões de euros em projetos envolvendo 2.122 EEI's em 27 países membros da UE e o custo anual estimado associado ao impacto e controle de espécies invasoras foi superior a 12 bilhões euros ano na Europa (MCNEELY et al., 2005; COMISSÃO EUROPEIA, 2008). Mais de 120 mil espécies exóticas de plantas, animais e microrganismos já foram registrados em países como África do Sul, Austrália, Brasil, Estados Unidos, Índia e Reino Unido. Apenas nesses seis países estudados, as estimativas com relação a perdas econômicas anuais decorrentes da introdução de pragas nas culturas, pastagens e nas áreas de florestas atingem cifras de aproximadamente 250 bilhões de dólares. Cálculos das perdas ambientais anuais relativas à introdução de pragas nesses mesmos países indicam que o montante ultrapassava os 100 bilhões de dólares (PIMENTEL et al., 2001).

O estudo realizado por Rico-Sánchez et al. (2021), demonstrou que, embora sejam cruciais para o desenvolvimento de uma gestão eficiente, na maioria dos países, os dados disponíveis sobre os custos monetários de EEI são escassos. Os autores investigaram os custos econômicos das EEI's no México, onde relataram que o país investiu, durante o período de 1992 a 2019, cerca de 5,33 bilhões de dólares. A pesquisa realizada por Adelino et al. (2021), investigou os custos econômicos da invasão biológica no Brasil, demonstrado pelos autores que o país investiu, ao longo de 35 anos (1984-2019), 105,53 bilhões de dólares. Desse total, cerca de 98% foram devidos a danos e perdas causados por EEI's enquanto os 2% restantes foram investidos na gestão (prevenção, controle ou erradicação). Os autores concluem que o Brasil tem optado principalmente por pagar pelos danos incorridos pelas EEI's, em vez de investir na prevenção de sua ocorrência, e indicam que estas espécies são uma causa importante de perdas econômicas no país.

Conforme relatado por Medvecká et al. (2018), de maneira geral, os ecossistemas florestais nativos são menos propensos a invasão do que os ambientes antropogênizados, no

entanto, há ocorrência do aumento de EEIs nos habitats florestais, causando impactos negativos na composição química do solo, alteração do microclima da floresta e na composição das espécies nativas. Richardson e Rejmánek (2011), realizaram um levantamento global sobre a dispersão de espécies florestais exóticas invasoras (EFEI's) onde apresentaram uma lista contendo 622 espécies (357 árvores e 265 arbustos, distribuídos em 78 famílias). As regiões com o maior número de EFEI's relatadas pelos autores são: Austrália, África do Sul, América do Norte, Ilhas do Pacífico e Nova Zelândia, e os motivos mais importantes para introdução e disseminação destas espécies foram a horticultura (62% das espécies), práticas silviculturais (13%), produção de alimentos (10%) e sistemas agroflorestais (7%). Conforme estes autores, cerca de 40% das EFEI's e 60% das arbustivas são dispersadas por aves. O principal problema da dispersão das EFEI's, são as alterações causadas no ecossistema em questão, podendo citar modificações na taxa de decomposição de serapilheiras e matéria orgânica, disponibilidade de luz, composição de espécies do sub-bosque, ciclagem de nutrientes e até inibir o crescimento de outras plantas por alelopatia (BONIFACIO et al., 2015; FUREY et al., 2014; WOZIWODA et al., 2014).

As espécies invasoras também representam um enorme desafio a gestão das áreas protegidas, as quais sofrem grande pressão de propágulos de EEI's junto aos seus limites, influenciado diretamente por características da paisagem do seu entorno (SPEAR et al., 2011). Apesar das previsões legais, sabe-se que há registros de EEI's em UC's em todo o mundo (SAMPAIO e SCHMIDT, 2013; ICMBIO 2014; INSTITUTO HÓRUS, 2020). No ano de 2007, o Programa Global de Espécies Invasoras (*Global Invasive Species Programme - GISP*), produziu um relatório com o objetivo de retratar o panorama do conhecimento sobre o impacto da invasão biológica em UCs em todas as regiões do globo. Na América do Norte, Europa e Austrália, já existiam dados que permitiram traçar a amplitude do impacto das EEI's e, em algumas situações, as rotas de introdução são conhecidas, com o acompanhamento de todo o processo de dispersão e invasão. No entanto, para as demais regiões do mundo, os dados são bastante esparsos e insuficientes para delimitar adequadamente o impacto das espécies invasoras.

Para Sampaio e Schmidt (2013), o primeiro passo para compreender a dimensão do problema causado pelas EEI's, é identificar quais espécies estão invadindo e causando impacto, e quais as regiões ocupadas por estas. Em vários países, as EEI's são tratadas como prioridades para manejo em UC's devido à ameaça que representam à função definida para essas áreas.

No Brasil, entretanto, a falta de manejo de EEI's em áreas protegidas é, de fato, a maior preocupação em relação ao avanço das invasões biológicas. O Decreto Federal nº 4339 de 2002,

que trata da Política Nacional de Biodiversidade, que aponta a necessidade de inventário e mapeamento de EEI's para orientar estudos de avaliação dos impactos ambientais gerados e ações de controle (BRASIL, 2002). O esforço de listar essas espécies iniciou-se com o Informe Nacional sobre Espécies Exóticas Invasoras, em 2006, quando foi publicada a primeira lista nacional de EEI's para o país (MMA, 2006). Demais listas oficiais foram produzidas nas diferentes esferas do governo, como a Resolução CONABIO nº 05, de 21 de outubro de 2009, que institui a Estratégia Nacional sobre Espécies Exóticas Invasoras. O Instituto Hórus de Desenvolvimento e Conservação Ambiental traz uma lista onde estão compiladas, até o momento, 481 EEI's registradas em território nacional, sendo que deste total, 209 são plantas (INSTITUTO HÓRUS, 2021).

Contudo, as alterações antrópicas na natureza, em áreas protegidas ou alteradas, como a remoção de vegetação nativa, queimadas, criação de pastos, beneficiam o estabelecimento das EEI's. Soma-se a isso, a facilidade de deslocamento do homem moderno, que pode transpor barreiras geográficas e conduzir, acidental ou intencionalmente, de um local a outro, espécies que se originaram e evoluíram em outras regiões. Por tais razões, são estritamente necessários os acordos e dispositivos legais, nacionais e internacionais, que preveem o controle e a proibição de introdução e soltura deliberada de espécies exóticas invasoras (CARVALHO et al., 2019).

2.1.1 Espécies Exóticas Invasoras no Rio Grande do Sul

O estado do Rio Grande do Sul (RS), assim como a maior parte dos estados brasileiros, é afetado pela invasão biológica e os decorrentes problemas sociais, políticos, econômicos, e ecossistêmicos causados por estes organismos. Com o objetivo de criar um plano de controle e prevenção, o governo do Estado do RS publicou a Portaria nº 79 de 2013, a qual estabelece normas de controle e lista 44 EEIs, distribuídas em mais de 20 famílias, que ocupam diferentes áreas de formações florestais no Estado (SEMA-RS, 2013).

O RS é considerado pioneiro no trato de questões ambientais desde os anos 50, onde existem, atualmente 108 UC's, sendo 10 de competência federal, 24 estaduais, 35 municipais e 39 são Reservas Particulares do Patrimônio Natural (RIO GRANDE DO SUL, 2021). Das 24 UC's estaduais, somente 12 possuem plano de manejo e conseqüente levantamentos de espécies, onde em todas estas UC's, foram constatadas a existência de EEI's, citando como exemplo de algumas espécies listadas: *Pinus* spp, *Acacia podalyriifolia*, *Handroanthus chrysotrichus*, *Eriobotrya japônica*, *Ligustrum* spp, *Psidium guaiava*, *Hovenia dulcis*, entre outras (SEMA – RS, 2018). Esta situação é preocupante e obriga os gestores a planejar formas

de obtenção de informações a respeito do comportamento das diferentes EEIs, bem como estratégias de controle e erradicação das mesmas.

Levantamentos florísticos realizados no Rio Grande do Sul, encontraram a presença de EEI's nas diferentes fitosionomias do Estado. Cordero et al. (2016), estudaram a fitossociologia do arbusto *Ulex europaeus* em um mosaico de pastagens e descobriram que este arbusto cobre 10,1% da área total estudada. Em uma pesquisa bibliográfica de plantas herbáceas e arbustos invasores, Rolim et al. (2015) descobriram que a maioria das espécies tem origem geográfica na Europa Central e se reproduz predominantemente por pequenas sementes ou frutos. Os autores também observaram a falta de dados sobre ecossistemas naturais em várias regiões do Estado.

Venzke et al. (2018), realizaram inventário florístico para identificar espécies invasoras em diferentes comunidades de Pelotas, RS. O método utilizado pelos autores encontrou riqueza de 26 espécies em 22 gêneros e 17 famílias, distribuídos entre árvores e arbustos. Também identificaram que a maioria das invasoras já está naturalizada na área de estudo.

Dos Santos et al. (2017), realizaram análise quali-quantitativa das EEI's presentes na arborização urbana das vias públicas do centro da cidade de Sananduva-RS. Os autores constaram um total de 517 espécies vegetais, entre nativas e exóticas invasoras. Desse total, cerca de 25% dos espécimes encontrados foram classificados como invasores, com maior ocorrência de *Cupresses lusitanica* (9,28%), *Ligustrum lucidum* (6,19%) e o *Cinnamomum burmannii* (4,83%). Os autores também observaram que a quantidade de EEI's nas ruas avaliadas, apresentaram maior frequência que as espécies nativas.

Missio e Longhi (2019), quantificaram a riqueza e densidade de espécies exóticas e seu potencial de invasão biológica e a correlação com o ambiente, em um fragmento de floresta estacional decidual, região central do RS. Os autores observaram 105 indivíduos exóticos invasores, como *Citrus x limon* (L.) Osbeck, *Eriobotrya japônica* (Thunb.) Lindl., *Hovenia dulcis* Thunb., *Tecoma stans* (L.) Juss. ex Kunth, *Melia azedarach* L., *Morus nigra* L., *Psidium guajava* L. A espécie *Hovenia dulcis* foi a de maior abundância com 85 indivíduos. As EEI's apresentaram maior frequência na parte inicial do trecho florestal, indicando que a área sofre os efeitos da fragmentação.

A grande maioria das EEI's identificadas estão relacionadas ao hábito de cultivo humano, corroborando a ideia de que são as ações antrópicas as principais vias de introdução e dispersão, e por consequência, causas das alterações nas paisagens e patrimônio (CARVALHO et al., 2019). As espécies invasoras já são parte da paisagem de ambientes naturais no Brasil. Zenni e Dechoum (2015), destacam que a *Hovenia dulcis*, espécie florestal nativa do leste

asiático, é facilmente observada no sul do Brasil, onde encontrou condições ambientais adequadas para o seu estabelecimento e dispersão em áreas alteradas e áreas naturais.

Dentre todas as EEIs descritas como causadoras de problemas ambientais no Estado do RS, pode-se destacar as espécies *Hovenia dulcis* (uva do japão) e *Psidium guajava* (goiabeira), consideradas, respectivamente, conforme a Portaria nº 79/2013, como pertencentes a categoria 1 - espécie proibida para cultivo e propagação e categoria 2 - espécies que podem ser cultivadas em condições controladas (RIO GRANDE DO SUL, 2013). Essas ações visam o controle e erradicação da invasão biológica, baseadas em legislações para proteger as áreas de florestas nativas, como a Lei de Crimes Ambientais (9.605/1998) e o Sistema Nacional de Unidades de Conservação SNUC (Lei nº 9.985/2000).

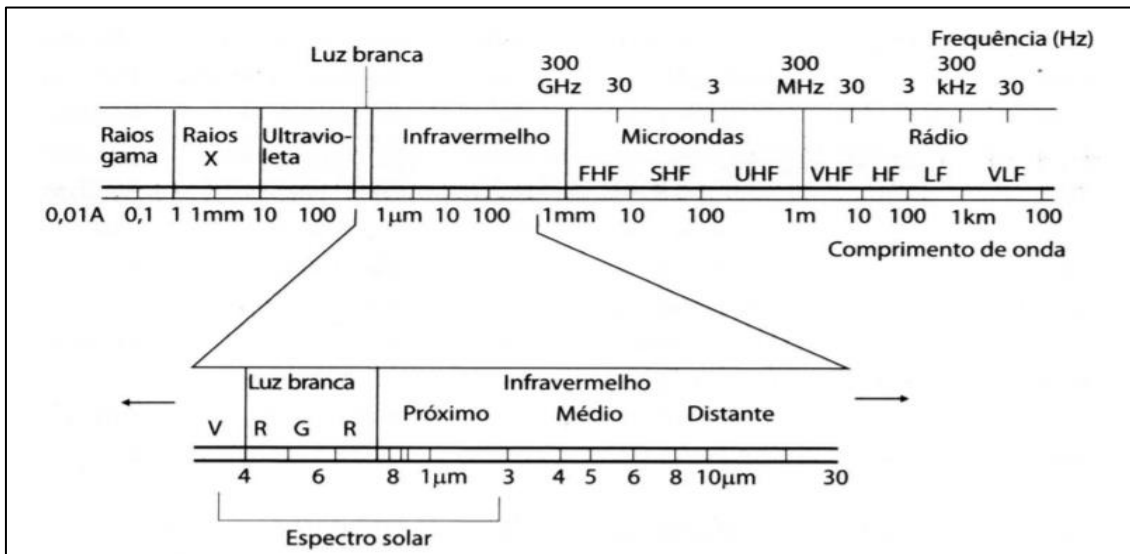
Dessa forma, muitas recomendações técnicas ainda se limitam a ações de diagnóstico e monitoramento, quando uma abordagem prática e proativa deveria ser adotada, especialmente prevenindo à introdução de espécies, de maneira voluntária ou acidental, assim como na detecção e eliminação precoce de populações em processo de estabelecimento e invasão (ZILLER e DECHOUM, 2013).

2.2 SENSORIAMENTO REMOTO DA VEGETAÇÃO: CONCEITOS E APLICAÇÕES

O sensoriamento remoto pode ser definido, conforme Florenzano (2007), como a tecnologia que permite obter imagens e outros tipos de informações da superfície terrestre, através da captação e do registro da radiação eletromagnética (REM), refletida ou emitida pela superfície, sem estar em contato direto com o objeto sob investigação. Estes objetos estão espalhados em diferentes categorias, como vegetação, água, solo, rochas, entre outros, em uma área geográfica limitada a terra. A detecção das interações entre a REM e os alvos da superfície terrestre, pode ser considerado como princípio básico de toda tecnologia do SR. Essa interação é alcançada através de sensores espectrais, que são equipamentos capazes de medir o espectro eletromagnético refletido (PONZONI e SHIMABUKURO, 2010). O espectro eletromagnético está dividido conforme a distribuição da radiação em diferentes regiões, organizado de acordo com o comprimento e frequência de onda (ABREU e COUTINHO, 2014).

A Figura 2 ilustra a representação do espectro eletromagnético e seus comprimentos de onda.

Figura 2 - Espectro eletromagnético.



Fonte: Adaptado de Gerhke (2016).

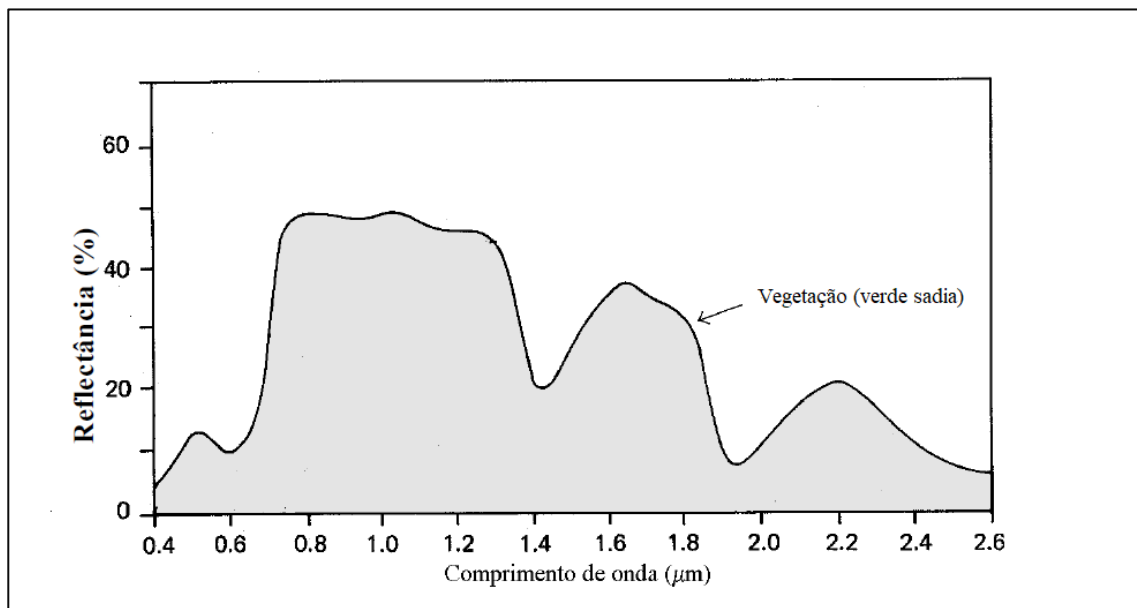
A obtenção de dados por SR requer o uso de energia, que pode ser proveniente de uma fonte natural ou artificial. Esses sensores permitem qualificar e quantificar o fluxo de energia radiante dos elementos naturais observados, proporcionando assim meios para a caracterização das suas funções e propriedades (FLORENZANO, 2007). Os processos de emissão, absorção, reflexão e transmissão, ocorrem simultaneamente, e as intensidades são relativas nos diferentes comprimentos de onda do espectro eletromagnético, caracterizando, assim, o objeto em questão. Esses processos podem ser alterados na ocorrência de fenômenos meteorológicos ou incidência de pragas e enfermidades, permitindo identificar e avaliar a gravidade das modificações causadas por fatores bióticos ou abióticos, e identificar as alterações fisiológicas nas plantas (PEDRALI, 2017).

No estudo da vegetação, as técnicas de SR são baseadas na radiação refletida por folhas isoladas, controladas pelo processo de fotossíntese, que é fundamentada, de forma resumida, na absorção da REM por parte dos pigmentos fotossintetizantes ou cloroplastos (clorofila, xantofilas e carotenos), que são estruturas presentes nas células do mesófilo contendo os pigmentos (PONZONI E SHIMABUKURO, 2010). O conteúdo interno dos pigmentos e de água afetam as propriedades de reflectância e transmitância das folhas. A estrutura interior e exterior da vegetação e suas interações com a REM, interferem diretamente na resposta espectral registrada por instrumentos de SR (GUREVITCH et al., 2009).

Este comportamento espectral da vegetação representa as propriedades de reflectância, absorção e transmitância da REM, ao nível foliar e de dossel. Muitos estudos abordam sobre a interação dos componentes bioquímicos (água, clorofila e outros pigmentos fotossintetizantes),

da vegetação, com o comportamento da Radiação fotossinteticamente ativa. A faixa espectral que alcança os comprimentos de onda entre 430 nm a 660 nm, é caracterizada por um forte pico de absorção 400 de clorofila *a*. Já a faixa de absorção de clorofila *b* fica entre 450 nm a 650 nm. Na região do infravermelho-próximo (NIR), a refletância aumenta drasticamente (entre 700 nm a 1.200 nm), com um pico de reflectância em torno de 900 nm para uma folha verde sadia (JENSEN, 2009; JENSEN 2015). A Figura 3 ilustra o espectro de reflectância da vegetação.

Figura 3 - Curva da reflectância espectral da vegetação.



Fonte: Souza Filho (2008).

As diferenças de reflectância existentes, podem ser obtidas e utilizadas de forma eficiente para mapear e quantificar, por exemplo, biomassa, falhas presentes no meio de plantios, problemas fitossanitários, identificação de plantas, dentre outros. Outra importante aplicação das técnicas de SR, está no estabelecimento e gerenciamento de áreas protegidas, onde é usado para planejar, monitorar e avaliar ações estratégicas para conservação. Para isso, devem ser considerados os aspectos quanto a resolução espacial e temporal dos sensores, para que os dados remotos adquiridos sejam compatíveis com as escalas necessárias para avaliar a biodiversidade (WIENS et al., 2009).

O estudo realizado por Bilar et al. (2018), identificou as condições de cobertura vegetal de uma UC no estado de Pernambuco, com a aplicação de índices biofísicos (NDVI, IAF SAVI, EVI e NDWI), gerados a partir da análise de imagens obtidas por sensores orbitais, onde constataram que a cobertura vegetal da UC se encontrava relativamente preservada, com detecção de áreas expostas e sob estresse hídrico, informações indispensáveis para a gestão desses espaços.

Penoni et al. (2017), utilizaram dados de SR para avaliar o grau de antropização em UC localizada no Cerrado brasileiro, a partir de modelos digitais de elevação. Os autores observaram que as regiões mais elevadas das UC sofrem menos com as ações antrópicas, enquanto as de menores altitudes tem maior grau de antropização, dessa forma pôde-se obter uma análise e atualização das informações das áreas de interesse da unidade, facilitando o processo de monitoramento e gestão.

Por sua vez, Mallmann et al. (2015), utilizaram NDVI e imagens de satélite do Sistema *RapidEye*, para caracterizar e quantificar os remanescentes florestais no Parque Estadual Quarta Colônia (PEQC), com o intuito de contribuir para a compreensão dos processos de sucessão e dinâmica da vegetação, assim como identificação de áreas degradadas. Os autores observaram que o mapeamento a partir do NDVI, demonstrou a presença de um mosaico sucessional, onde as porções mais conservadas das floretas encontram-se em áreas de declividade acentuada, destacando-se o número significativo de áreas degradadas.

Diante do exposto, nota-se que a utilização de dados adquiridos via SR apresenta diversas fontes para observação e obtenção de dados da vegetação, essas técnicas são ferramentas extremamente valiosas para o planejamento e monitoramento dos processos ecológicos, contribuindo diretamente para a gestão de unidades de conservação.

2.2.1 Sensoriamento Remoto de Alta Resolução

As aplicações atuais do SR abrangem monitoramento dinâmico de usos do solo, evoluções de biodiversidade, recursos naturais, clima, inventário e monitoramento das coberturas vegetais, acompanhamento da produção primária das florestas e pastagens, monitoramento de áreas propensas a invasão biológica, estudo das mudanças climáticas, entre outros (LIU, 2015). Essas informações são obtidas através de sensores, geralmente acoplados a plataformas orbitais, como os satélites, e também em plataformas aéreas.

Em termos de aplicabilidade, diferentes sensores podem ser utilizados para obter informações sobre a vegetação, entretanto, o uso de um determinado sensor irá depender de suas principais características, tais como as resoluções espectral, temporal, radiométrica e espacial, uma vez que são estas que fornecem os detalhes necessários a obtenção dos dados (JENSEN, 2009).

De acordo com Silva (2014), a resolução espectral corresponde à capacidade de um sensor, em capturar informação em distintas regiões do espectro eletromagnético. Quanto maior for a quantidade de bandas e menor for o intervalo dos comprimentos de onda, melhor será a resolução espectral do sensor. Ela é importante pois, quanto maior for o número de bandas

cobertas pelo sensor, maior será a capacidade dele em diferenciar alvos específicos. Os sensores de alta resolução espectral podem ser divididos em: RGB que capturam informações das bandas espectrais da luz visível (vermelho, verde e azul (*Red, Green, Blue*)), multiespectrais que além de possuir as bandas RGB, também contém bandas da região do infravermelho (faixa estreita) e os sensores hiperespectrais, que possuem centenas de bandas atuando em diversas regiões do espectro (MENESES E ALMEIDA, 2012). Conforme Helmer et al. (2015), sensores multiespectrais são mais comuns em aplicações florestais, devido à capacidade de observação de padrões na faixa do infravermelho, e podem fornecer informações sobre a saúde da vegetação, estimativas de área plantada, contagem e outros.

Quanto a resolução temporal, é definida em função do tempo de revisita de um determinado sensor, para o mesmo ponto da superfície terrestre. O satélite LandSat 7, por exemplo, possui um tempo de revisita de 16 dias, enquanto o sistema CBERS leva 26 dias para recobrir a mesma área (JENSEN, 2009). É importante para o monitoramento de áreas, crescimento e produtividade de diferentes culturas, entre outros (FORMAGGIO e SANCHES, 2017). A resolução radiométrica, para CRISP (2015), é a variável que se refere a menor variação de intensidade possível de ser detectada pelo sensor.

Quanto a resolução espacial, esta apresenta um papel relevante para aplicações no estudo da vegetação, pois é ela que delimita a dimensão dos objetos (e conseqüentemente as feições) que podem ser identificadas, portanto, a caracterização de aplicações de modo geral se baseia nessa característica. White et al. (2016) definem uma classificação da resolução espacial como sendo: muito baixa > 1.000 m; baixa 100 m –1.000 m; média 10 m–100 m; alta 1 m–10 m; e altíssima < 1m.

Helmer et al. (2015) relatam que os sensores de baixa ou muito baixa resolução, geralmente são aplicadas para fins meteorológicos ou para classificação de florestas em escalas globais, uma vez que essas imagens possuem uma alta taxa de recobrimento. Para Panda et al. (2015), os sensores de média resolução são comumente aplicados em mapeamentos de tipologia florestais, e em sua maioria apresentam bandas além do visível. Enquanto que, para análises a nível florestal mais específico, como a detecção de árvores individuais, monitoramento de pragas e doenças, identificação de EEI's, recomenda-se o uso de imagens de alta ou altíssima resolução espacial, cujo sensor também atue em pequenas faixas do espectro (HELMER et al., 2015).

Dessa forma, com o avanço da tecnologia, métodos alternativos para obtenção de informações a respeito de parâmetros florestais, com imagens de alta resolução, vem sendo cada vez mais desenvolvidos. Um exemplo é o uso de RPAS, também chamados popularmente de

DRONES, que estão sendo aplicados de forma substitutiva ou complementar as imagens obtidas por satélites, para suprir diferentes finalidades.

Nos últimos anos, a utilização dos RPAS para coletas de dados em florestas tem se tornado cada vez mais recorrentes, onde os RPAS são manuseados para o embarque de sensores que operam coletando dados sobre a vegetação. Diversos autores, tais como, Torres-Sánchez et al. (2013); Colomina e Molina, (2014); Aasen et al. (2015); Saarinen et al. (2017), citam como benefício dos RPAS, o baixo custo operacional, versatilidade dos sensores embarcados, alta resolução espacial, resolução temporal de acordo com o objetivo das tarefas de aplicação, e sua resolução espectral de acordo com a finalidade e com os sensores embarcados. Para Guimãres et al. (2020), a principal vantagem dos RPAS em relação aos sistemas de SR tradicionais, é a sua flexibilidade de uso em escala regional e local, assim como a alta resolução e precisão dos dados obtidos.

Conforme Huang et al. (2013), geralmente os RPAS possuem um sistema de controle por rádio frequência para o controle automático do voo, que também permite a realização do planejamento de voo e ainda, memória interna para armazenamento de dados, como: altura de voo, distância e coordenadas geográficas do percurso executado pela aeronave. Além da diferença entre componentes, os RPAS possuem tamanho e formas diferentes, não existindo um modelo único adequado para todos os usos. O modelo e tamanho são definidos de acordo com a finalidade proposta (COLOMINA e MOLINA, 2014).

Pádua et al. (2017), relata que as plataformas utilizadas em áreas florestais, geralmente são pequenas, com autonomia que varia de alguns minutos até algumas horas e podem ser subdivididas em asa fixa ou asa rotativa. Cada tipo tem suas vantagens, e a escolha do RPA baseia-se no tamanho e complexidade da área mapeada, no tipo de sensor a ser embarcado e a resolução desejada no levantamento, condições necessárias para decolagem e pouso da plataforma, além da experiência do operador para o planejamento e gerenciamento do voo.

As informações obtidas acerca da vegetação, estão relacionadas ao tipo de sensor que foi embarcado no RPAS. A câmera fotográfica, capaz de captar as bandas do visível, é um exemplo clássico de sensor imageador utilizado em um RPAS (BARETH et al., 2015). Aasen et al. (2015); Honkavaara et al. (2013), também destacam os sensores multi e hiperespectrais, sensíveis à REM em diferentes regiões do espectro eletromagnético, sensores termais, sensíveis à REM na região do infravermelho termal (ZARCO-TEJADA et al., 2012), e os LiDAR, sensores que emitem um pulso laser em alta frequência para obtenção da distância entre o sensor e o alvo (LIN et al., 2011; TULLDAHL et al., 2015).

Na obtenção de dados de inventários florestais, autores como Cunliffe et al. (2016);

Mohan et al. (2017); Guo et al. (2017); Yin e Wang (2019), utilizaram plataformas RPAS para obter informações precisas de parâmetros básicos, como altura, diâmetro, volume e biomassa do solo, como estrutura e na determinação da composição, extensão e crescimento das espécies, para vários tipos de florestas e culturas.

No contexto da restauração de ecossistemas naturais, Almeida et al. (2019), exploraram o potencial de um sistema LiDAR acoplado a uma plataforma RPAS para avaliar os resultados de um experimento de restauração florestal com o plantio de diferentes espécies, projetadas para maximizar o acúmulo de biomassa acima do solo na Mata Atlântica no Brasil. O plantio foi projetado com 20 espécies de árvores nativas, combinando dois níveis de densidade e dois níveis de manejo para um total de quatro combinações de tratamento mais um controle. As diferenças estruturais entre os tratamentos e as parcelas de controle foram distinguidas de forma confiável pelo sistema de controle RPAS, indicando que o sistema adotado demonstra potencial para monitorar a restauração florestal em larga escala.

2.2.1.1 Uso de RPAS para identificação de espécies florestais

Nesta seção, estão exemplificadas algumas aplicações do uso de RPAS na ciência florestal, voltado principalmente a detecção e identificação de árvores. Eugenio et al. (2020), realizaram uma análise sistemática sobre a utilização do RPAS na silvicultura, onde os autores agruparam as aplicações em seis categorias principais, e suas respectivas porcentagens: Estimativa de inventário e parâmetros florestais (61,3%); conservação de ecossistemas naturais (19,8%), monitoramento de incêndio (6,1%), mapeamento de pragas e doenças (5,8%), avaliação pós-colheita (1,2%) e outras (5,8%). Também foi observado que a grande maioria dos sensores usados são RGB, seguido dos multiespectrais, em todas as áreas agrupadas.

Dessa forma, nos estudos de Eugenio et al. (2020), Eugenio et al. (2021 a) e Eugenio et al. (2021 b), nota-se que há uma tendência crescente da aplicabilidade de RPAS no cenário florestal nos últimos anos. Para sintetizar as inovações e tendências que descrevem o uso de plataformas RPAS para fins florestais, algumas das principais contribuições de publicações recentes são apresentadas na Tabela 2, relacionadas a identificação de EEI's em ambientes florestais.

Tabela 2 - Exemplos de uso de RPAS na identificação de espécies florestais exóticas invasoras.

Autor	País	Espécie	Sensor	Algoritmos	Principais Resultados
de Sá et al. (2018)	Portugal	<i>Acacia longifolia</i>	RGB	<i>Random Forest</i> (RF)	Precisão geral > 0,96; e Kappa > 0,85 para identificação da espécie invasora no período de floração
Dash et al. (2019)	Nova Zelândia	<i>Pinus sylvestris</i> e <i>P. ponderosa</i>	Multiespectral e LiDAR	RF e Regressão Logística (RL)	Alta precisão (kappa < 0,996) para detecção das coníferas invasoras.
Kattenborn et al. (2019)	Chile	<i>Pinus radiata</i> , <i>Ulex europaeus</i> e <i>Acacia dealbata</i>	RGB e hiperespectral	<i>RF</i>	A correlação foi de 0,70, 0,77 e 0,90 para identificação das invasoras três espécies.
James e Bradshaw (2020)	Austrália	<i>Hakea genus</i>	RGB	<i>Convolutional Neural Network</i> (CNN)	A acurácia global foi 96% de precisão em detectar a espécie invasora.
Müllerová et al. (2017)	República Tcheca	<i>Robinia pseudoaccacia</i>	RGB e multiespectral	<i>Supervised Maximum Likelihood</i> (ML) e SVM	Precisão geral de 73% e 81%, e Kappa de 0,66 para os algoritmos ML e SVM, respectivamente, na detecção da espécie invasora
Sabat-Tomala et al. (2020)	Polônia	<i>Solidago spp.</i> , <i>Calamagrostis epigejos</i> e <i>Rubus spp.</i>	Hiperespectral	RF e SVM	Os resultados da classificação oscilaram em torno de 0,90 para todas as espécies estudadas, com os dois algoritmos.
Lima et al. (2021)	Brasil	<i>Hovenia dulcis</i>	RGB	<i>Nearest Neighbor</i> (NN)	Acurácia global e Kappa apresentaram valores de 0,97 e 0,95 para identificação da espécie.

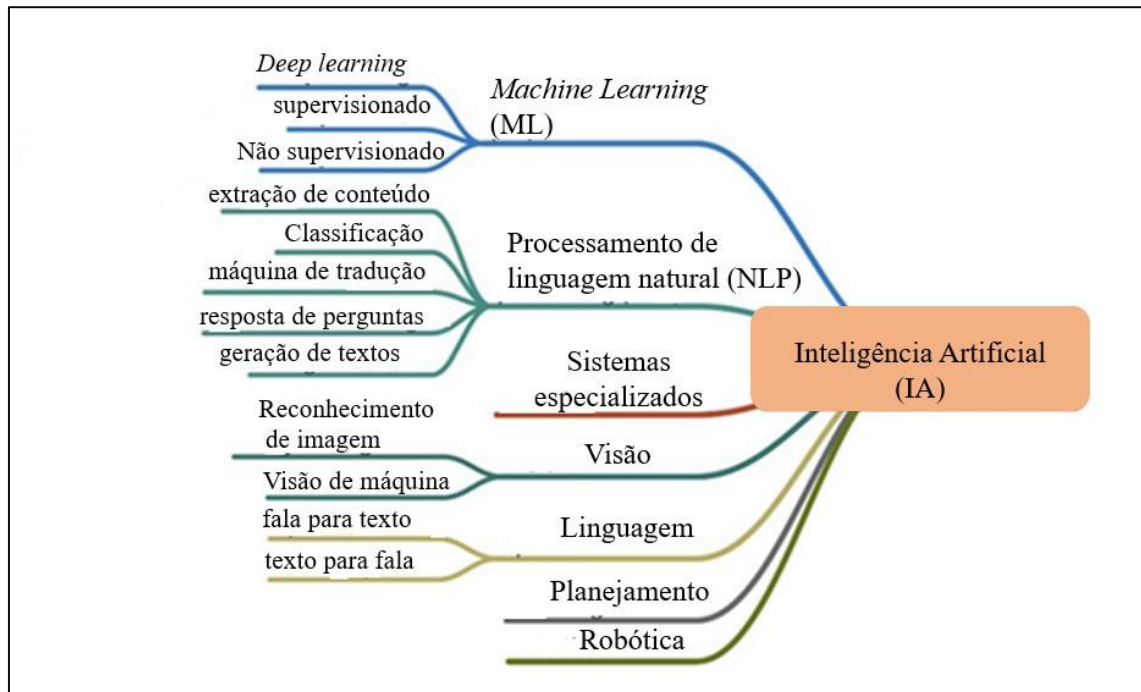
2.3 INTELIGÊNCIA ARTIFICIAL

A inteligência artificial (IA) permeia praticamente todos os setores da economia, da ciência, e da sociedade (KAUFMAN, 2019). A IA, e suas áreas abrangentes como o *Machine Learning* (ML) e *Deep Learning* (DL), retratam a capacidade de uma máquina em continuar melhorando o seu próprio desempenho, sem que os seres humanos precisem explicar exatamente como realizar todas as tarefas atribuídas a ela (BISHOP, 2007; MICHIE et al., 1994).

A definição do termo “Inteligência Artificial”, ainda é motivo de discussão entre pesquisadores. Rich e Knigth (1994) definem IA como o estudo que leva os computadores a realizarem tarefas que, até o momento, os humanos fazem melhor. Para Schalkof (1992), IA é um campo de estudo que busca explicar e emular comportamentos inteligentes em termos de processos computacionais. Lauriere (1990), diz que para todo problema que não haja nenhuma solução algorítmica, torna-se um problema de IA. Ou seja, todas as tarefas relativas a processamento de símbolos, reconhecimento de imagens e outras atividades que envolvam “aprendizado” (ROSA, 2011).

De maneira geral, a IA é uma área de pesquisa da ciência da computação que busca métodos ou dispositivos computacionais que simulam a capacidade humana de resolver problemas. Desde que foi criada, as pesquisas voltadas a IA tentam complementar computacionalmente os sistemas que pensam e agem de forma racional, e os que pensam e agem de forma semelhante aos seres humanos. Essas quatro vertentes mostram que foi estabelecido uma teoria ou paradigma, para guiar as pesquisas nesse ramo (MACHADO, 2011). A Figura 4 ilustra as subáreas abrangentes pela IA.

Figura 4 - Domínios da Inteligência Artificial.



Fonte: Adaptado de Alvear (2018).

2.3.1 Aprendizado de máquina - *Machine learning*

O aprendizado de máquina (AM), do inglês *Machine Learning (ML)*, abrange, de acordo com Lary et al. (2016), uma gama de procedimentos complexos, sendo uma subdivisão da IA baseada no processo de aprendizagem biológica que engloba diferentes domínios, como mineração de dados, e diversos algoritmos (por exemplo, redes neurais, máquinas de vetor de suporte, árvores de decisão, florestas aleatórias, raciocínio baseado em casos, entre outros) que podem fornecer regressão não paramétrica, não linear multivariada ou classificação.

O AM refere-se à detecção automatizada de padrões de dados significativos, ou seja, são algoritmos que aprendem a partir do conjunto de dados fornecidos, gerando resultados preditivos ou descritivos, com base no que aprendeu (SHALEV-SHWARTZ e BEN-DAVID, 2013). As técnicas de AM, de acordo com Esteves et al. (2009), empregam um princípio de inferência denominado indução, que operam baseados em um conjunto de exemplos de classificadores, que deve ser capaz de prever a classe de novos dados quaisquer do domínio no qual ele foi treinado.

O aprendizado indutivo pode ser dividido em dois tipos principais: supervisionado e não supervisionado. Silva et al. (2017), ressaltam que o aprendizado supervisionado objetiva induzir um classificador ou hipótese, através de um conjunto expressivo de dados previamente rotulados, para classificar novos exemplos ainda não rotulados. Quanto ao aprendizado não

supervisionado, o indutor analisa os exemplos fornecidos e tenta determinar se alguns deles podem ser agrupados de alguma maneira, formando agrupamentos ou clusters. Após a determinação dos agrupamentos, normalmente, é necessária uma análise para determinar o que cada agrupamento significa no contexto do problema que está sendo analisado (SIVIERO e JÚNIOR, 2019). De maneira geral, a Figura 5 apresenta a hierarquia de aprendizado descritas.

Figura 5 - Hierarquia do aprendizado de máquina.



Fonte: Adaptado de Almeida et al. (2020).

2.3.1.1 Aprendizado Não supervisionado

O aprendizado de máquina não supervisionado, também conhecido como análise de *cluster*, é tido como a descoberta de classes que não foram definidas previamente pelo analista. Uma das principais diferenças entre o AM supervisionado e o não supervisionado é que não há um conjunto de treinamento para o segundo e, portanto, nenhuma função óbvia para a validação cruzada (GENTLEMAN e CAREY, 2008).

As principais tarefas realizadas pelo AM não supervisionado são agrupamento (*clustering*) e redução de dimensionalidade, abordagens também amplamente utilizadas para identificação de anomalias nos dados. Para as tarefas de *clustering*, o modelo recebe um conjunto de dados não rotulado, e partir disso busca agrupá-lo com base em alguma característica de similaridade, como a distância entre os pontos (ALPAYDIN, 2020).

No âmbito do processamento de imagens, as ações de AM não supervisionado que envolvem *clustering* e segmentação, correspondem essencialmente a diferentes instâncias do problema de agrupamento, ou seja, o objetivo geral é identificar grupos de imagens primitivas semelhantes, como *pixels*, características locais, segmentos ou mesmo imagens completas (PUZICHA et al., 1999). De acordo com Kim et al. (2020), a segmentação de imagem a partir

de AM não supervisionado é usada para prever rótulos mais gerais, onde a imagem é particionada em seus componentes constituintes.

2.3.1.1.1 Segmentação de imagens

A segmentação de imagens é o processo que constrói uma rede hierárquica de objetos e os classifica com base nos critérios de homogeneidade, ou seja, traduz a similaridade entre objetos vizinhos. Após a segmentação, cada objeto é descrito com relação a suas propriedades geométricas e topológicas, onde o reconhecimento de cada objeto resulta em uma imagem rotulada, com os *pixels* que pertencem a objetos diferentes associados a rótulos distintos (RONCERO, 2005).

Os parâmetros utilizados para segmentar uma imagem podem ser o número de bandas e o tamanho da janela de varredura, que se desloca por toda a imagem avaliando a similaridade espectral e verificando a variância existente. Podem também ser utilizados a proporção entre a média e desvio padrão, e a similaridade permitida/tolerada entre segmentos (quanto maior o valor desta similaridade, menor é o número de segmentos) (EASTMAN e IDRISI, 2009; JENSEN, 2015, p. 416-17). Sendo assim, a imagem é particionada e influenciada por parâmetros de escala, tonalidade e forma.

Na literatura, diversos estudos tem utilizado a segmentação durante o processamento das imagens de alta resolução, como por exemplo as técnicas de correspondência de modelos, filtragem máxima local, detecção de bordas, transformação de bacias hidrográficas, deslocamento médio, ou combinações destes, foram testadas com resultados promissores (BRANDTBERG e WALTER, 1998; CULVENOR, 2002; POULIOT et al., 2002; WANG, 2010).

O algoritmo de segmentação de deslocamento médio (*mean shift – MS*) é um classificador de agrupamento não paramétrico que substitui cada ponto discreto por um kernel de densidade contínuo finamente delimitado e, em seguida, agrupa pontos, de acordo com um estimador de densidade global (WESSEL et al., 2018; VLACHOPOULOS et al., 2020). O MS foi introduzido por Fukunaga e Hostetler (1975), como um estimador de função de densidade de probabilidade não paramétrica para reconhecimento de padrões.

O algoritmo MS tem sido utilizado com sucesso para segmentação de análise de imagem baseada em objeto (OBIA) devido à sua versatilidade geral de agrupamento no domínio espacial-espectral (MING et al., 2015; DE LUCA et al., 2019). Foi testado com sucesso em imagens obtidas por RPAS por Lu et al. (2015), Ming et al. (2015) e De Luca et al. (2019) para

mapeamento da cobertura da terra e por Wessel et al. (2018), em diferentes configurações de segmentação na abordagem OBIA, para diferenciar espécies de árvores.

2.3.1.2 Aprendizado Supervisionado

O AM supervisionado é um método que, utilizando uma base de dados classificada, realiza a predição de novos registros em vários desses exemplos, ou seja, é quando existem casos que possuem uma classificação disponível para determinados conjuntos de dados (conjunto de treinamento), mas precisa ser previsto para outras instâncias. Os responsáveis por essas tarefas são algoritmos de aprendizado supervisionados projetados para determinados fins que funcionam como agentes que observam exemplos de entrada e saída, e aprendem uma função de mapeamento da entrada para uma saída (RUSSEL e NORVIG, 2013).

Os classificadores baseados em AM supervisionado, no âmbito do sensoriamento remoto, apresentam vantagens em relação aos classificadores supervisionados fundamentados em conceitos estatísticos, vários estudos têm demonstrado a importância do uso de algoritmos de AM para classificação de alvos a partir de imagens de SR, devido à alta performance preditiva em análise de dados (CARVALHO et al., 2019). Os algoritmos supervisionados têm sido usados com intuito de melhorar a classificação do uso e cobertura da terra, tais como a *Support Vector Machines* (SVM) e *Random Forest* (RF).

2.3.1.2.1 *Support Vector Machine* (SVM)

A Máquina de Vetor de Suporte, ou *Support Vector Machine* (SVM), consiste em um método de aprendizado supervisionado desenvolvido por Cortes et al. (1995), baseado no conceito de planos de decisão que definem limites de decisão. O algoritmo foi baseado na teoria de aprendizagem estatística e tem o objetivo de determinar a localização dos limites de decisão que produzem a separação ótima de classes (VAPNIK, 1999). O SVM é um classificador não paramétrico capaz de lidar com a heterogeneidade dos dados, exigindo menos tempo computacional durante a execução com parâmetros de *kernel* apropriados.

A ideia principal por trás dos algoritmos SVM é estimar a dependência linear entre pares de vetores de entrada n -dimensionais e variáveis-alvo unidimensionais, ajustando um hiperplano de aproximação ótimo a um conjunto de amostras de treinamento. As observações que possuem distância mínima até o hiperplano são denominadas vetores de suporte. Treinado o modelo, a predição de uma instância desconhecida é feita determinando-se a posição da mesma em relação ao hiperplano de separação (SHAO e ZHANG, 2016).

Recentemente, tem sido demonstrado uma atenção especial ao algoritmo SVM em SR, principalmente no que diz respeito à classificação de imagens. As principais características desse classificador são: i) alta capacidade de generalização e alta precisão de classificação em relação a outros classificadores; ii) a convexidade da função custo, que sempre permite que a solução ideal seja alcançada; iii) robustez no tratamento de dados de alta dimensão como no caso de dados hiperespectrais. Vários estudos de aplicações do SVM em SR foram publicados em periódicos, podendo ser constatados em Schölkopf et al. (2000); Pal e Mather (2005); e Mountrakis e Ogole (2011).

No contexto da ciência florestal em conjunto de dados de SR, o SVM tem mostrado alta eficácia, principalmente para identificação e classificação de espécies (DIXON e CANDADE, 2008). Sothe et al. (2019), utilizando o classificador SVM, puderam classificar 12 espécies de árvores em uma floresta subtropical altamente diversa no sul do Brasil, com base em dados de imagens hiperespectrais adquiridos por RPAS. Este foi o primeiro estudo usando este tipo de dados para classificar um grande número de espécies de árvores em uma floresta subtropical. Os autores obtiveram resultados satisfatórios em termos de classificação, atingindo uma precisão geral de até 72,4% e um índice Kappa de 0,70 ao combinar dados de bandas hiperespectrais visíveis e infravermelho próximos, aos recursos de nuvem de pontos fotogramétricos, modelo de altura do dossel e índices de vegetação.

2.3.1.2.2 *Random Forest (RF)*

A floresta aleatória, ou *Random Forest* (RF), é um método de aprendizagem conjunta sugerido por Breiman (2001), baseado em uma combinação de preditores, onde cada preditor deve ser dependente dos valores estimados de uma amostra aleatória para todas as árvores, independentemente. As decisões são combinadas de acordo com as decisões que foram tomadas com base no uso de centenas de classificadores (FENG et al., 2015).

Essencialmente, o RF é um algoritmo de AM que combina os conceitos de árvores de classificação e regressão, com algum grau adicional de randomização (BIAU e SCORNET, 2016). Conforme Shao e Zhang (2016), o RF foi projetado para melhorar o método de árvores de classificação e regressão linear tradicional, de modo a integrar um grande conjunto de árvores de decisão baseado em uma técnica determinística, selecionando um conjunto aleatório de variáveis e uma amostra aleatória do treinamento. O algoritmo utiliza processos diferentes dependendo da natureza do problema, de modo que para classificação, o resultado final é alcançado pela votação de cada árvore da floresta, já na regressão, a saída da floresta será a média entre os resultados das árvores (MONTAÑO, 2016).

Ao analisar globalmente e em diversas áreas de pesquisa, é possível identificar um consenso entre os pesquisadores de que o RF é um dos algoritmos mais utilizados. Esse alto uso pode estar relacionado a vários fatores, entre os quais se citam tarefas de regressão e classificação, o RF é utilizado para estimar parâmetros quantitativos da vegetação na área de SR (MALENOVSKÝ et al., 2017), é simplificado quando comparado a outros métodos de AM (por exemplo, SVM ou redes neurais), existem menos parâmetros para especificar ao executar RF (BREIMAN, 2001), e preciso, conforme Biau e Scornet (2016), que afirmam que o RF é geralmente reconhecido por sua precisão e sua capacidade de lidar com grandes tamanhos de amostra e espaços de recursos de alta dimensão.

No estudo de Reis et al. (2019), combinando sensores hiperespectral e LiDAR, e plataformas associadas ao algoritmo *Random Forest*, com o objetivo de avaliar o sucesso da restauração florestal, alcançaram resultados promissores com um índice Kappa de 0,99 para as variáveis que compõem a estrutura da floresta abaixo do dossel. Puliti et al. (2019) analisaram o potencial da combinação de dados de campo e RPAS para modelar as principais características da floresta em fase de regeneração alcançando resultados muito promissores com o uso do algoritmo de RF.

No mapeamento de espécies invasoras, Kattenborn et al. (2019), propuseram um fluxo de trabalho para mapear as frações de cobertura de 3 espécies de invasoras (*Pinus radiata*, *Acacia delabata* e *Ulex europaeus*), utilizando dados de RPAS e posterior escalonamento, com base em RF, para dados de Sentinel-1 e Satélites Sentinel-2. Uma validação independente revelou que o R^2 do aumento da escala representou 0,78 ou mais para todas as espécies invasoras detectadas.

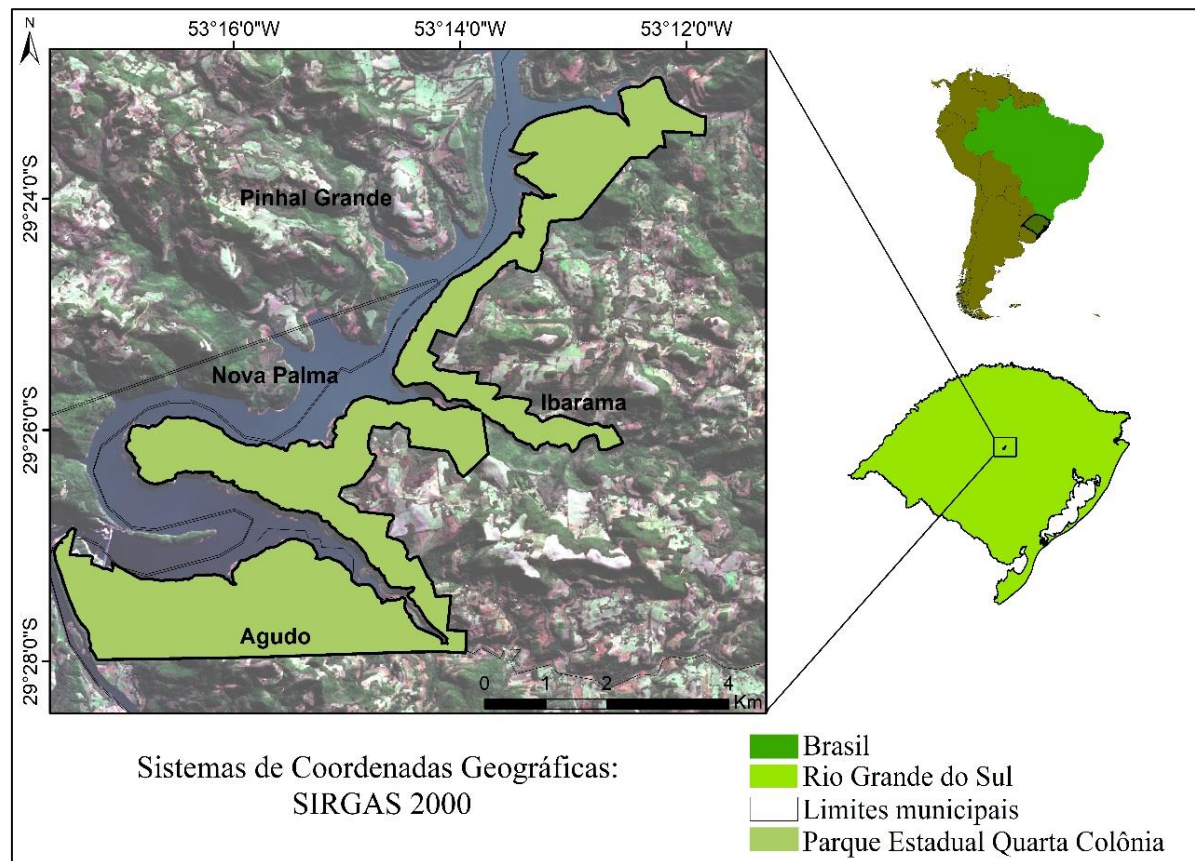
Além disso, neste campo, o objeto de pesquisa para de Sá et al. (2018), foi avaliar o potencial invasor das espécies florestais de *Acacia longiflora*. Com o uso do algoritmo de RF, eles alcançaram excelentes resultados (92%) quando validados com imagens obtidas de sensores orbitais.

3 MATERIAL E MÉTODOS

3.1 LOCALIZAÇÃO E CARACTERIZAÇÃO DA ÁREA DE ESTUDO

A área de estudo pertence ao Parque Estadual Quarta Colônia (PEQC), uma Unidade de Conservação (UC) de proteção integral, criada a partir do Decreto Estadual nº 44.186, de 19 de dezembro de 2005, sendo decorrente da compensação ambiental proveniente da instalação da Usina Hidrelétrica de Dona Francisca, situada no rio Jacuí, que abrange os municípios de Agudo e Ibarama, Região Central do Rio Grande do Sul. A área esta compreendida entre as coordenadas 29° 27' 36,11" Sul e 53° 16' 37, 07" Oeste, com um território de 1.840 ha (Figura 6).

Figura 6 - Mapa de localização do Parque Estadual Quarta Colônia, RS, Brasil.



Fonte: Autora (2022).

De acordo com o Sistema Brasileiro de Classificação de Solos (SBCS), os solos da região são do tipo Argissolos e Cambissolos associados a Neossolos lítico (EMBRAPA, 2018). O relevo é considerado forte-ondulado, formado por morros e escarpas, originários de derramamento basáltico que recobre as formações sedimentares de arenitos, silticos e argilosos (PEDRON et al., 2009; PEDRON e DALMOLIN, 2011).

De acordo com a classificação de Köppen, o clima da região é do tipo subtropical úmido – Cfa, onde os meses mais quentes vão de dezembro a fevereiro com temperatura média de 22°C, enquanto que os meses junho, julho e agosto são os mais frios, com temperatura média de -3°C e 18°C. A precipitação média anual é de aproximadamente 1.722 mm (ALVARES et al., 2013).

A vegetação pertence ao tipo fitogeográfico Floresta Estacional Decidual e é inerente ao Bioma Mata Atlântica, caracterizada por um mosaico sucessional que abriga importantes remanescentes de Floresta Estacional Decidual (MALLMANN et al., 2015), estas áreas estão em processo de restauração, anteriormente degradadas durante a construção da barragem da usina hidrelétrica (SCHUMACHER et al., 2011).

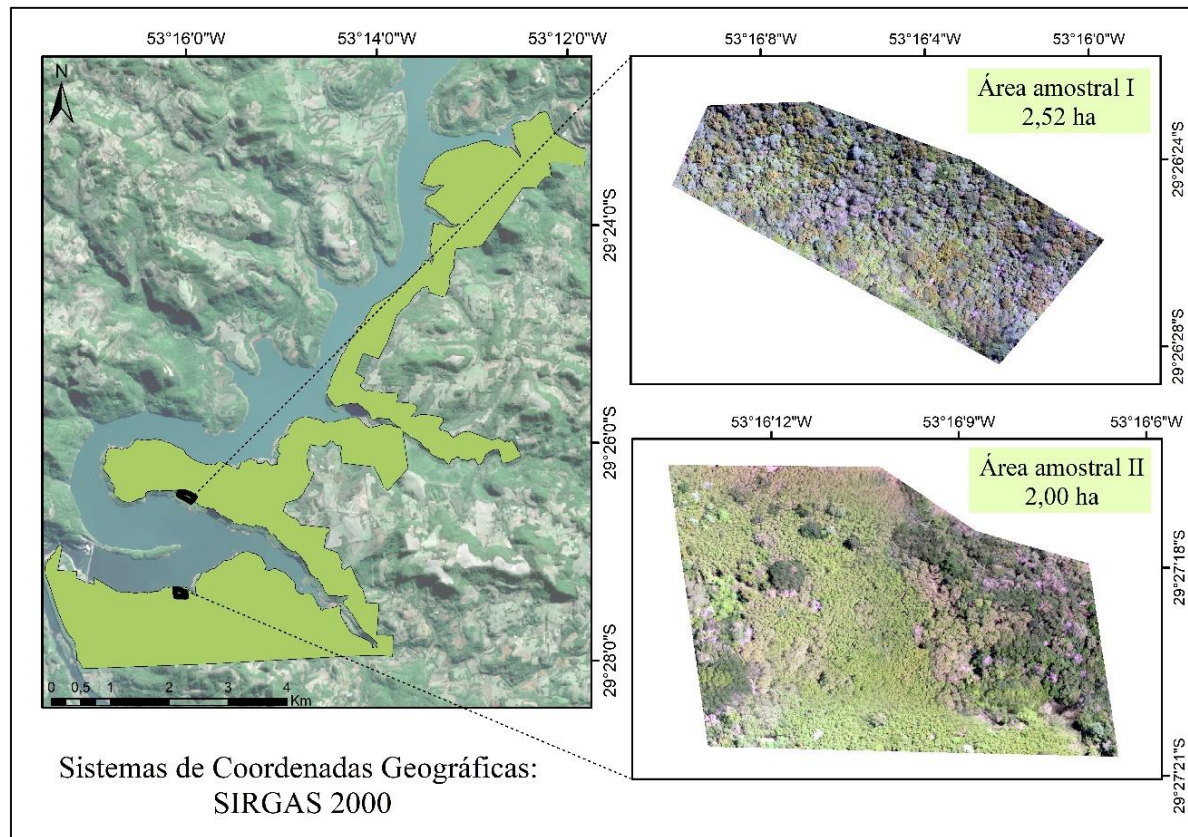
Estudos realizados por Missio e Longhi (2019), na região próxima ao PEQC, amostraram 65 espécies arbóreas e arbustivas, entre nativas e exóticas, distribuídas em 31 famílias botânicas, com mais de 2000 indivíduos ha⁻¹. As famílias de maior riqueza em espécies nativas, foram a Fabaceae, Lauraceae, Myrtaceae, Euphorbiaceae, Meliaceae, Moraceae, Salicaceae e Sapindaceae. Dentre as espécies mais abundantes e de maior valor de importância, *Casearia sylvestris*, *Nectandra lanceolata*, *Cupania vernalis* e *Guarea macrophylla* representaram 57% da comunidade arbórea. Farias (1994), Callegaro et al. (2014); Scoti et al. (2016) também encontraram maior incidência das famílias Myrtaceae, Lauraceae, Euphorbiaceae, Fabaceae, Sapindaceae em estudos realizados na mesma tipologia.

3.1.1 Área amostral

Para melhor entendimento, a região onde foi realizado o censo dos exemplares de *H. dulcis* foi chamada de área amostral I e possui 2,52 ha, localizada nas coordenadas geográficas: 29° 26' 22" S e 53° 16' 10" Oe, enquanto a região de levantamento da espécie *P. guajava*, foi denominada de área amostral II com 2,00 ha, localizada nas coordenadas 29° 27' 16" S e 53° 16' 14" O.

As áreas I e II foram selecionadas após visitas ao PEQC, ao serem observados locais de maior concentração das espécies. As parcelas se encontram em fragmentos florestais, em estágio secundário de regeneração natural, de aproximadamente 20 anos. As áreas estão no entorno do rio Jacuí (Figura 7), denominadas de “APP do alague”.

Figura 7 - Mapa de localização das áreas de estudo no Parque Estadual Quarta Colônia, RS, Brasil.



Fonte: Autora (2022).

3.2 AQUISIÇÃO DOS DADOS DE CAMPO

3.2.1 Descrição das espécies alvo


Os alvos do presente estudo consistem em duas espécies florestais exóticas invasoras: *Hovenia dulcis* Thumb. (uva-do-japão) e *Psidium guajava* L. (goiabeira), incluídas na Lista de EEI do Estado do RS, estabelecida pela Portaria n° 79/2013, da Secretária Estadual do Meio Ambiente (SEMA). Essas espécies apresentam populações amplamente estabelecidas e dispersas no PEQC, ocupam áreas extensas e transformam o habitat local, causam impacto direto sobre a vegetação nativa da unidade. Estes critérios foram tomados para a seleção das duas EFEI's, assim como a indicação da gestora da UC, que necessita de monitoramento e manejo de ambas as espécies no PEQC.

3.2.1.1 *Hovenia dulcis* Thumb.Quadro 1 - Descrição da espécie *Hovenia dulcis* Thumb.

Sinônimos	<i>Hovenia pubescens</i> Sweet.	<i>Hovenia dulcis</i> Thumb
Família	<i>Rhamnaceae</i>	
Nomes populares	uva-do-Japão; uva-japonesa	
Origem da espécie	China, Japão, Coréia do Norte, Coréia do Sul, Tailândia e Vietnã	
Grupo taxonômico	Árvore	
Descrição	Árvore caducifólia, com 10 a 15 m de altura, podendo atingir 25 m de altura e 50 cm ou mais de DAP no Sul do Brasil. A frutificação inicia entre 3-4 anos no Rio Grande do Sul. A queda das folhas ocorre de abril-maio até fins de agosto	
Floração e Frutificação	Agosto a fevereiro / março a outubro.	
Aspectos Ecológicos	Apresenta características de planta pioneira. A espécie possui regeneração natural intensa por sementes, aproveita clareiras de florestas exploradas para se estabelecer. Não raro, cresce em terrenos baldios e próximo a habitações, formando agrupamentos. Quanto aos aspectos edáficos, apresenta grande plasticidade, se desenvolvendo em solos compactos, rasos e pedregosos, desde arenosos até argilosos (CARVALHO, 1994).	

Fonte: Autora (2022).

3.2.1.2 *Psidium guajava* L.Quadro 2 - Descrição da espécie *Psidium guajava* L.

Família	<i>Myrtaceae</i>	<i>Psidium guajava</i> L
Nomes populares	goiabeira; goiaba; guava	
Origem da espécie	Nativas da América tropical, do sul do México ao Norte da América do Sul.	
Grupo taxonômico	Árvore	
Descrição	Arvoreta (árvore de pequeno porte), com até 10 m de altura, ramificando-se da base e frequentemente produzindo brotação pelo tronco ou raiz.	
Floração e Frutificação	setembro a novembro / dezembro a março	
Aspectos Ecológicos	É uma espécie tropical e subtropical de rápido crescimento, adaptada a uma ampla gama de condições ambientais. É tolerante à sombra, com reprodução precoce e dispersão de sementes auxiliada por aves e mamíferos. Pode formar matas densas que deslocam a vegetação nativa e é relatada como uma planta invasora em muitos países (CRONK e FULLER, 1995; SMITH, 1998)	Fonte: Autora (2022).

3.2.2 Levantamento Florístico

O levantamento florístico das EFEI's (*H. dulcis* e *P. guajava*) foi realizado no mês de novembro de 2020, através de censo, nas duas áreas amostrais. O método empregado nos trabalhos de campo foi o “caminhamento”, que consiste em reconhecer o tipo de vegetação


(fitofisionomias) na área amostrada, elaborar a lista da espécie alvo, a partir de caminhadas ao longo de linhas imaginárias, e análise dos resultados (FILGUEIRAS et al., 1994).

Dentro de cada área, as árvores foram identificadas e as posições foram medidas para todos os indivíduos com circunferência à altura do peito (CAP) ≥ 5 cm, medido a 1,30 m do solo, posteriormente transformados para diâmetro à altura do peito (DAP). A posição de cada árvore foi registrada com uso de receptor *Global Positioning System* (GPS), com erro de posição na ordem de 3 metros, e registrada a altura total das árvores, por meio de avaliação visual e estimativa.

Posteriormente, foi elaborada uma planilha eletrônica, que continham as coordenadas geográficas X e Y das espécies amostradas no censo, salva em arquivo de extensão .CSV.

A Figura 8 ilustra exemplos da cobertura vegetal obtidas de diferentes vistas nas áreas amostrais I e II.

Figura 8 – Vista interior (a), vista frontal (b) e vista aérea usando a câmera RGB do RPAS (c) da área amostral I. Vista interior (d), vista frontal (e) e vista aérea usando a câmera RGB do RPAS (f) da área amostral II.



Fonte: Autora (2022).

3.3 AQUISIÇÃO DOS DADOS REMOTOS

3.3.1 Aquisição das imagens

O levantamento aéreo foi realizado no mês de janeiro de 2021, onde as imagens foram adquiridas com um RPAS, quadricóptero *Phantom-4 Pro*, produzido pela empresa chinesa DJI, uma aeronave leve (1388 g), que possui uma câmera RGB (*red, green, blue*) conectada, com tempo de voo de aproximadamente 30 minutos. Para obtenção das imagens multiespectrais, foi utilizada a câmera multiespectral *Parrot Sequoia*® (Parrot Drone SAS, Paris, França),

embarcada ao *Phantom 4 Pro*. O sensor *Sequoia* captura imagens em quatro bandas espectrais distintas, sendo duas no comprimento de onda do visível, uma na região da borda vermelha e outra no infravermelho próximo. As imagens dessas quatro bandas têm resolução de 1,2 megapixels (MP). Faz parte do sistema, o *Sunshine Sensor*[®], o qual fica também acoplado ao RPAS e conectado a câmera de modo que seja possível realizar a correção radiométrica das imagens. Os valores de albedo para a correção radiométrica são obtidos a partir do painel de calibração que acompanha a Parrot Sequoia[®]. O quadro 3 apresenta as especificações do sensor.

Quadro 3 - Especificações técnicas do Sensor Parrot Sequoia.

Sequoia [®]		Sensor Sunshine [®]
Resolução da câmera	1,2 MP	4 sensores espectrais com os mesmos filtros
Tamanho da imagem	1280 x 960 pixels	
Ângulo Focal	3,98 mm	
Tamanho do pixel	3,75 µm	GPS
Bandas espectrais	<i>Green</i> - 550nm ± 40nm	IMU + Magnetômetro
	<i>Red</i> - 660nm ± 40nm	Cartão SD
	<i>Red Edge</i> - 735nm ± 10nm	1W
	<i>NIR</i> - 790nm ± 40nm	35g

Fonte: Parrot, 2020.

A aquisição das imagens em campo foi realizada por meio de uma sequência de etapas, como: a geração do plano de voo, testes e verificações no RPAS, lançamento e pouso, com o intuito de garantir a qualidade dos dados obtidos das mesmas.

A geração do plano de voo do RPAS foi realizada no aplicativo *DroneDeploy*[®], utilizado desde a configuração prévia e simulações de plano de voo, até o levantamento em campo. Foram definidas as características dos dados obtidos pela câmera acoplada no RPAS, como a resolução espacial das imagens de 18 cm, valores de sobreposição lateral de 70% e longitudinal 80%, uma vez que esses índices determinam o quanto de uma foto sobrepõe na imagem seguinte, interferindo na qualidade do mapa gerado, e a altura de voo de altura de voo de 120 m.

Por se tratar de sensores distintos, as configurações de disparo para captura das imagens RGB e multiespectrais foram realizadas em diferentes aplicativos. Para o sensor RGB, o disparo é calculado por meio do aplicativo *DroneDeploy* de forma automática, em função da escolha do sensor e dos parâmetros de voo (sobreposição e altura). Quanto aos ajustes do sensor *Sequoia*, estes são realizados por meio da conexão *Wi-Fi* da câmera *Sequoia* no aparelho

celular, onde o disparo configurado em intervalos de 2 segundos, partindo do pressuposto que, quanto maior for a sobreposição de imagem maior a precisão.

Ressalta-se a importância de o RPAS estar de acordo com a legislação vigente da Agência Nacional de Telecomunicações (ANATEL), da Agência Nacional de Aviação Civil (ANAC) e do Departamento de Controle do Espaço Aéreo (DECEA). Para cada voo, foi realizada uma conferência na fase de planejamento e execução. Durante o planejamento, foi feita a análise da previsão do tempo, levando em consideração os elementos meteorológicos, como por exemplo, precipitação e velocidade do vento. Após o planejamento, foi solicitado e obtida a autorização ao DECEA, para a utilização do espaço aéreo no dia e horário estipulado. Para a fase de execução do voo, foi necessário estudar o melhor posicionamento para decolagem da aeronave, verificar velocidade e direção do vento e o horário do voo.

Estando o plano de voo configurado, o próximo passo foi executá-lo, iniciando com os testes nos sensores da aeronave (câmera, altitude, velocidade do vento e giroscópio), verificação do estado da bateria e lançamento. Visando diminuir o efeito da angulação do sol e as sombras das árvores, os voos foram realizados nos horários entre as 11h00 e 13h00. Procurou-se também realizar o imageamento em dia claro e sem a incidência de nuvens. A tabela 3 apresenta o número de imagens adquiridas e tamanho do *pixel* (*Ground Sample Distance – GSD*), nas duas áreas de estudo.

Tabela 3 - Informações sobre os voos realizados nas áreas de estudo.

Áreas	Altura (m)	Velocidade (m/s)	Nº de Imagens		GSD médio (cm)
			Multispectral	RGB	
I	120	10	-	64	18
II	120	10	522	40	18

3.4 PROCESSAMENTO DOS DADOS

3.4.1 Criação do *shapefile* das EFEI's

Com a planilha eletrônica que continha as coordenadas geográficas X e Y, foi realizado, no Sistema de Informações Geográficas (SIG) *ArcMap 10.8* (ESRI, 2016), a transformação desses dados em um arquivo vetorial (*shapefile*), com uso da ferramenta *add XY data*.

O arquivo *shapefile* foi utilizado para localizar com precisão a distribuição espacial dos indivíduos, entretanto, foi necessário realizar ajustes na geolocalização dos pontos, devido as condições locais das respectivas áreas de estudo, como a dificuldade de acesso e deslocamento, atrelado ao relevo da região ser fortemente acentuado, e a flutuação do sinal do GPS, que limita

a precisão das coordenadas.

3.4.2 Geração do ortofotomosaico

As imagens foram extraídas do equipamento e processadas no aplicativo computacional *Pix4Dmapper Pro*[®] (Pix4D SA, 2021) adquirido a partir de uma licença gratuita para uso estudantil. As imagens georreferenciadas, em conjunto com os parâmetros internos e externos do sensor de aquisição utilizado, permitem a resolução de distorções das imagens e encontrar características comuns entre as imagens, gerando uma nuvem de pontos esparsa. Posteriormente o número de pontos é incrementado, formando-se uma nuvem de pontos densa. A última fase do processo do Pix4D consiste na criação dos resultados ortorretificados, através da interpolação da nuvem de pontos em conjunto com as imagens fornecidas inicialmente.

As imagens RGB e multiespectrais de cada voo foram processadas em projetos separados, onde para as imagens RGB, foi utilizado o modelo de processamento *Agriculture RGB*, cujo resultado é um ortofotomosaico de alta resolução no formato de saída *geotiff*. Quanto ao processamento das imagens multiespectrais, foi utilizado o modelo de processamento *Agriculture Multispectral*, onde foram gerados um ortofotomosaico em formato *geotiff* de cada uma das bandas espectrais capturadas pelo sensor Sequoia, incluindo controle radiométrico, que consiste na calibração radiométrica das bandas, inserindo os valores de albedo que fazem parte do sensor *Sunshine* da Parrot Sequoia. O sistema de coordenadas utilizado foi World Geodetic System (WGS) 1984 e Datum WGS-84.

3.4.3 Georreferenciamento das imagens

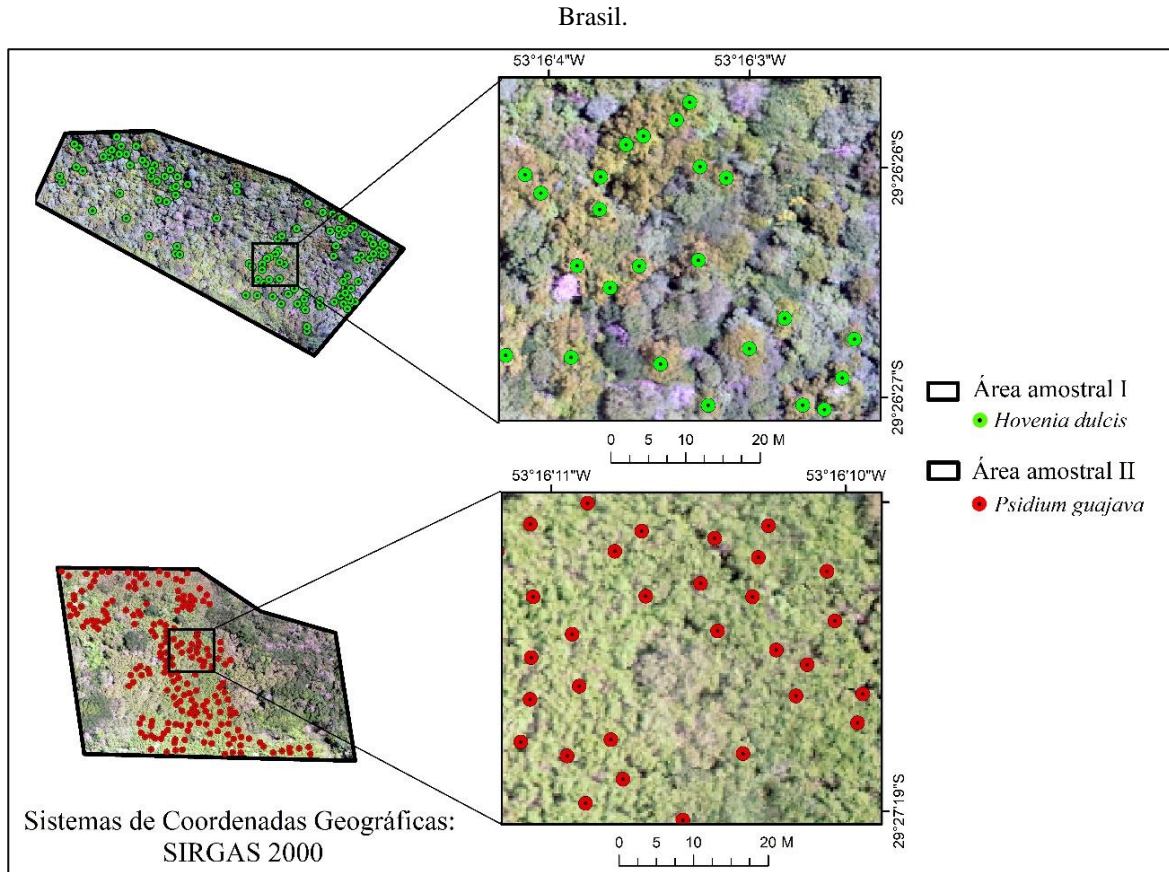
O processo de posicionamento geométrico dos ortomosaicos multiespectrais foi executado no SIG ArcMap 10.8[®], tendo como base as imagens RGB georreferenciadas e ortorretificadas, a partir de pontos conhecidos. Foram coletados 16 pontos de controle nas imagens, apresentando um erro médio quadrático inferior a 0,5 *pixel*. Esse processo foi necessário devido ao sensor multispectral não possuir integração direta com a controladora do RPAS.

3.4.4 Geolocalização das espécies alvos

As ortofotos RGB foram exportadas e inseridas no SIG *ArcMap* 10.8[®], onde foram feitas a distribuição das coordenadas geográficas de cada árvore coletada durante o censo, assim como a correção da localização precisa dos pontos a partir do arquivo *shapefile*, realizada por meio de edição vetorial manual sobre o mosaio RGB. Para a elaboração do mapa de distribuição das

espécies, utilizou-se todos os pontos vetorizados, gerando um arquivo matricial separado para cada área amostral (Figura 9).

Figura 9 - Geolocalização das espécies alvo nas áreas amostrais I e II, Parque Estadual da Quarta Colônia, RS,



3.4.5 Índices de Vegetação¹

Os índices de vegetação (IV) foram selecionados após uma revisão de literatura com base nas faixas espectrais disponíveis, nas evidências de correlação com os parâmetros analisados e quanto ao seu desempenho. Os índices encontram-se dispostos na Tabela 4.

No SIG *ArcMap* 10.8, os mosaicos de bandas foram utilizados para o cálculo dos 13 IV. Além disso, o recorte das imagens foi realizado a partir do arquivo vetorial *shapefile* de plotagens, utilizando uma distância interna para evitar efeito de borda nos *pixels*. Com base nas imagens multiespectrais adquiridas para a área amostral II, foram calculados os seguintes IV: CVI – *Chlorophyll Vegetation Index*; NDVI - *Normalized Difference Vegetation Index*; GNDVI - *Green Normalized Difference Vegetation Index*; TVI - *Transformed Vegetation Index*;

¹ É importante ressaltar que devido a problemas do sensor sequoia, tornou-se inviável utilizar as imagens multiespectrais capturadas na área amostral I (*H. dulcis*), sendo assim, esta etapa foi realizada apenas para a área amostral II (*P. guajava*).

MTVI - *Modified Triangular Vegetation Index*; MSAVI - *Modified Soil Adjusted Vegetation Index*; TCARI - *Transformed Chlorophyll Absorption in Reflectance Index*; MCARI - *Modified Chlorophyll Absorption in Reflectance Index*; MCARI2 - *Modified Chlorophyll Absorption in Reflectance Index2*; OSAVI - *Optimized Soil Adjusted Vegetation Index*; SAVI - *Soil Adjusted Vegetation Index*; GWDRVI – *Green Wide Dynamic Range Vegetation Index*; WDRVI - *Wide Dynamic Range Vegetation Index*.

Tabela 4 - Índices de Vegetação utilizados no estudo.

Sigla	Fórmula	Autor
CVI	$\frac{R_{NIR} * R_{RED}}{R_{GREEN}^2}$	Haboudane et al. (2002)
NDVI	$\frac{R_{NIR} - R_{RED}}{R_{NIR} + R_{RED}}$	Rouse et al. (1974)
GNDVI	$\frac{R_{NIR} - R_{GREEN}}{R_{NIR} + R_{GREEN}}$	Gitelson e Merzlyak (1994)
TVI	$\sqrt{NDVI + 0,5}$	Rouse (1974).
MTVI2	$\frac{1,5[1,2(R_{NIR} - R_{RED}) - 2,5(R_{NIR} - R_{GREEN})]}{\sqrt{(2R_{NIR} + 1)^2 - (6R_{NIR} - 5R_{RED}) - 0,5}}$	Haboudane et al. (2004)
MSAVI	$\frac{(2R_{NIR} + 1) - \sqrt{(2R_{NIR} + 1)^2 - 8(R_{NIR} - R_{REDEGE})}}{2}$	Qi et al. (1994)
TCARI	$3 \left[(R_{REDEGE} - R_{RED}) - 0,2(R_{REDEGE} - R_{GREEN}) \left(\frac{R_{REDEGE}}{R_{RED}} \right) \right]$	Daughtry et al. (2000)
MCARI	$\left[(R_{REDEGE} - R_{RED}) - 0,2(R_{REDEGE} - R_{GREEN}) \left(\frac{R_{REDEGE}}{R_{RED}} \right) \right]$	Daughtry et al. (2000)
MCARI2	$\frac{1,5[2,5(R_{NIR} - R_{RED}) - 1,3(R_{NIR} - R_{GREEN})]}{\sqrt{(2R_{NIR} + 1)^2 - (6R_{NIR} - 5R_{RED}) - 0,5}}$	Haboudane et al. (2004)
OSAVI	$\frac{1,16(R_{NIR} - R_{RED})}{(R_{NIR} + R_{RED} + 0,16)}$	Rondeaux et al. (1996)
SAVI	$\frac{1,5(R_{NIR} - R_{RED})}{(R_{NIR} + R_{RED} + 0,5)}$	Huete (1988)
GWDRVI	$\left[\frac{0,3 (R_{NIR} - R_{GREEN})}{0,3 (R_{NIR} - R_{GREEN})} \right] + \frac{(1 - 0,3)}{(1 + 0,3)}$	Gitelson (2004)
WDRVI	$\left[\frac{(R_{NIR} - R_{GREEN})}{(R_{NIR} - R_{GREEN})} \right]$	Gitelson (2004)

3.5 SELEÇÃO DAS VARIÁVEIS DE ENTRADA PARA APRENDIZADO DE MÁQUINA²

Após gerar os IV, foi realizado o processo de seleção das variáveis de entrada do modelo, o qual envolveu os 13 IV e as quatro bandas do sensor sequoia (*red*, *green*, *nir*, *red edge*), totalizando 17 variáveis. Esta etapa teve como objetivo selecionar qual a faixa do espectro eletromagnético otimizaria a classificação e identificação da EFEI *P. guajava*, na área de estudo. No SIG *ArcMap* 10.8, foram utilizados como dados de entrada, 125 polígonos vetoriais da classe “*Psidium guajava*” e utilizada a ferramenta “*model builder*” que automatiza o recorte desses polígonos para as 17 variáveis.

Dessa forma, foram obtidas as médias de reflectância das quatro bandas do sensor Sequoia e dos IV derivados, para as 125 amostras. Posteriormente, foi calculado o coeficiente de correlação de *Spearman* (p) que quantifica a força de associação existente entre a variável dependente (*P. guajava*) e as 17 variáveis, no aplicativo computacional *R studio*. Assim, foi possível selecionar as variáveis de entrada do modelo com o maior nível de associação entre os dados derivados das imagens e a variável resposta.

3.6 MODELO DE CLASSIFICAÇÃO

Todos os processos de modelagem foram realizados no SIG *ArcGIS Pro* versão 2.8, obtido a partir de uma licença gratuita para uso estudantil.

3.6.1 Criação das amostras de treinamento

Primeiramente, após a análise das características presentes nas áreas I e II, quatro classes de interesse foram estabelecidas para o treinamento do classificador, sendo para a área amostral I: “*Hovenia dulcis*”, “espécie similar³”, “sombra” e “demais espécies⁴” e para a área II: “*Psidium guajava*”, “espécie similar”, “sombra” e “demais espécies.”

Ressalta-se que a classe “espécie similar” foi escolhida devido à fotointerpretação visual de algumas espécies, nas respectivas áreas de estudo, apresentarem uma resposta espectral semelhante à espécie alvo. Os quadros 4 e 5 apresentam as informações sobre o número de




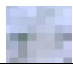
² Conforme destacado na nota de rodapé anterior, esta etapa foi realizada apenas para a área amostral II (*P. guajava*).

³ Fotointerpretação visual de algumas espécies com resposta espectral semelhante a espécie alvo, como por exemplo, *Luehea divaricata* e *Psidium cattleianum*.

⁴ Outras espécies arbóreas encontradas na área de estudo com resposta espectral diferente da espécie alvo.





polígonos gerados para cada classe e o número de identificação utilizado na ferramenta *Training Samples Manager* do *ArcGis Pro*.

Quadro 4 - Definição das classes de interesse para a área amostral I.

Área amostral I RGB	Nome da Classe	Número da Classe	Número de polígonos	Amostra Real
	<i>Hovenia dulcis</i>	5	355	
	Espécie similar	10	235	
	Sombra	15	490	
	Demais espécies	20	695	

Fonte: Autora (2022).

Quadro 5 - Definição das classes de interesse para a área amostral II.

Área amostral II RGB e multiespectral	Nome da Classe	Número da Classe	Número de polígonos	Amostra Real
	<i>Psidium guajava</i>	5	300	
	Espécie similar	10	250	
	Sombra	15	380	
	Demais espécies	20	520	

Fonte: Autora (2022).

Para realizar a classificação supervisionada, as amostras de treinamento foram necessárias como dados de entrada no processo. Grupos de *pixels* com características semelhantes foram criados manualmente e a amostragem levou em consideração a importância de se ter uma coleta de amostras bem distribuída por toda a área, bem como uma quantidade representativa para cada classe. Destaca-se que a ferramenta que realiza a criação das amostras de treinamento obtém a porcentagem de *pixels* de cada polígono criado, dessa forma, foi necessário gerar mais de um polígono em cada ponto coletado, afim de não haver mistura de classes e obter o máximo de polígonos representativos para a posterior classificação.

Além disso, os arquivos vetoriais *shapefile* sobrepostos no *raster* onde estavam sendo geradas as amostras referentes a classe de identificação das EFEI's, foram divididos de modo aleatório em 90% para treinamento/teste dos modelos e 10% para validação do melhor modelo.

Isso implica dizer que nenhuma amostra de treinamento foi criada nos pontos de teste/validação, de modo que o critério definitivo é medir o poder preditivo a partir de novos dados, isto é, dados que nunca foram “vistos” pelo modelo em nenhum estágio de sua construção.

3.6.2 Processo de Classificação

Dois métodos de classificação foram utilizados neste estudo: *pixel a pixel* e Análise de Imagens Baseada em Objeto (*Object-based image analysis* - OBIA). A abordagem baseada em objeto necessita de uma imagem segmentada como *raster* de entrada para a classificação. Para executar a segmentação, o SIG *ArcGis Pro* fornece o algoritmo de deslocamento médio (*Mean Shift*) (ESRI, 2021), que substitui cada ponto discreto (*pixel* da imagem) por um *kernel* de densidade contínuo finamente delimitado e, em seguida, agrupa pontos, de acordo com um estimador de densidade global (COMANICIU e MEER, 2002).

O *kernel* pode ser adaptado manualmente pelo usuário. O detalhe espectral pode ser definido em uma faixa entre 1,0 e 20,0, com um valor mais alto sendo apropriado para recursos que devem ser classificados separadamente, mas têm características espectrais um tanto semelhantes. Outro parâmetro é a configuração de detalhes espaciais. Valores pequenos produzem resultados suaves entre áreas agrupadas, enquanto valores mais altos são mais apropriados quando objetos pequenos são observados e devem ser combinados. Por se tratar de objetos pequenos, valores altos foram escolhidos para ambos os parâmetros. Após vários testes, os parâmetros de segmentação que melhor se adequaram as imagens para as áreas de estudo I e II foram: valor de detalhe espectral de 15.5, e o valor de detalhe espacial de 15.

3.6.3 Aprendizado de Máquina no SIG *ArcGis Pro*

Os algoritmos de AM utilizados para a classificação *pixel a pixel* e OBIA, foram *Random Forest* (RF) e *Support Vector Machine* (SVM), sendo considerados métodos de AM amplamente usados no âmbito do SR (LÓPEZ-SERRANO et al., 2016). Esses algoritmos são implementados no *ArcGIS Pro* como as chamadas funções *raster*. Essas funções, em comparação com as ferramentas de geoprocessamento padrão, funcionam de forma dinâmica (*on the fly*) e são adequadas para processamento distribuído em um servidor de imagem. Este é um requisito importante quando se considera o uso dessas ferramentas para grandes conjuntos de dados.

Os hiperparâmetros de configuração no *ArcGIS Pro* para utilização do algoritmo RF, para os métodos de classificação *pixel a pixel* e OBIA, foram:

- Número máximo de árvores (*max_num_trees*): Um maior número de árvores, leva a taxas de precisão mais altas, embora essa melhoria eventualmente se estabilize. O número de árvores aumenta o tempo de processamento linearmente.
- Profundidade da árvore (*max_tree_depth*): A profundidade é outra maneira para explicar o número de regras que cada árvore pode criar para chegar a uma decisão. As árvores não crescerão mais fundo do que neste cenário.
- Número máximo de amostras a serem usadas para definir cada classe (*max_samples_per_class*): O valor padrão de 1000 é recomendado quando as entradas são *rasters* não segmentados (classificação *pixel a pixel*). Já um valor menor ou igual a 0 significa que o sistema usará todas as amostras de treinamento para treinar o classificador (classificação OBIA).

Para as duas áreas amostrais, foram utilizados os mesmos valores para determinação de cada um destes parâmetros, exceto para o Número máximo de amostras por classe (Tabela 5).

Tabela 5 – Parâmetros utilizados no algoritmo *Random Forest* para o processo de classificação supervisionada.

Parâmetros	Classificação	
	<i>Pixel a Pixel</i>	OBIA
<i>max_num_trees</i>	100	100
<i>max_tree_depth</i>	50	50
<i>max_samples_per_class</i>	1000	0

Para a implementação do algoritmo SVM, os hiperparâmetros de configuração no *ArcGIS Pro*, para a classificação *pixel a pixel* e OBIA, foram:

- Número máximo de amostras (*max_samples_per_class*): Um valor padrão de 500 é recomendado quando as entradas são *rasters* não segmentados (classificação *pixel a pixel*). Já um valor menor ou igual a 0, significa que o sistema usará todas as amostras dos sites de treinamento para treinar o algoritmo (classificação OBIA).

Uma vez que o parâmetro influencia o resultado da classificação, assim como para o algoritmo RF, os mesmos valores de hiperparâmetros foram utilizados para as duas áreas amostrais (Tabela 6).

Tabela 6 - Parâmetro utilizado no algoritmo *Support Vector Machine* para o processo de classificação supervisionada.

Parâmetros	Classificação	
	<i>Pixel a Pixel</i>	OBIA
<i>max_samples_per_class</i>	500	0

3.6.4 Avaliação da Precisão

A avaliação de precisão foi obtida por meio da medição da quantidade de acertos e erros do resultado da classificação ou da medição da acurácia proveniente do processo de atribuição dos *pixels* a determinadas classes, oriundos do grau de confusão entre as classes em uma matriz de confusão e pelo cálculo de índices, que fornecem uma medida geral, como o Índice Kappa (CONGALTON e GREEN, 1993).

Quanto ao Índice Kappa, este é um coeficiente baseado na diferença entre a concordância observada (diagonal principal da matriz de confusão com a concordância entre a classificação e os dados de referência) e a chance de concordância entre os dados de referência de uma classificação aleatória (produto entre os totais marginais da matriz) (CONGALTON e BIGING, 1992).

O Índice Kappa é calculado conforme a Equação 1 e é indicado como medida de precisão por representar toda a matriz de confusão.

$$K = \frac{N \sum_{i=1}^r X_{ij} - \sum_{i=1}^r X_{i+} X_{+i}}{N^2 - \sum_{i=1}^r X_{i+} X_{+i}} \quad (1)$$

Onde:

N = número total de amostras.

r = número de classes;

X_{ij} = número de elementos classificados corretamente;

X_{i+} = total de elementos classificados para uma categoria *i*;

X_{+i} = total de elementos de referência amostrados para uma categoria *i*.

A acurácia global (AG) foi obtida a partir da equação 2:

$$Classe K = \frac{X_{1,1} + X_{2,2} + X_{3,3} + X_{k,k}}{N_{k,k}} \quad (2)$$

A fidedignidade da classificação foi avaliada pelo índice Kappa e Acurácia Global. O nível de exatidão do índice Kappa foi classificado conforme a Tabela 7.

Tabela 7 - Nível de exatidão da classificação, conforme o valor do Índice Kappa

Índice Kappa	Concordância
< 0,00	Péssima
0,0 – 0,20	Ruim
0,20 – 0,40	Razoável
0,40 – 0,60	Boa
0,60 – 0,80	Muito boa
0,80 – 1,00	Excelente

Fonte: Adaptado de Landis e Koch (1977).

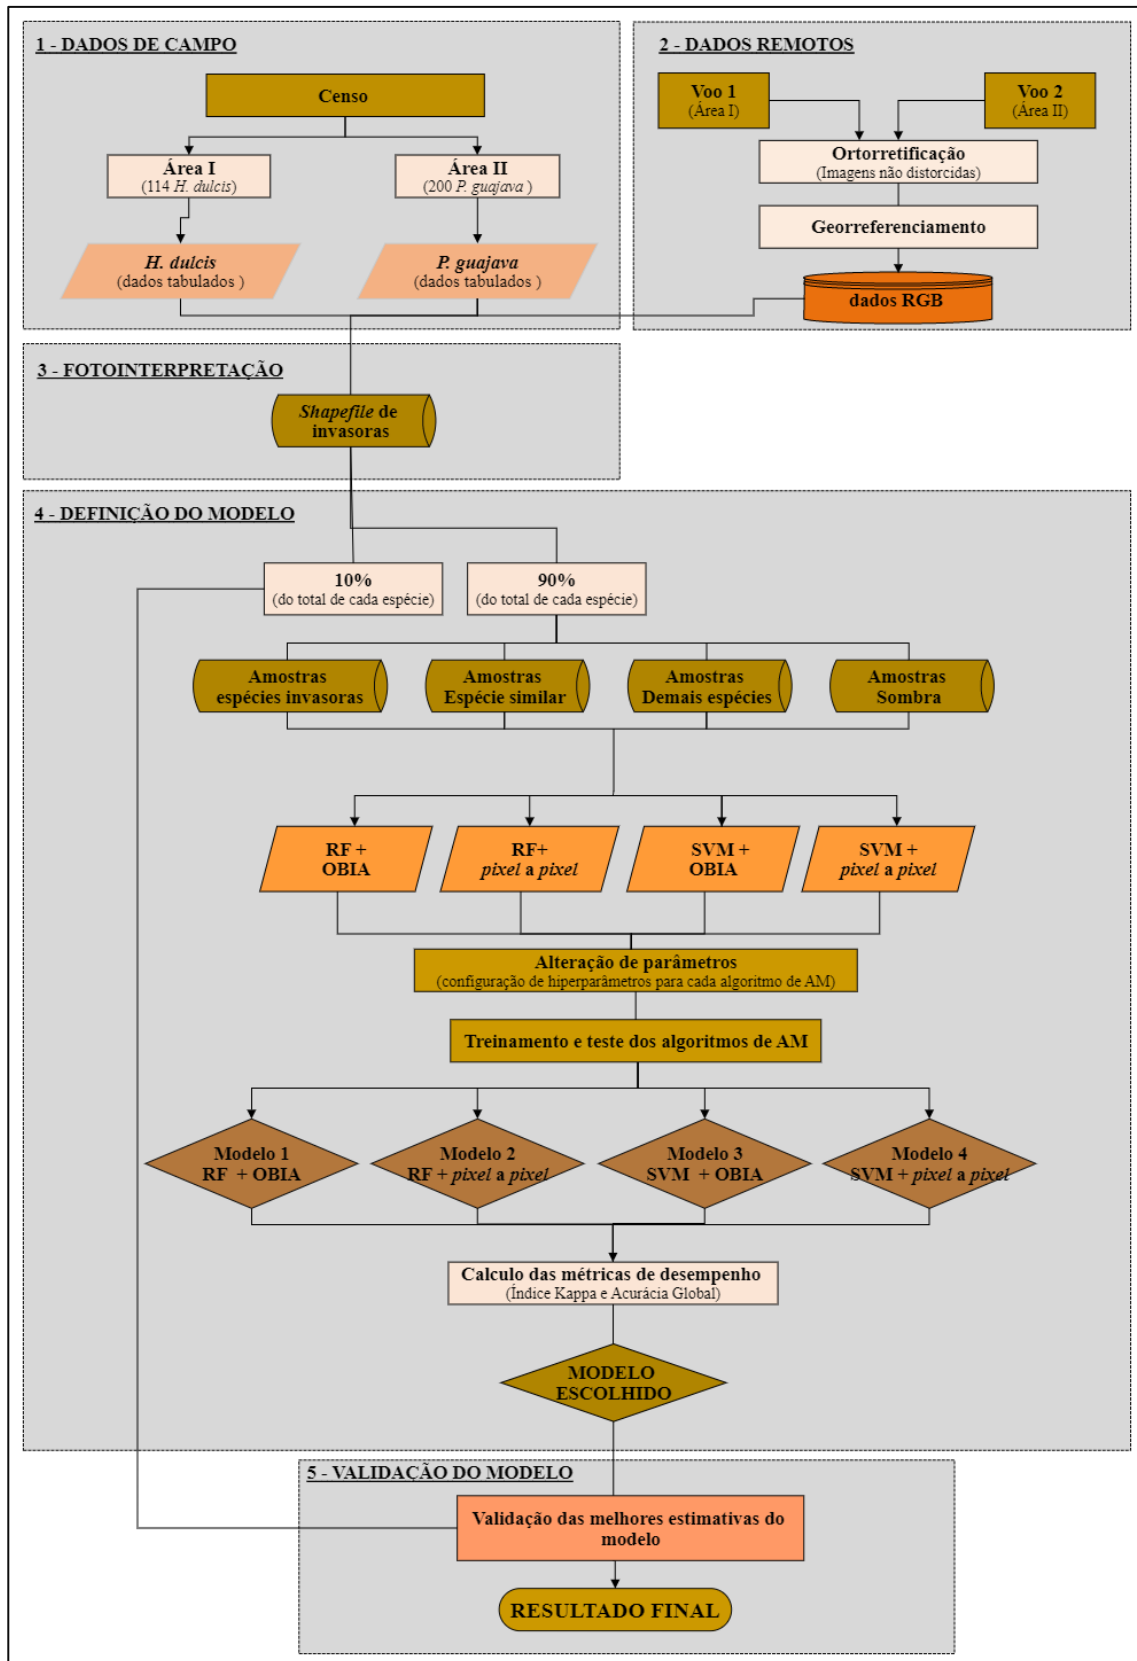
Como conjunto de dados de referência, foi adotada a camada de feição com 200 pontos aleatórios, representando a verdade fundamental. As informações sobre a natureza real das características foram adquiridas a partir da análise do ortofotomosaico RGB combinada com a verdade de campo das áreas de estudo.

Para a distribuição dos pontos aleatórios, foi utilizada a ferramenta *Accuracy Assessment Points*, disponível no *ArcGis Pro*, e escolhido o esquema de amostragem aleatório estratificado, que cria pontos distribuídos aleatoriamente dentro de cada classe, onde cada classe tem um número de pontos proporcional à sua área relativa (CASTANHEIRA, 2013). Em relação à tabela de atributos da camada de pontos, a coluna *GroundTruth* foi preenchida pelo usuário, enquanto a coluna *Classified* foi ocultada para não confundir o processo de classificação do *raster* analisado. Por fim, foi gerada a matriz de confusão, com a ferramenta *Compute Confusion Matrix*.

3.6.5 Escolha do Modelo

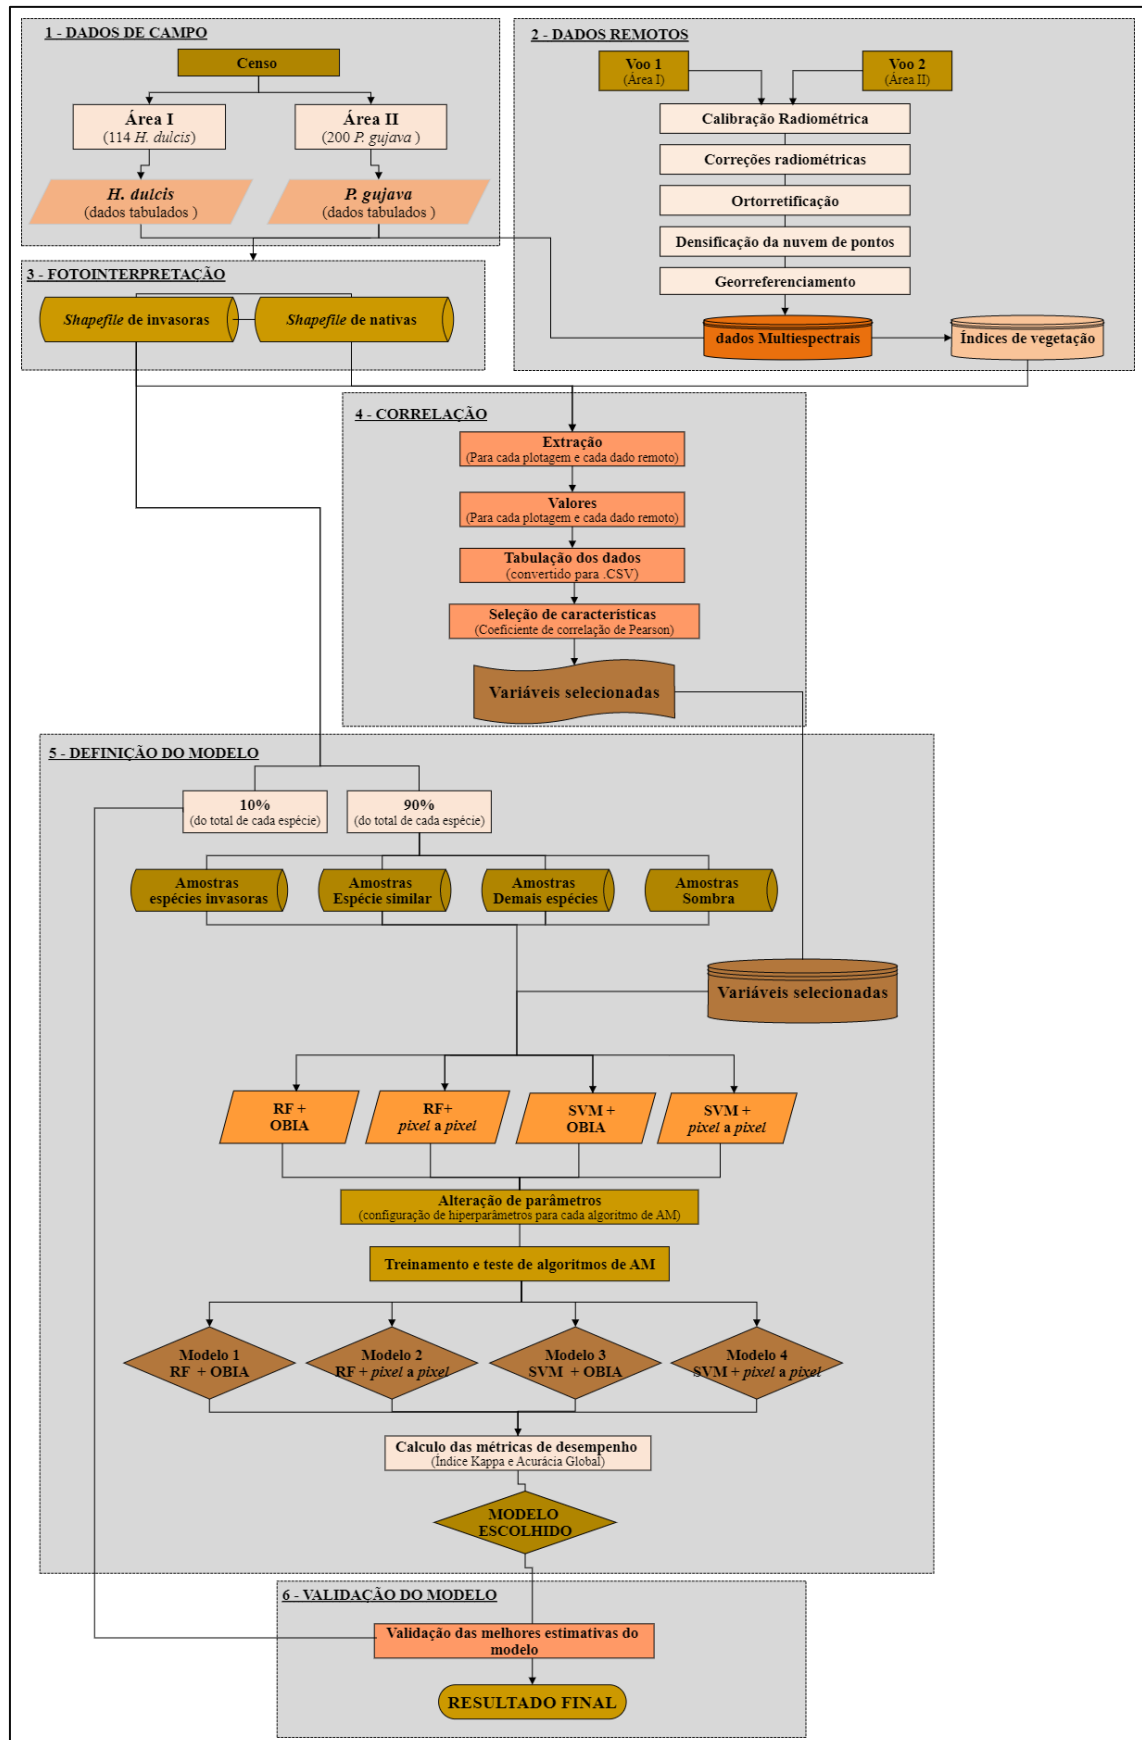
Os modelos de AM foram avaliados conjuntamente quanto à performance de ajuste aos dados de treinamento e teste, onde a qualidade dos ajustes foi avaliada a partir do critério: Percentual de acerto dos algoritmos nos dados teste. A Figura 10 e 11 mostra, de forma resumida, as principais etapas envolvidas na aquisição, tratamento e modelagem dos dados para as imagens RGB e multiespectrais, ao longo do desenvolvimento do trabalho.

Figura 10 - Sequência metodológica empregada na obtenção do modelo RGB para identificação de EFEI's *H. dulcis* e *P. guajava* no PEQC, RS, Brazil.



Fonte: Autora (2022).

Figura 11 - Sequência metodológica empregada na obtenção do modelo multispectral para identificação de EFEI's *H. dulcis* e *P. guajava* no PEQC, RS, Brazil.



Fonte: Autora (2022).

4 RESULTADOS E DISCUSSÃO

Para melhor compreensão dos resultados obtidos, eles vêm apresentados em duas formas: 1) Identificação da EFEI *Hovenia dulcis* e 2) Identificação da EFEI *Psidium guajava*.

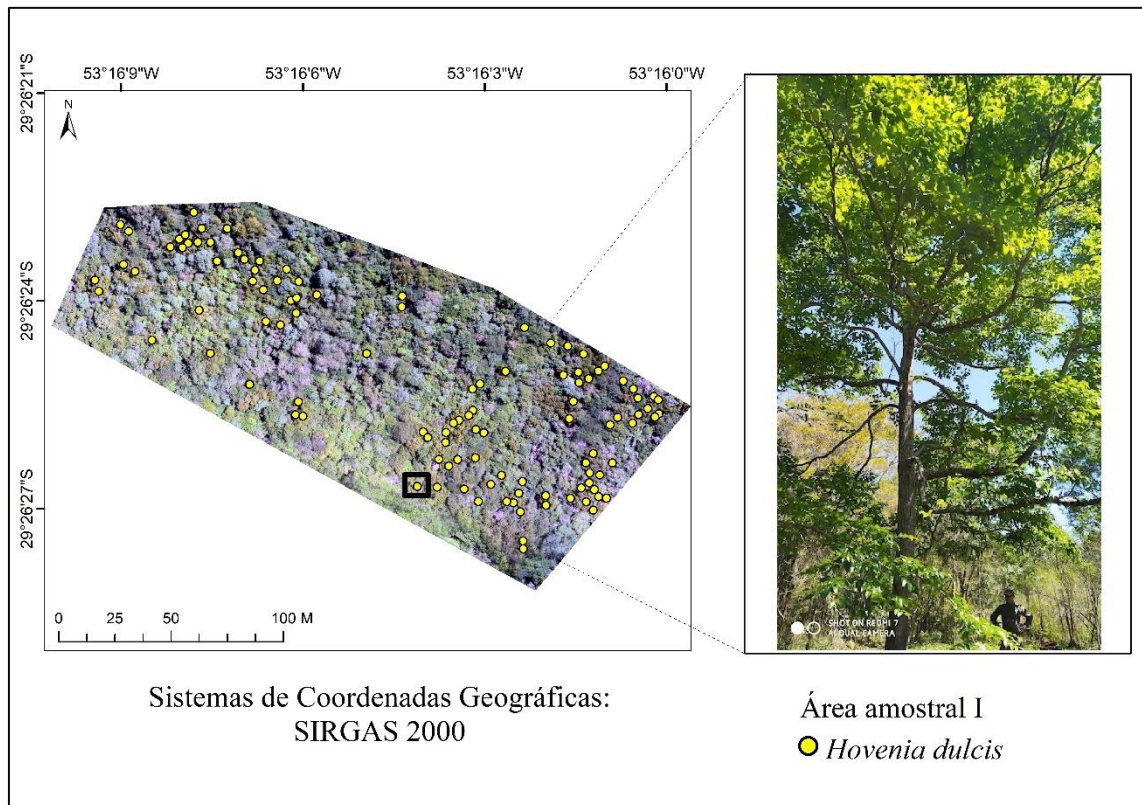
4.1 IDENTIFICAÇÃO DA ESPÉCIE FLORESTAL EXÓTICA INVASORA *Hovenia dulcis*

No levantamento de campo, foram inventariadas 114 árvores de *H. dulcis*, com DAP médio entre 14,43 cm e média da altura total estimada de 14,47 metros, distribuídas ao longo de toda a área amostral I. De acordo com Lima et al. (2015), populações desta espécie invasora estão presentes no interior de fragmentos florestais em diferentes estágios sucessionais, o que indica a sua alta capacidade de invasão.

Associa-se a invasão da EFEI na área de estudo a ação antrópica, principalmente pela região ter sido, em tempos anteriores, área de residência dos construtores da Usina Hidrelétrica de Dona Francisca. Como consequência da intervenção humana, tem-se a dispersão de sementes desses frutos e a dispersão zoocórica. Além disso, a espécie é tolerante à sombra na fase de plântula, possui potencial de invasão até mesmo no interior de florestas que apresentam menor abertura de dossel e de melhor conservação (DECHOUM et al., 2015).

Pode-se observar na Figura 12 que a maior parte da área amostral I está ocupada por diversas vegetações arbóreas, como foi constatado a campo, sendo, em sua maioria, espécies nativas da região. Porém, a invasora *H. dulcis*, tem sua ocorrência distribuída na área de forma aleatória, o que pode ser interpretado como um alto grau de invasão e dispersão. Este comportamento oferece oportunidade para estudos de comportamento espacial da espécie, com uso, por exemplo, de análise geoestatística ou processo pontual marcado, a fim de averiguar se existe ou não dependência espacial em sua distribuição, aparentemente aleatória nos dados deste trabalho.

Figura 12 – Representação da EFEI *hovenia dulcis* localizadas na área amostral I.

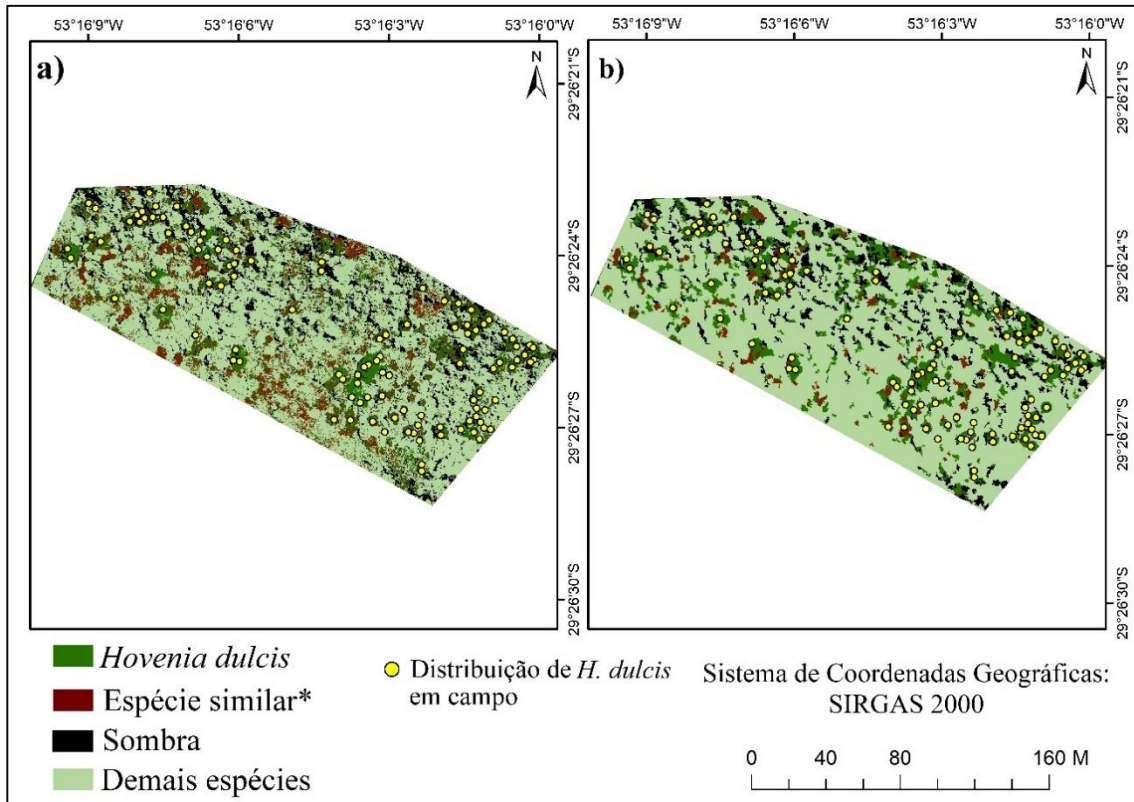


Fonte: Autora (2022).

Destaca-se que a presença da *H. dulcis* tem se tornado cada vez mais comum nesta tipologia florestal, uma vez que fatores como a facilidade de multiplicação por sementes e a frutificação consistente influenciam a sua grande dispersão, além de ser uma espécie bastante rústica e de rápido crescimento, o que compromete a disseminação e prejudica o desenvolvimento de espécies autóctones, a ponto de poder substituí-las devido sua agressividade e facilidade de adaptação (PIMENTEL et al., 2008).

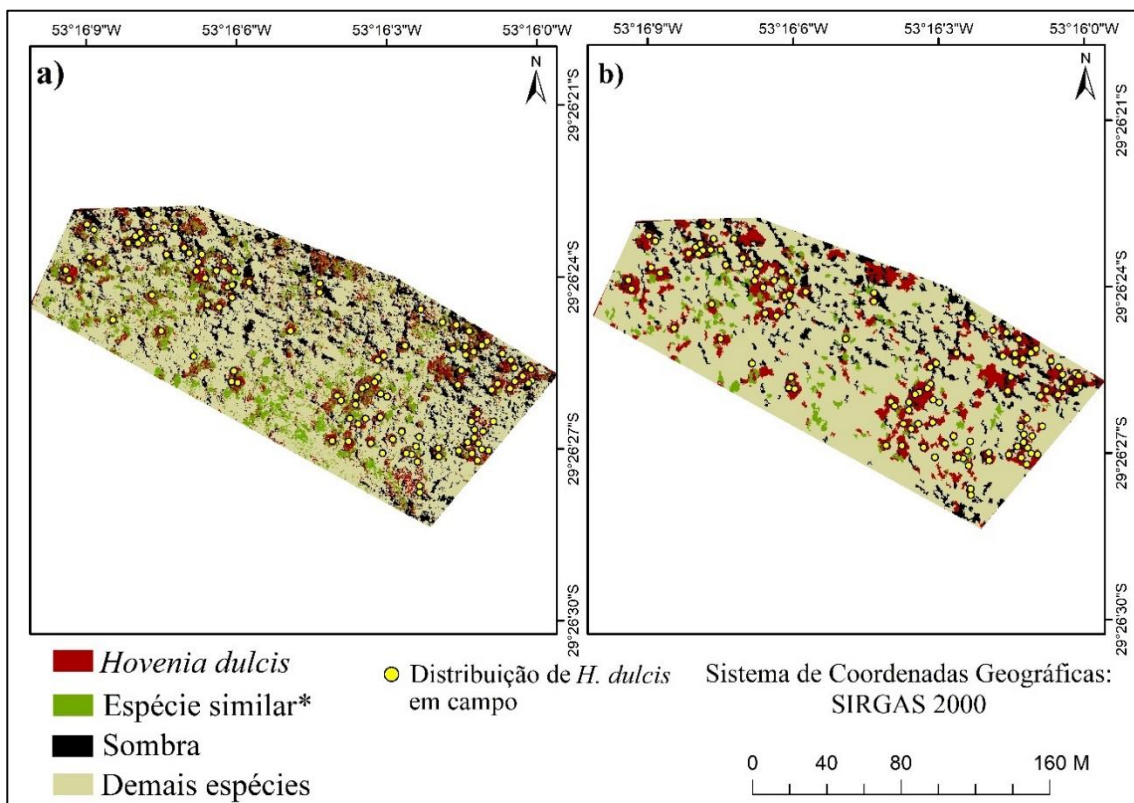
Quanto ao processo de classificação, é possível observar nas Figuras 13 (a, b) e 14 (a, b), o resultado desta, por meio dos algoritmos RF e SVM, nas abordagens *pixel a pixel* e OBIA.

Figura 13 - Resultado das classificações *pixel a pixel* (a) e OBIA (b), ambos com o algoritmo RF, para *H. dulcis* no PEQC, RS, Brasil.



*fotointerpretação visual de algumas espécies com resposta espectral semelhante a espécie alvo.
 Fonte: Autora (2022).

Figura 14 - Resultado da classificação *pixel a pixel* (a) e OBIA (b), ambos com o algoritmo SVM, para *H. dulcis* no PEQC, RS, Brasil.



*fotointerpretação visual de algumas espécies com resposta espectral semelhante a espécie alvo.
 Fonte: Autora (2022).

Ao analisar o desempenho dos dois métodos empregados, *pixel a pixel* e OBIA, não foram encontradas diferenças significativas, uma vez que, todos os valores de acurácia global obtidos foram acima de 85%. O menor valor de Kappa foi obtido com o classificador SVM no método OBIA, o que apesar de baixo, ainda é considerado um valor de exatidão muito bom, conforme o índice de concordância de Landis e Koch (1977). Na comparação entre os algoritmos de AM, o classificador RF apresentou resultados superiores ao SVM, nas duas abordagens, conforme constatado na Tabela 8.

Tabela 8 – Resultado dos valores de Acurácia global e Índice Kappa para as classificações realizadas a partir das abordagens *pixel a pixel* e OBIA para *H. dulcis* no PEQC, RS, Brasil.

Método	Algoritmo	Acurácia Global (%)	Índice Kappa
<i>Pixel a pixel</i>		91,5	0,87
OBIA	<i>Random Forest</i>	89,0	0,80
<i>Pixel a pixel</i>	<i>Support Vector Machine</i>	90,5	0,85
OBIA		87,0	0,77

Foi observado na matriz de confusão⁵, que houve grande mistura entre as classes “*Hovenia dulcis*” e “espécie similar”, principalmente no método *pixel a pixel*, para os dois algoritmos de AM. O maior valor de confusão entre essas classes já era previsto devido à similaridade espectral observada entre ambas no processo de fotointerpretação, o que vai de encontro ao afirmado por Novo (2008) e Ponzoni e Shimabukuro (2010), que destacam que as curvas de resposta espectral na vegetação, entre as espécies possuem características similares, definindo, em algumas condições fenológicas e morfológicas, confusão na diferenciação das espécies.

Na abordagem OBIA, ressalta-se que para a classe “espécie similar” a segmentação da imagem não foi precisa, criando objetos que a categorizaram tanto para a classe “*Hovenia dulcis*” ou para “demais espécies”. Dessa forma, poucas regiões da referida classe foram observadas no mapa de classificação, fator que pode ter gerado valores mais baixos para esse processo, quando gerada a matriz de confusão.

Para a classe “sombra” os dois métodos foram eficientes para categorizá-la, onde a melhor performance foi obtida com algoritmo RF, na abordagem *pixel a pixel*. Quanto a classe “demais espécies”, o algoritmo SVM apresentou um desempenho ligeiramente melhor que o RF, tanto para *pixel a pixel* quanto para OBIA.

⁵ Apêndice A

De modo geral, a interpretação visual das imagens resultantes e as análises de precisão indicaram que ambos os classificadores detectaram a EFEI *Hovenia dulcis* na área de pesquisa com um nível de precisão muito alto, ainda que, os melhores resultados foram obtidos com o algoritmo RF na classificação *pixel a pixel*.

As classificações produzidas usando abordagens *pixel a pixel* e OBIA criaram representações semelhantes e visualmente aceitáveis das classes estabelecidas na área de estudo. Conforme destacado por Stuckens et al. (2000), espera-se que as classificações baseadas em objeto ofereçam uma aparência visual mais generalizada e uma representação mais contígua da cobertura vegetal, o que talvez represente melhor a percepção da paisagem. Em alguns casos, a representação generalizada de classes produzida por OBIA pode ser responsável por uma aparente preferência por esse tipo de classificação, que apresentam desempenho ligeiramente melhor (DURO et al., 2012).

No entanto, no presente estudo, a região onde encontra-se a espécie *H. dulcis*, difere das características encontradas na área amostral II para a espécie *P. guajava*, observou-se que a ocorrência da EFEI *H. dulcis* acontece de forma aleatória e aparentemente sem agrupamentos, com indivíduos mais distantes uns dos outros, o que pode explicar melhor porque a análise baseada em objeto não foi tão precisa quanto a *pixel a pixel*.

Com relação aos algoritmos de AM, esses resultados também indicam que o classificador RF funciona melhor para a classificação de grandes formas espectralmente mais uniformes, mas que diferem significativamente de seus arredores, enquanto que o classificador SVM, mostra-se melhor para identificar espécies de plantas que são espectralmente menos similares (SABAT-TOMALA et al., 2020).

A confiabilidade dos métodos de AM também foi verificada no mapeamento de árvores invasoras em zonas ribeirinhas, realizada por Michez et al. (2016) com imagens obtidas por sensores embarcados em RPAS, adotando dados visíveis e NIR, onde recursos espectrais e de textura foram calculados em várias escalas e a variável mais relevante foi identificada com um modelo de classificação supervisionada, com base no algoritmo RF. Os melhores valores de precisão geral alcançaram 72%, 68% e 97% para *I. glandulifera*, *Knotweed* japonês e *H. mantegazzianum*, respectivamente.

Wessel et al. (2018) realizaram uma avaliação dos algoritmos RF e SVM em dados obtidos por sensores do satélite sentinel-2A, para a classificação de árvores caducas (abetos, faias e carvalhos) em duas regiões florestais na Alemanha. Os autores testaram o desempenho dos algoritmos em abordagem *pixel a pixel* e OBIA, para a separação de árvores de folhas largas e coníferas. Assim como observado na presente pesquisa, não foram encontradas diferenças

significativas na eficiência dos dois métodos de classificação, e dos algoritmos. A melhor precisão geral foi de 91% para OBIA, com o classificador SVM. Os autores relatam que o ajuste de hiperparâmetros teve impacto nos resultados da classificação e depende dos dados utilizados.

Indo ao encontro do presente estudo, Adam et al. (2014), utilizaram os classificadores RF e SVM no mapeamento de uso e cobertura da terra, utilizando imagens multiespectrais. Os autores relataram que os algoritmos obtiveram desempenho semelhantes, com uma precisão geral de classificação de 93,07% e 91,80% para RF e SVM, respectivamente. Huang et al. (2021), utilizaram dados hiperespectrais com os algoritmos RF e SVM para identificar a espécie invasora *Mikania micrantha* Kunth. Os autores alcançaram uma precisão de 88,71% para RF e 84,68% para o SVM.

A pesquisa realizada por Lima et al. (2019), utilizando parâmetros de classificação similares ao deste estudo para mapear a espécie invasora *H. dulcis*, encontraram resultados satisfatórios utilizando o algoritmo NN, em um remanescente florestal da Floresta Ombrófila Mista no estado de Santa Catarina, obtendo uma acurácia global de 82% e *Kappa* de 0,76.

Sabat-Tomala et al. (2020), compararam o desempenho dos algoritmos RF e SVM em identificar três espécies invasoras, *Rubus* spp., *Calamagrostis epigejos* e *Solidago* spp., em dados de um sensor hiperespectral aerotransportado. Em termos de precisão, os resultados indicaram melhor acurácia global (92%) e *Kappa* de 0,92, para o classificador RF, semelhantes aos encontrados nesse estudo.

4.1.1 Validação e seleção do modelo

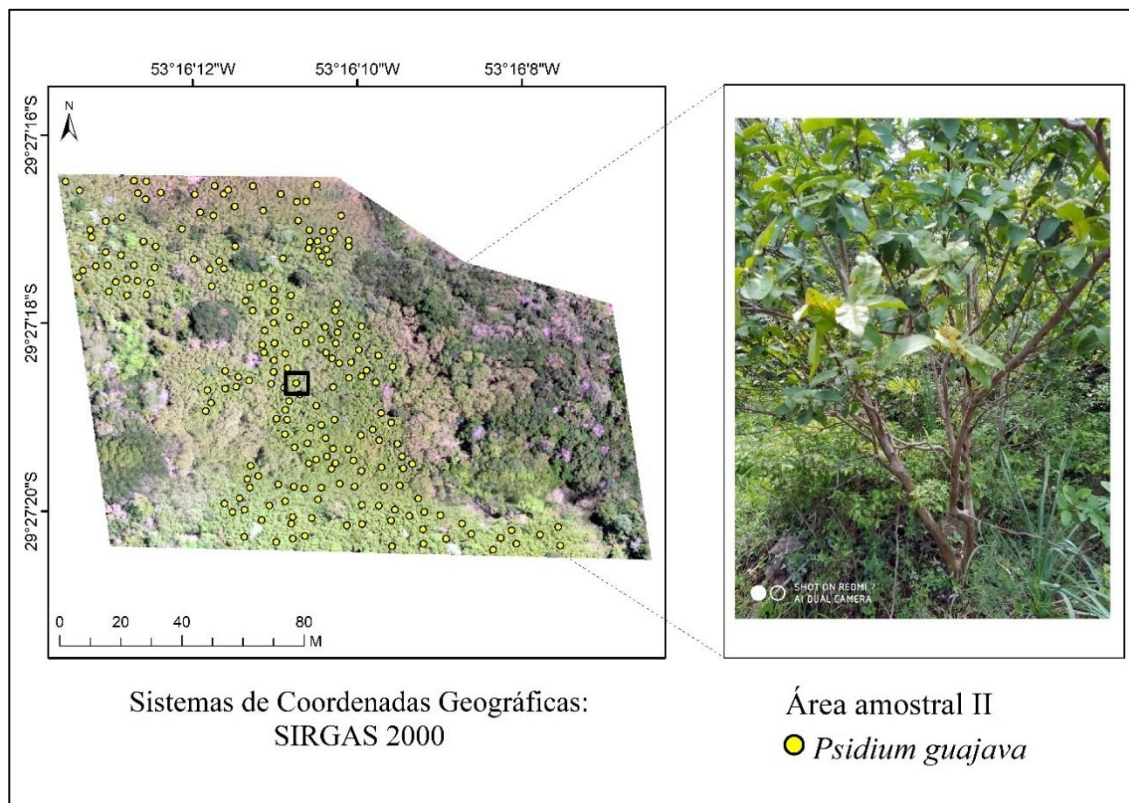
A separação dos conjuntos de treinamento e validação permitiu evitar a superestimação da precisão dos resultados, devido à correlação espacial de *pixels* do mesmo polígono de referência, a fim de minimizar a correlação espacial entre as amostras e para obter métricas de classificação precisas e imparciais. Dessa forma, o melhor modelo obtido para identificação da EFEI *Hovenia dulcis*, na respectiva área de estudo, foi a utilização do algoritmo *Random Forest* no método *pixel a pixel*, pois na etapa de validação, houve um acerto de 90,91% dos pontos geolocalizados que não foram utilizadas para treinamento e teste do modelo.

Este resultado vai de encontro ao que foi constatado com o conjunto de dados de treinamento, cujos melhores resultados também foram obtidos com o algoritmo RF, na classificação *pixel a pixel*.

4.2 IDENTIFICAÇÃO DA ESPÉCIE FLORESTAL EXÓTICA INVASORA *Psidium guajava*

No levantamento florístico de *P. guajava* realizado na área amostral II, foram inventariadas 200 árvores, com DAP médio de 10,72 cm e média da altura total estimada de 8,10 metros. Conforme pode ser observado na Figura 15, há uma ocupação superdominante da espécie, onde a maior parte da área está totalmente tomada pela EFEI, também sendo encontradas outras vegetações arbóreas nativas da região.

Figura 15 - Representação da EFEI *Psidium guajava* localizadas na área amostral II no PEQC, RS, Brasil.



Fonte: Autora (2022).

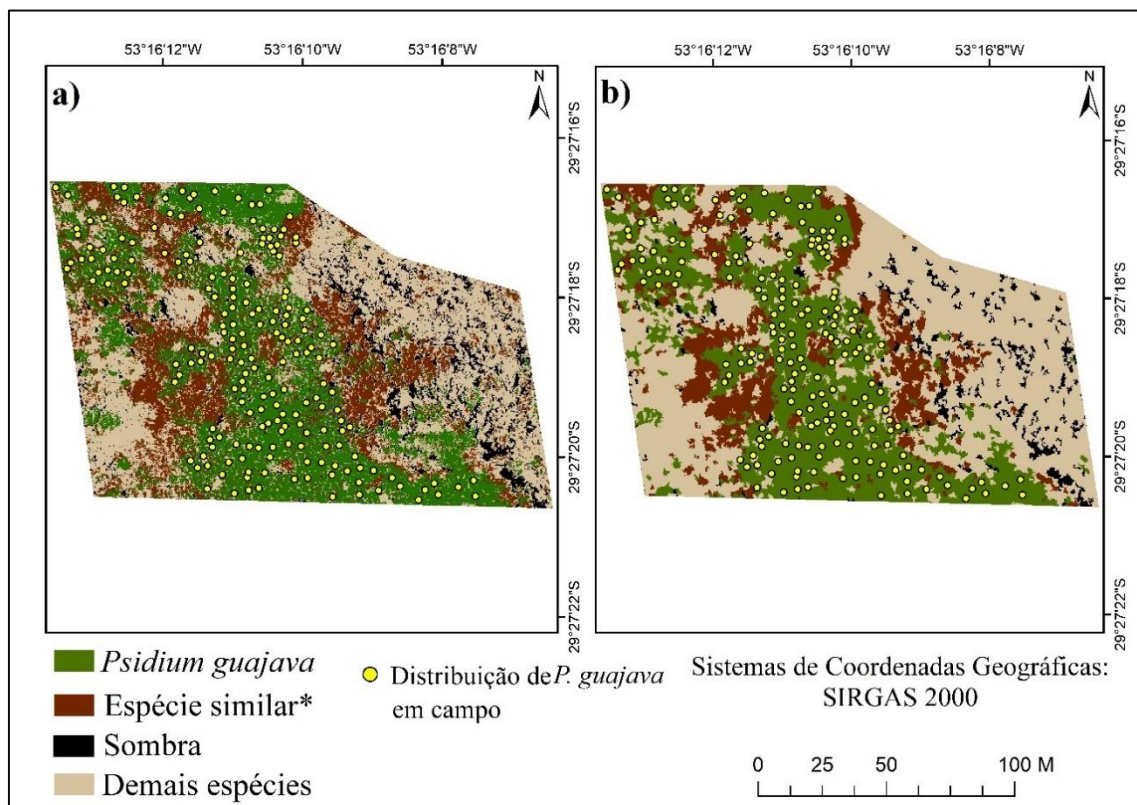
Assim como a invasora *H. dulcis*, a ocupação de *P. guajava* na área de estudo pode ser associada às alterações antrópicas causadas durante a construção da Usina hidrelétrica. Somado a isso, Zviejkovski et al. (2009) relatam que diante de um distúrbio antrópico, a área tende a ser ocupada por *P. guajava* e por demais EEI's, que se estabelecem e dificultam e/ou impedem o estabelecimento das espécies pioneiras e secundárias nativas de região, modificando o processo sucessional local.

O sucesso de dominância de *P. guajava* pode ser atribuído a combinação de rebrota e seu fruto comestível ser disperso por diversas aves, macacos, entre outros mamíferos, e até por insetos (DA SILVA et al., 2013). Em conjunto a sua excelente dispersão, a EFEI se estabelece

preferencialmente em áreas perturbadas, solos com boa umidade e locais mais abertos e iluminados como bordas de fragmentos florestais, tendo um impacto grande sobre a flora nativa devido ao sombreamento que provoca nas áreas por ela dominada (ZVIEJKOVSKI, et al. 2009).

Para a identificação de *P. guajava* na área amostral II, dotou-se de imagens providas de dois sensores distintos (RGB e multiespectral), e também, como foi realizado para a *H. dulcis*, testou-se os métodos de classificação *pixel a pixel* e OBIA, aplicando os algoritmos de AM. Os resultados obtidos estão apresentados nas Figuras 16 (a, b) e 17 (a, b), referentes às classificações utilizando os algoritmos RF e SVM.

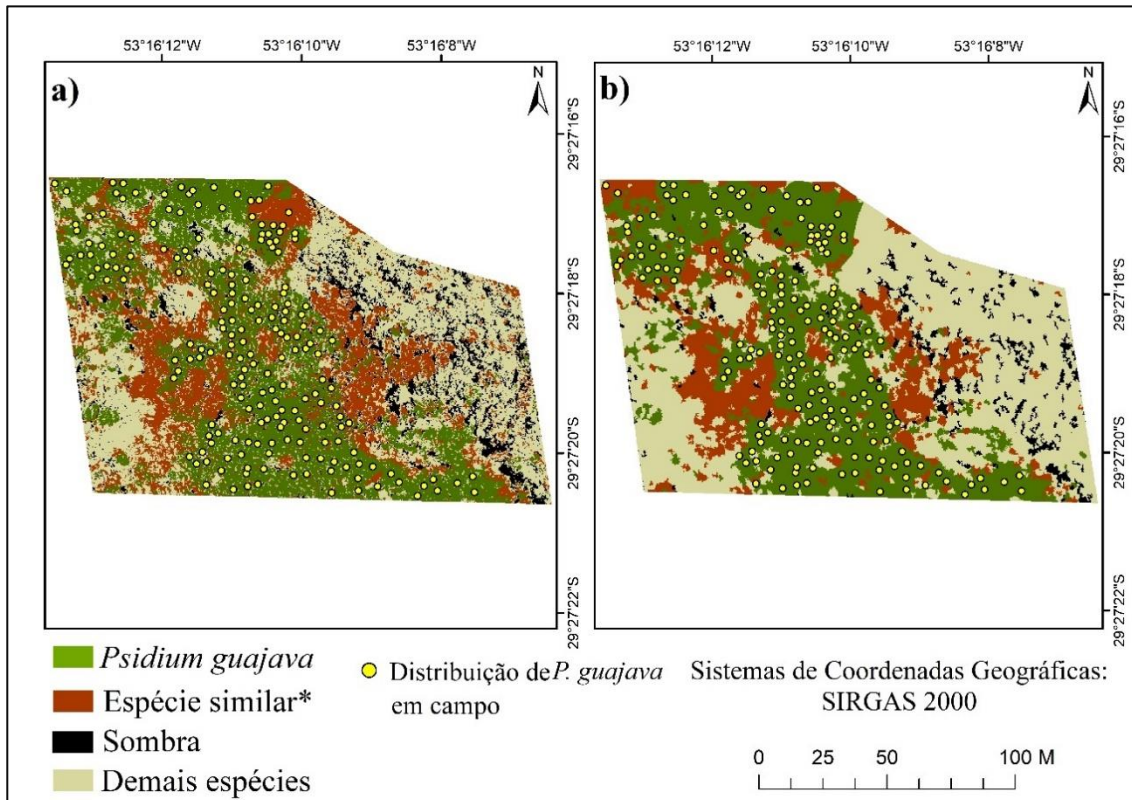
Figura 16 – Resultado da classificação *pixel a pixel* (a) e OBIA (b), ambos com o algoritmo RF utilizando a composição de imagens RGB, para *P. guajava* no PEQC, RS, Brasil.



*fotointerpretação visual de algumas espécies com resposta espectral semelhante a espécie alvo.

Fonte: Autora (2022).

Figura 17 - Resultado da classificação *pixel a pixel* (a) e OBIA (b), ambas om o algoritmo SVM utilizando a composição de imagens RGB, para *P. guajava* no PEQC, RS, Brasil.



*fotointerpretação visual de algumas espécies com resposta espectral semelhante a espécie alvo.

Fonte: Autora (2022).

Ao comparar os resultados das abordagens *pixel a pixel* e OBIA, assim como para *H. dulcis*, não houve diferença significativa no desempenho das classificações, onde todas as precisões foram acima de 85%. De modo geral, para o conjunto de dados de treinamento utilizados na composição RGB, os melhores resultados foram obtidos com o algoritmo RF, na classificação OBIA (Tabela 9), valor este considerado excelente conforme o índice de concordância de Landis e Koch (1977).

Tabela 9 - Resultado dos valores de Acurácia global e Índice Kappa para as classificações realizadas a partir das abordagens *pixel a pixel* e OBIA com a composição de imagens RGB para *P. guajava* no PEQC, RS, Brasil.

Método	Algoritmo	Acurácia Global (%)	Índice Kappa
<i>Pixel a pixel</i>	Random Forest	86,5	0,81
OBIA		92,5	0,89
<i>Pixel a pixel</i>	Support Vector Machine	87,5	0,82
OBIA		88,0	0,82

Observa-se que para o método *pixel a pixel*, para os dois algoritmos de AM, os valores de Kappa e acurácia global foram menores em relação a OBIA, o que de acordo com análise da

matriz de confusão⁶, está relacionado principalmente aos equívocos cometidos pelos algoritmos ao rotular as classes “*psidium guajava*” e “espécie similar”. Essa confusão, conforme destacado por Schowengerdt (2007), pode ser atribuída ao efeito de mistura espectral, em que cada *pixel* pode conter mais de uma classe na sua dimensão espacial, incorrendo em divergências entre a classificação de um *pixel* e a sua referência. Por outro lado, as curvas de resposta espectral entre espécies de vegetação possuem características similares, definindo, em algumas condições fenológicas e morfológicas, confusão na discriminação das espécies de vegetação (NOVO, 2008).

As classificações *pixel a pixel* e OBIA, foram eficientes em categorizar a classe “sombra”, não ocorrendo atribuições a outras classes quando observada a matriz de confusão. Para a classe “demais espécies”, o algoritmo RF apresentou um melhor desempenho que SVM, nas duas abordagens.

Mafanya et al. (2017) compararam métodos de classificação *pixel a pixel* e OBIA para identificar a EEI *Harrisia pomanensis* por meio de imagens RGB obtidas sensor embarcado em RPAS. Os autores também compararam algoritmos classificadores baseados em *pixels* não supervisionados (k-medida e Distância Euclidiana), algoritmo baseado em objeto não supervisionado (Iseog), algoritmo supervisionado baseado em *pixel* (Maxver) e algoritmo baseado em objeto supervisionado (Bhattacharya). Os melhores resultados foram semelhantes ao encontrados neste estudo, utilizando algoritmo baseado em objeto Bhattacharya, que apresentou acurácia global de 95,7%, e foi recomendado para o mapeamento da EEI.

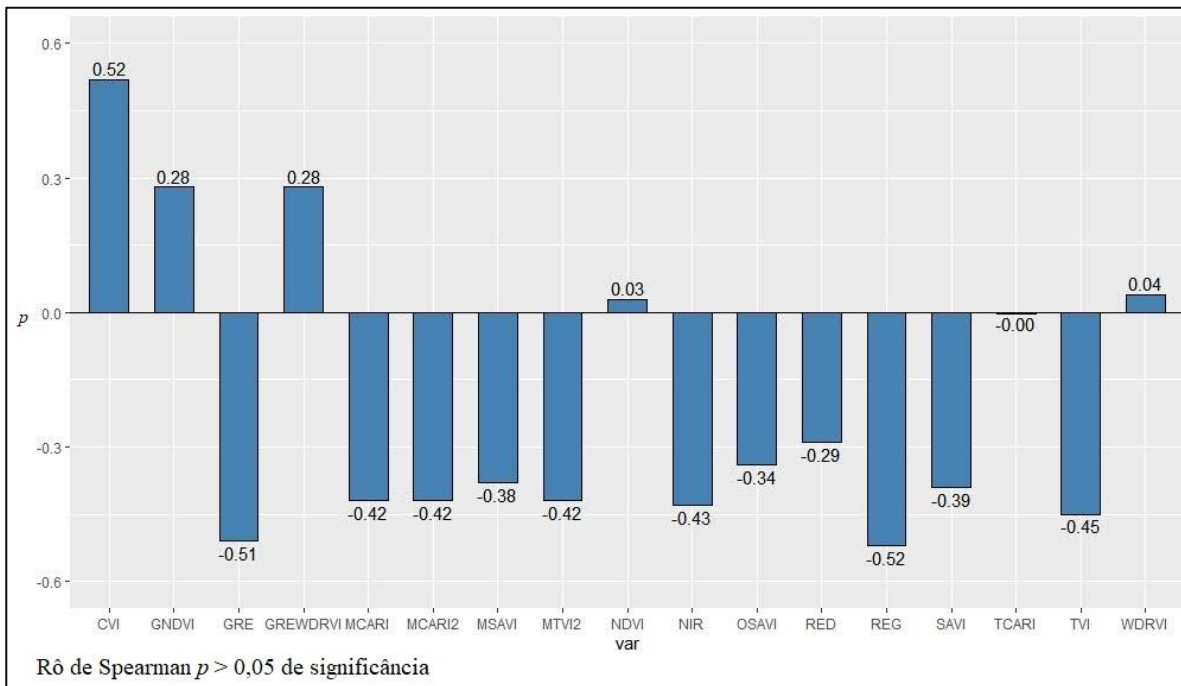
Kattenborn et al. (2020), utilizaram imagens RGB adquiridas por sensor/RPAS para identificar espécies invasoras em florestas e áreas abertas. Os autores aplicaram o algoritmo CNN para mapear as EEI’s *Pinus radiata* e *Ulex europaeus* no Chile, obtendo precisões consideradas excelentes (R^2 0,85), tal que também relatam que as precisões preditivas usando CNN e imagens RGB baseadas em sensor/RPAS, as quais possuem baixa resolução espectral e alta resolução espacial, são de alto valor para o mapeamento da vegetação.

Quanto ao resultado do processo de seleção das variáveis de entrada do modelo, as correlações das 17 variáveis utilizadas para otimizar a classificação e identificação de *P. guajava* estão apresentados na Figura 18. Observa-se que, dos 13 IV calculados, cinco apresentaram altos valores de correlação com a variável resposta (*P. guajava*), no entanto, devido ao SIG *ArcGis Pro* limitar a entrada de uma imagem *raster* composta por somente três bandas, a composição multispectral foi feita a partir dos maiores valores de correlação obtidos,

⁶ Apêndice B

sendo estes o IV: *Chlorophyll Vegetation Index* (CVI), seguido das bandas espectrais *Red Edge* e *Green*, denominadas, respectivamente de “REG” e “GRE”. Dessa forma, foi utilizada a composição dessas imagens, durante as etapas de classificação. Para melhor apresentação dos resultados, a composição de bandas REG, GRE e CVI foi denominada de RGCV.

Figura 18 – Resultado da correlação de *Spearman* entre os preditores e as variáveis respostas relacionadas a espécie invasora *Psidium guajava* no PEQC, RS, Brasil.



Fonte: Autora (2022).

Ao analisar o resultado da classificação utilizando a composição de imagens RGCV, foi observado uma performance superior a RGB, tanto a nível de abordagens (*pixel a pixel* e OBIA), quanto ao desempenho dos algoritmos RF e SVM. Isso pode ser atribuído ao uso da banda espectral *Red-Edge*, uma vez que é uma região na zona de transição RED-NIR do espectro de refletância da vegetação e marca a fronteira entre a absorção pela clorofila na região vermelha visível e o espalhamento devido à estrutura interna da folha na região NIR (FILELLA e PANUELAS, 1994). A banda *Red-Edge* também é afetada por parâmetros bioquímicos e biofísicos, sendo sensível a diferentes níveis de clorofila presentes nas folhas (HATFIELD et al., 2008). Assim, mudanças no conteúdo de clorofila podem gerar grandes diferenças de refletância e transmitância das folhas, as quais podem ajudar a separar diferentes classes de vegetação no processo de mapeamento (SOUZA et al., 2015), assim como demonstra bons resultados para extração de informação em nível de dossel (GHOLIZADEH et al., 2016).

Além disso, a banda verde (*green*) também possui relevância nesse sentido, pois no estudo realizado por Rex et al. (2016), que investigaram análise derivativa de dados de

reflectância para caracterização de espécies arbóreas das famílias Myrtaceae, Fabaceae e Rutaceae, a espécie *P. guajava* apresentou maior fator de reflectância sobretudo na região do verde (entre 500 e 600 nm). Kaffer et al. (2016) obtiveram resultados semelhantes também para a família Myrtaceae, que apresentaram um padrão que pode ser caracterizado pela baixa reflectância na região do azul e do vermelho, e elevada na região do verde. Coura et al. (2005), ressaltam que as mudanças espectrais nas folhas devido ao estresse fisiológico alteram a resposta espectral tanto na região visível, quanto na faixa do NIR, o que pode explicar também os melhores resultados obtidos com esta composição de imagens.

Outro fator significativo pode ser atrelado à adição de um IV a composição de bandas, uma vez que estes índices são uma maneira de inferir sobre as condições da vegetação, como estágios fenológicos, concentração de clorofila nas folhas, assim como visam realçar as variações de densidade da cobertura vegetal (HUETE et al., 1997; PONZONI e SHIMABUKURO, 2010), além de atenuar os efeitos da interação da radiação com o alvo, melhorando o resultado de uma classificação.

De modo geral, no conjunto de dados de treinamento da composição de imagens RGCV, os melhores resultados foram obtidos com o algoritmo RF, na abordagem OBIA, alcançando uma acurácia global de 93% e índice Kappa de 0,90, considerado excelente de acordo com Landis e Koch (1977), como pode ser observado na Tabela 10.

Tabela 10 - Resultado dos valores de Acurácia global e Índice Kappa para as classificações realizadas a partir das abordagens *pixel a pixel* e OBIA, com a composição de imagens RGCV, para *P. guajava* no PEQC, RS, Brasil.

Método	Algoritmo	Acurácia Global (%)	Índice Kappa
<i>Pixel a pixel</i>		92,0	0,89
OBIA	<i>Random Forest</i>	93,0	0,90
<i>Pixel a pixel</i>		89,0	0,84
OBIA	<i>Support Vector Machine</i>	92,5	0,89

Com a composição de imagens multiespectrais, observou-se uma menor confusão entre as classes “*Psidium guajava*” e “espécie similar”, mesmo para a abordagem *pixel a pixel*, o que pode explicar os melhores resultados obtidos com essa composição⁷. De acordo com o estudo de Wessel et al. (2018), o uso da banda *Red-Edge* do satélite sentinel-2, mostrou diferenças nos perfis espectrais da vegetação, o que pode ter contribuído também para os melhores resultados a partir da composição multiespectral. Esse fato pode estar associado, também, ao deslocamento da borda do vermelho próximo ao azul (*blue-shift of red-edge*) com referência ao deslocamento

⁷ Apêndice C

do gradiente da transição entre o vermelho e o NIR na direção aos menores comprimentos de onda, perceptível na curva da resposta espectral da vegetação.

Assim como para observado para a composição RGB, os dois métodos de classificação foram eficientes em categorizar a classe “sombra”. Para a classe “demais espécies”, o algoritmo RF apresentou um desempenho ligeiramente melhor que SVM, tanto para *pixel a pixel* quanto OBIA.

Estes resultados são semelhantes aos encontrados por De Luca et al. (2019), que investigaram a eficiência dos algoritmos RF e SVM para classificar de imagens multiespectrais de alta resolução, obtidas por sensor/RPAS, em uma abordagem baseada em objeto. Os autores obtiveram um nível de precisão muito alto para ambos os classificadores, com valores de coeficiente Kappa de 0,97 para RF e de 0,93 para SVM.

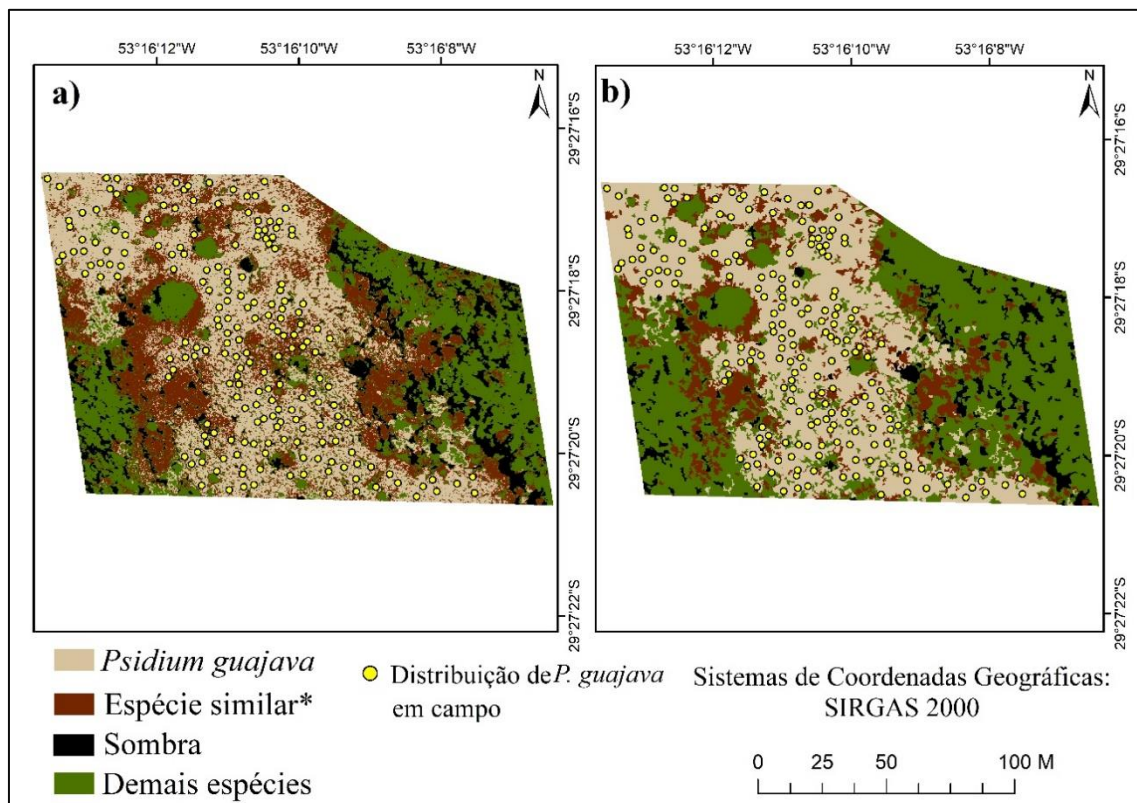
Immitzer et al. (2012), utilizaram o algoritmo RF em comparação entre abordagens *pixel a pixel* e OBIA para classificar diferentes espécies de árvores em uma floresta temperada, com dados de altíssima resolução espacial. Os autores relatam que ao classificar objetos em vez de *pixels*, as precisões podem ser aumentadas significativamente para a maioria das espécies de árvores, e obtiveram precisão geral de 82% na classificação de 10 espécies de árvores, onde a abordagem OBIA superou a classificação *pixel a pixel*, indo de encontro aos resultados encontrados nesse estudo.

Por sua vez, Li et al. (2015), utilizaram o método OBIA, empregando os algoritmos SVM e RF para mapear espécies de árvores em área urbana, com imagens de alta resolução. Os autores alcançaram resultados semelhantes, onde o SVM apresentou precisão geral de 92,4 % e Kappa de 0,89, e para o RF, uma acurácia global de 90,2% e índice Kappa de 0,85, onde nota-se, também, que os resultados indicam que as precisões entre os dois algoritmos são muito próximas.

Conforme Jensen et al. (2020), mesmo os produtos de dados multiespectrais, podem ter dificuldade em detectar plantas que exibem características semelhantes às de seus arredores. No geral, os resultados são melhores ao usar produtos multiespectrais em vez de apenas ópticos. Em seu estudo, os autores aplicaram diversos algoritmos de AM, como RF, SVM e NN, para identificar a espécie invasora Kudzu, utilizando imagens multiespectrais do satélite Sentinel-2, e hiperespectrais do sensor AVIRIS. O algoritmo RF se mostrou excelente para a detecção da espécie invasora nos dois conjuntos de dados, apresentando *Kappa* de 0,91 e 0,85 respectivamente. O classificador SVM, por sua vez, apresentou índice *Kappa* de 0,95 e 0,70, mostrando um melhor desempenho com dados do sensor multiespectral, mas ainda satisfatórios para a detecção da invasora.

É importante frisar que, há pouca literatura referente a identificação ou mapeamento da espécie invasora *P. guajava* com a utilização de dados provenientes de SR. Entretanto, destaca-se a espécie *Psidium cattleianum*, nativa da região Sul do Brasil, a qual é semelhante a *P. guajava*, sendo da mesma família *Myrtaceae*, é considerada invasora em florestas Havaianas, onde Barbosa et al. (2016), utilizaram espectroscopia de imagem aerotransportada de alta resolução, para mapear áreas invadidas pela espécie. Os autores analisaram o desempenho de duas estruturas de classificação: *Biased Support Vector Machine* (BSVM) e *Mixture Tuned Matched Filtering* (MTMF). A abordagem BSVM se mostrou eficiente em detectar o grau de invasão de *P. cattleianum* na área de estudo. As Figuras 19 (a, b) e 20 (a, b) ilustram a distribuição das classes temáticas, para as abordagens *pixel a pixel* e OBIA, e os classificadores RF e SVM.

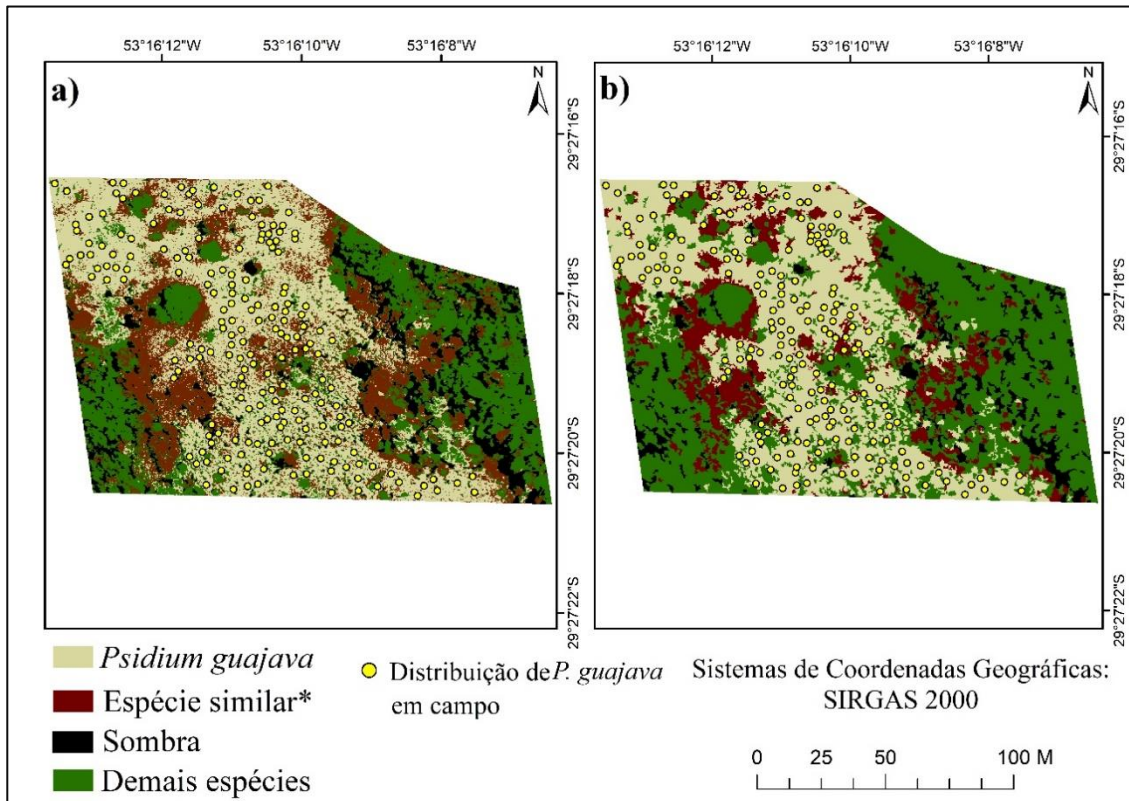
Figura 19 - Resultado da classificação *pixel a pixel* (a) e OBIA (b), ambas com o algoritmo RF utilizando a composição de imagens RGCV para *P. guajava* no PEQC, RS, Brasil.



*fotointerpretação visual de algumas espécies com resposta espectral semelhante a espécie alvo.

Fonte: Autora (2022).

Figura 20 - Resultado da classificação pixel a pixel (a) e OBIA (b), ambas com o algoritmo SVM utilizando a composição de imagens RGCV para *P. guajava* no PEQC, RS, Brasil.



*fotointerpretação visual de algumas espécies com resposta espectral semelhante a espécie alvo.

Fonte: Autora (2022).

Indo ao encontro do presente estudo, Fassnacht et al. (2016) destacam a alta relevância que as bandas visíveis possuem na identificação da vegetação, principalmente pela absorção de pigmentos fotossintéticos de clorofila a e b, entretanto, a análise da imagem RGB de forma isolada não é aconselhável, em vez disso, uma combinação de bandas infravermelhas e visíveis leva a alta precisão para classificações de árvores de folhas largas a partir de imagens de alta resolução. Este fato está relacionado à largura das bandas na imagem RGB, diferente das multiespectrais que possuem faixa estreita. Somado a isso, o uso de sensores com alta e altíssima resolução espacial, são extremamente importantes para obter maior precisão o que facilita o estudo, na escala submétrica, que possibilita distinguir árvores individuais e dosséis pequenos.

4.2.1 Validação e seleção do modelo

Além da precisão da classificação, também foi observado o resultado das amostras de validação para avaliar o desempenho dos algoritmos de AM em classificar corretamente a espécie *P. guajava*, a partir da composição de imagens RGB e RGCV. Dessa forma, foram selecionados os modelos que apresentaram melhores resultados nos dados de teste.

Para a composição RGB, o melhor resultado obtido foi utilizando o classificador RF, na abordagem OBIA, com 96,33% de acerto, o que condiz com os resultados de acurácia global e Kappa obtidos nos dados de treinamento. Do mesmo modo, para a composição RGCV, o modelo selecionado, indo de encontro ao resultado de acurácia e índice Kappa dos dados de treinamento, foi o obtido com o algoritmo RF na classificação OBIA, com 100% de acerto.

Nota-se que, tanto para os dados de treinamento quanto aos dados de teste, para as duas composições de imagens o desempenho do algoritmo RF foi superior ao SVM, nos dois métodos utilizados. A abordagem baseada em objeto mostrou-se excelente em conjunto ao algoritmo RF para identificar a EFEI *P. guajava*, levando em consideração também, as precisões excelentes obtidas com a composição multiespectral.

Contudo, foram observadas pequenas diferenças de desempenho quanto a utilização dos algoritmos de AM nos dois modelos obtidos, mesmo com melhor resultado na composição RGCV. Dessa forma, levando em consideração também o conjunto de dados de treinamento, para identificação da EFEI *P. guajava*, o modelo obtido com o uso de imagens multiespectrais (composição RGCV), é mais eficiente e robusto em classificar a invasora.

5 CONSIDERAÇÕES FINAIS

O desenvolvimento tecnológico para monitorar com precisão EFEI's em áreas protegidas pode desempenhar um importante papel no monitoramento e conservação dos ecossistemas florestais.

O algoritmo RF forneceu as melhores precisões para identificação das duas espécies florestais exóticas invasoras em todos os modelos testados.

A abordagem OBIA apresentou melhores resultados para a classificação de *P. guajava*, enquanto que para a espécie *H. dulcis*, as melhores precisões foram alcançadas a partir do método *pixel a pixel*.

A composição das bandas *Red Edge* e *Green* em combinação com o índice de vegetação CVI, demonstrou ser mostrou-se excelente em diferenciar padrões da EFEI *P. guajava*, com as maiores exatidões nos modelos gerados.

Dessa forma, o estudo realizado pode ser considerado importante na identificação das EFEI's *Hovenia dulcis* e *Psidium guajava* em floresta estacional decidual, na região Sul do Brasil, com um fluxo de trabalho simplificado para o monitoramento de áreas protegidas com a presença dessas espécies.

Salienta-se que o presente estudo pode ser incorporado na etapa inicial da criação do Plano de Manejo Florestal da UC, para uso de controle e erradicação das EFEI's, uma vez que

fornece dados acurados para a espacialização e contagem desses indivíduos.

Por fim, ressalta-se a importância de novos estudos a partir dos dados disponíveis, onde poderia ser realizado um *Upscalling* com imagens de satélites de alta resolução espacial e bandas multiespectrais, para monitoramento e quantificação dessas EFEI's em todo o interior do PEQC.

REFERÊNCIAS

- AASEN, H. et al. Generating 3D hyperspectral information with lightweight UAV snapshot cameras for vegetation monitoring: From camera calibration to quality assurance. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 108, p. 245–259, 2015.
- ABREU, K. M. P. DE; COUTINHO, L. M. Remote sensing applied to the study of vegetation with emphasis on index of vegetation and landscapes metrics. **Revista Vértices**, v. 16, n. 1, p. 173–198, 2014.
- ADAM, E. et al. Land-use/cover classification in a heterogeneous coastal landscape using RapidEye imagery: Evaluating the performance of random forest and support vector machines classifiers. **Int. J. Remote Sens**, v. 35, p. 3440–3458, 2014.
- ADELINO, J. R. P. et al. The economic costs of biological invasions in Brazil: a first assessment. **NeoBiota**, v. 67, p. 349, 2021.
- ALMEIDA, A.; CARVALHO, F.; MENINO, F. **Introdução ao Machine Learning**. 1^a ed. 2020. Disponível em: <https://dataat.github.io/introducao-ao-machine-learning/>
- ALMEIDA, D. R. A. et al. Monitoring the structure of forest restoration plantations with a drone-lidar system. **International Journal of Applied Earth Observation and Geoinformation**, v. 79, n. December 2018, p. 192–198, 2019.
- ALPAYDIN, E. **Introduction to Machine Learning**. MIT press, 2020.
- ALVARES, C. A. et al. Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, n. 6, p. 711-728, 2013.
- ALVEAR, J. O. **Arboles de decision y random forest**. 2018.
- ArcGIS for Desktop. **Segment Mean Shift**. Disponível em: <<http://desktop.arcgis.com/en/arcmap/10.3/tools/spatial-analyst-toolbox/segment-mean-shift.htm>>. Acesso em: 30 de julho de 2021.
- BARBOSA, J. M.; ASNER, G. P.; MARTIN, R. E.; BALDECK, C. A.; HUGHES, F.; JOHNSON, T. Determining Subcanopy *Psidium cattleianum* Invasion in Hawaiian Forests Using Imaging Spectroscopy. **Remote Sensing**, v. 8, p. 33, 2016.
- BARETH, G. et al. Feasibility study of using non-calibrated UAV-based RGB imagery for grassland monitoring: Case study at the Rengen Long-term Grassland Experiment (RGE), Germany. **DGPF Tagungsband**, v. 24, p. 55–62, 2015.
- BELLARD, C. et al. Insights from modeling studies on how climate change affects invasive alien species geography. **Ecology and Evolution**, v. 8, n. 11, p. 5688-5700, 2018.
- BIAU, G.; SCORNET, E. A random forest guided tour. **TEST**. v. 25, p. 197–227, 2016.

BILAR, A. B. C., de MENDONÇA P., R. M.; CERQUEIRA, M. Monitoramento da cobertura vegetal através de índices biofísicos e gestão de áreas protegidas. **Geosul**, v. 33, n. 68, p. 236-259, 2018

BISHOP, C. M. **Pattern Recognition and Machine Learning**. Springer-Verlag, 2007.

BONIFACIO, E. et al. Alien red oak affects soil organic matter cycling and nutrient availability in low-fertility well-developed soils. **Plant and Soil**, v. 395, n. 1–2, p. 215–229, 2015.

BRADLEY, B. A. Remote detection of invasive plants: A review of spectral, textural and phenological approaches. **Biological Invasions**, v. 16, n. 7, p. 1411–1425, 2014.

BRANDTBERG, T.; WALTER, F. Automated delineation of individual tree crowns in high spatial resolution aerial images by multiple-scale analysis. **Machine Vision and Applications**, v. 11, n. 2, p. 64-73, 1998.

BRASIL. **Decreto Federal nº 4.339 de 22 de agosto de 2002**. Institui princípios e diretrizes para a implementação da Política Nacional da Biodiversidade. PUBLICADO NO DOU em 23/08/2002. Disponível em: <http://www.planalto.gov.br/ccivil_03/decreto/2002/D4339.htm> Acesso em: 26 de julho de 2020.

BRASIL. **Lei nº 9.605, de 12 de fevereiro de 1998**. Dispõe sobre as sanções penais e administrativas derivadas de condutas e atividades lesivas ao meio ambiente, e dá outras providências. Diário Oficial [da] República Federativa do Brasil, Poder Executivo, Brasília, DF, 13 fev. 1998. Seção 1, p. 1. Disponível em: <http://www.planalto.gov.br/ccivil_03/leis/19605.htm> Acesso em: 26 de julho de 2020.

BRASIL. Ministério do Meio Ambiente. **Unidades de Conservação: O que são**. Brasília, 2019. Disponível em: Ministério do Meio Ambiente. <<https://www.mma.gov.br/areasprotegidas/unidades-de-conservacao/o-que-sao.html>> Acesso em 18 de março de 2021.

BRASIL. Ministério do Meio Ambiente. **SNUC – Sistema Nacional de Unidades de Conservação da Natureza: Lei nº 9.985, de 18 de julho de 2000**. Regulamenta o art. 225, § 1º, incisos I, II, III e VII da Constituição Federal, institui o Sistema Nacional de Unidades de Conservação da Natureza e dá outras providências. Disponível em: <http://www.planalto.gov.br/ccivil_03/leis/19985.htm> Acesso em: 26 de julho de 2020

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

CALLEGARO, R. M.; ARAÚJO, M. M.; LONGHI, S. J. Fitossociologia de agrupamentos em floresta estacional decidual no Parque Estadual Quarta Colônia, Agudo-RS. **Revista Brasileira de Ciências Agrárias**, v. 9, n. 4, p. 590-598, 2014.

CALVARIO, G. et al. A multi-disciplinary approach to remote sensing through low-cost UAVs. **Sensors (Switzerland)**, v. 17, n. 6, 2017.

CARTER, G. A. et al. Remote sensing and mapping of tamarisk along the Colorado river, USA: a comparative use of summer-acquired Hyperion, Thematic Mapper and QuickBird data. **Remote Sensing**, v. 1, n. 3, p. 318-329, 2009.

CARVALHO, A. B. P. et al. Uma espécie asiática invade a paisagem do sul do Brasil. **Revista Memória em Rede**, v. 11, n. 20, p. 166, 2019.

CARVALHO, I. S. et al. Classificação Da Vegetação Do Parque Nacional Da Chapada Das Mesas, Maranhão, Usando Obia, Machine Learning e Softwares Livres. **Anais do XIX Simpósio Brasileiro de Sensoriamento Remoto**, p. 2984–2987, 2019.

CARVALHO, P.E. R. **Ecologia, silvicultura e usos da uva-do-japão (*Hovenia dulcis Thunberg*)**. Circular Técnica n° 23, Embrapa. CNP-Florestas. Colombo, PR, 1994. ISSN 0101-1847.

CASTANHEIRA, N. P. **Estatística aplicada a todos os níveis**. 1 ed. InterSaberes, 2013.

CDB – CONVENÇÃO SOBRE A DIVERSIDADE BIOLÓGICA. Ministério do meio ambiente. **Decreto Legislativo n° 02, de 5 de junho de 1992 - Convenção sobre a Diversidade Biológica**. 32p, Brasília, 1992. Disponível em: <https://www.mma.gov.br/estruturas/sbf_dpg/_arquivos/cdbport.pdf> Acesso em: 26 de julho de 2020.

COLOMINA, I.; MOLINA, P. Unmanned aerial systems for photogrammetry and remote sensing: A review. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 92, p. 79–97, 2014.

COMANICIU, D.; MEER, P. Mean shift: A robust approach toward feature space analysis. **IEEE Trans. Pattern Anal. Mach. Intell.** v. 24, p. 603-619, 2002.

COMISSÃO EUROPEIRA. **Towards an EU Strategy on Invasive Species Communication**. Commission of the European Communities. Brussels, 2008. Disponível em: <https://ec.europa.eu/environment/nature/invasivealien/docs/1_EN_ACT_part1_v6.pdf> Acesso em: 25 de julho de 2020.

CORDERO, L. R. et al. Invasive gorse (*Ulex europaeus*, Fabaceae) changes plant community structure in subtropical forest–grassland mosaics of southern Brazil. **Biological Invasions**, v. 18, n. 6, p. 1629–1643, 2016.

CORTES, C.; VAPNIK, V.; SAITTA, L. Support-Vector Networks Editor. **Machine Learning**. Kluwer Academic Publishers, 1995.

COURA, S. M. C. et al. Comparação das características espectrais das espécies *Ligustrum japonicum* Thunb. e *Cassia macranthera* DC. **In: Anais do XII Simpósio Brasileiro de Sensoriamento Remoto**, Goiânia, INPE, p. 1477-1484. 2005.

CRISP – CENTRE FOR REMOTE IMAGING, SENSING AND PROCESSING. **Spatial resolution and pixel size**. 2015. In: FORMAGGIO, A. R.; SANCHES, I. D. Sensoriamento remoto em agricultura. Oficina de Textos, 2017.

CRONK Q. C. B.; FULLER J. L. **Plant invaders: the threat to natural ecosystems**. London, UK: Chapman & Hall, 1995.

CULVENOR, D. S. TIDA: An algorithm for delineation of tree crowns in high spatial resolution remotely sensed imagery. **Computers & Geosciences**, v. 28, n. 1, p. 33-44, 2002.

CUNLIFFE, A. M.; BRAZIER, R. E.; ANDERSON, K. Ultra-fine grain landscape-scale quantification of dryland vegetation structure with drone-acquired structure-from-motion photogrammetry. **Remote Sensing of Environment**, v. 183, p. 129–143, 2016.

DA SILVA, J. C. B. et al. Dispersão por aves de *Psidium guajava* L. (Myrtaceae) em ambiente ripário na bacia do rio Paraná, Brasil. **Semina: Ciências Biológicas e da Saúde**, v. 34, n. 2, p. 195-204, 2013.

DASH, J. P. et al. Early detection of invasive exotic trees using UAV and manned aircraft multispectral and LiDAR Data. **Remote Sensing**, v. 11, n. 15, p. 1–21, 2019.

DASH, J. P. et al. Assessing very high resolution UAV imagery for monitoring forest health during a simulated disease outbreak. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 131, p. 1-14, 2017.

DAUGHTRY, C. S. T. et al. Estimating corn leaf chlorophyll concentration from leaf and canopy reflectance. **Remote sensing of Environment**, v. 74, n. 2, p. 229-239, 2000.

DE LUCA, G. et al. Object-based land cover classification of cork oak woodlands using UAV imagery and Orfeo ToolBox. **Remote Sensing**, v.11, n.10, p. 1238, 2019.

DE SÁ, N. C. et al. Mapping the flowering of an invasive plant using unmanned aerial vehicles: Is there potential for biocontrol monitoring? **Front Plant Sci.** v. 9, p. 1-13, 2018.

DECHOUM, M. S. et al. Invasions across secondary forest successional stages: effects of local plant community, soil, litter, and herbivory on *Hovenia dulcis* seed germination and seedling establishment. **Plant ecology**, v. 216, n. 6, p. 823-833, 2015.

DEUR, M.; GAŠPAROVIĆ, M.; BALENOVIĆ, I. Tree species classification in mixed deciduous forests using very high spatial resolution satellite imagery and machine learning methods. **Remote Sensing**, v. 12, n. 23, p. 1–18, 2020.

DIXON, B.; CANDADE, N. Multispectral landuse classification using neurais networks and support vector machines: one or the other, or both? **International Journal Remote Sensing**. v. 29, p. 1185–1206, 2008.

DJI. **Phantom 4 PRO**. User Manual, 2020. Disponível em:
<<https://www.dji.com/br/phantom-4-pro>> Acesso em: 15 de janeiro de 2021.

DOS SANTOS, R. C.; ANTUNES, L. D. B. Espécies exóticas invasoras na arborização urbana de vias públicas de Sananduva - RS. **REVSBAU**, v. 12, n. 2, p. 39–47, 2017.

DRAKE, J.A. **Handbook of Alien Species in Europe**. Springer, Berlin, 2009.

DURO, D. C.; FRANKLIN, S. E.; DUBÉ, M. G. A comparison of pixel-based and object-based image analysis with selected machine learning algorithms for the classification of

agricultural landscapes using SPOT-5 HRG imagery. **Remote sensing of environment**, v. 118, p. 259-272, 2012.

EASTMAN, J. R.; IDRISI, T. **Guide to GIS and image processing**. Clark Labs, Clark University, Worcester, MA, 2009.

EMBRAPA. Centro Nacional de Pesquisa de Solos. **Sistema Brasileiro de Classificação de Solos**. Brasília: Embrapa -SPI; Rio de Janeiro: Embrapa Solos, 2018. 5ª ed. 355p.

ESRI. **ArcGIS Pro ESRI Student Program**. Disponível em: <<https://learn-arcgis-learnings.hub.arcgis.com/pages/access-arcgis-software>>. Acesso em: 5 de maio de 2021.

ESRI. **Arcgis Professional Gis for the desktop, Version 10.8**. environmental Systems Research Institute, 2016. Disponível Em: <https://www.esri.com/arcgis-blog/products/arcgis-enterprise/3d-gis/arcgis-10-4-is-here/?Rmedium=Redirect&Rsource=Blogs.Esri.Com/Esri/Arcgis/2016/02/18/Arcgis-10-8-Is-Here>

ESTEVEZ, R. S.; LORENA, A. C.; ZANCHETTA, M. Aplicação de técnicas Aprendizado de Máquina na Classificação de Imagens Mamográficas. **II Simpósio de Iniciação Científica da Universidade Federal do ABC**, p. 1–3, 2009.

EUGENIO, F. C. 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. 8238-8266, 2021a.

EUGENIO, F. C. et al. Remotely piloted aircraft systems and forests: A global state of the art and future challenges. **Canadian Journal of Forest Research**, v. 50, n. 8, p. 705–716, 2020.

EUGENIO, F. C. et al. Remotely Piloted Aircraft Systems to Identify Pests and Diseases in Forest Species: The Global State of the Art and Future Challenges. **IEEE Geoscience and Remote Sensing Magazine**, p. 2-15, 2021b.

FARIAS, J. A. C. et al. Estrutura fitossociológica de uma Floresta Estacional Decidual na região de Santa Maria, RS. **Ciência Florestal**, v. 4, p. 109-128, 1994.

FASSNACHT, F.E.; et al. Review of studies on tree species classification from remotely sensed data. **Remote Sens. Environ**, v. 186, p. 64–87, 2016.

FENG, Q.; LIU, J.; GONG, J. UAV Remote sensing for urban vegetation mapping using random forest and texture analysis. **Remote Sensing**. v. 7, p. 1074-1094, 2015.

FILELLA, I.; PANUELAS, J. The red edge position and shape as indicators of plant chlorophyll content, biomass and hydric status. **International Journal of Remote Sensing**. v. 15, p. 1459 -1470, 1994

FILGUEIRAS, T.S., BROCHADO, A.L., NOGUEIRA, P.E. & GUALLA II, G.F. 1994. **Caminhamento - Um método expedito para levantamentos florísticos qualitativos**. In: Caderno de Geociência IBGE. 12: 39-43.

FLORENZANO, T. G. **Iniciação em Sensoriamento Remoto**. São Paulo: Oficina de Textos, 2007.

FOODY, G. M.; MATHUR, A. A relative evaluation of multiclass image classification by support vector machines. **IEEE Transactions on Geoscience and Remote Sensing**, v. 42, n. 6, p. 1335-1343, 2004.

FORMAGGIO, A. R.; SANCHES, I. D. **Sensoriamento remoto em agricultura**. Oficina de Textos, 2017.

FUKUNAGA, K.; HOSTETLER, L. The estimation of the gradient of a density function, with applications in pattern recognition. **IEEE Transactions on Information Theory**, v. 21, n. 1, p. 32–40, 1975.

FUREY, C. et al. The importance of native and exotic plant identity and dominance on decomposition patterns in mountain woodlands of central Argentina. **Acta Oecologica**, v. 54, p. 13–20, 2014.

GENTLEMAN, R.; CAREY, V.J. Unsupervised Machine Learning. **Bioconductor Case Studies**, p. 137–157, 2008.

GERHKE, R. J. **Desenvolvimento e calibração de piranômetros de baixo custo**. 2016. 51p. Projeto Integrador (curso técnico em Meteorologia). Instituto Federal de educação, ciência e tecnologia de Santa Catarina - IFSC, Florianópolis – SC, 2016.

GHOLIZADEH, A.; MIŠUREC, J.; KOPAČKOVÁ, V.; MIELKE, C.; ROGASS, C. Assessment of red-edge position extraction techniques: A case study for norway spruce forests using hmap and simulated sentinel-2 data. **Forests**, v. 7, n. 10, p. 226, 2016.

GISP. **Invasive alien species and protected areas A scoping report, part I**. The global invasive species programme. 93 p, 2007. Disponível em:
<http://www.issg.org/pdf/publications/gisp/resources/ias_protectedareas_scoping_i.pdf.
Acesso em: 22 de mar. de 2021.

GITELSON, A. A. Wide dynamic range vegetation index for remote quantification of biophysical characteristics of vegetation. **Journal of plant physiology**, v. 161, n. 2, p. 165-173, 2004.

GITELSON, A.; MERZLYAK, M. N. Spectral reflectance changes associated with autumn senescence of *Aesculus hippocastanum* L. and *Acer platanoides* L. leaves. Spectral features and relation to chlorophyll estimation. **Journal of plant physiology**, v. 143, n. 3, p. 286-292, 1994.

GUIMARÃES, N. et al. Forestry remote sensing from unmanned aerial vehicles: A review focusing on the data, processing and potentialities. **Remote Sensing**, v. 12, n. 6, p. 1046, 2020.

GUO, Q. et al. An integrated UAV-borne lidar system for 3D habitat mapping in three forest ecosystems across China. **International Journal of Remote Sensing**, v. 38, n. 8–10, p. 2954–2972, 2017.

GUREVITCH, J.; SCHEINER, S.M.; FOX, G.A. **Ecologia vegetal**. 2 ed, 2009. Tradução: Getun, F. et al. Porto Alegre. Artmed. 592pag. ISBN 978-85.363-1918-6.

HABOUDANE, D. et al. Hyperspectral vegetation indices and novel algorithms for predicting green LAI of crop canopies: Modeling and validation in the context of precision agriculture. **Remote sensing of environment**, v. 90, n. 3, p. 337-352, 2004.

HABOUDANE, D. et al. Integrated narrow-band vegetation indices for prediction of crop chlorophyll content for application to precision agriculture. **Remote sensing of environment**, v. 81, n. 2-3, p. 416-426, 2002.

HATFIELD, J. L.; GITELSON, A. A.; SCHEPERS, J. S.; WALTHALL, C. L. Application of Spectral Remote Sensing for Agronomic Decisions. **Agronomy Journal**, v. 100, p.117, 2008.

HELMER, E. H. et al. Characterizing tropical forests with multispectral imagery. **Land Resources Monitoring, Modeling, and Mapping with Remote Sensing**, p. 3–22, 2015.

HONKAVAARA, E. et al. Processing and assessment of spectrometric, stereoscopic imagery collected using a lightweight UAV spectral camera for precision agriculture. **Remote Sensing**, v. 5, n. 10, p. 5006–5039, 2013.

HUANG, Y. B. et al. Development and prospect of unmanned aerial vehicle technologies for agricultural production management. **International Journal of Agricultural and Biological Engineering**, v. 6, n. 3, p. 1–10, 2013.

HUANG, Y.; et al. Hyperspectral Imaging for Identification of an Invasive Plant Mikania micrantha Kunth. **Frontiers in Plant Science**, v. 12, p. 787, 2021.

HUETE, A. R. A soil-adjusted vegetation index (SAVI). **Remote sensing of environment**, v. 25, n. 3, p. 295-309, 1988.

HUETE, A. R. et al. A comparison of vegetation indices over a global set of TM images for EOS-MODIS. **Remote Sensing of Environment**, v. 59, n. 3, p. 440–451, 1997.

ICMBIO. Instituto Chico Mendes de Conservação de Biodiversidade. **Relação de UC com Plano de Manejo**. Brasília, 2014. Disponível em: www.icmbio.gov.br/portal/biodiversidade/unidades-de-conservacao/planos-de-manejo/listaplano-de-manejo.html. Acesso em: 25 de julho de 2020.

IMMITZER, M.; ATZBERGER, C.; KOUKAL, T. Tree Species Classification with Random Forest Using Very High Spatial Resolution 8-BandWorldView-2 Satellite Data. **Remote Sensing**, v. 4, n. 9, p. 2661-2693, 2012.

INSTITUTO HÓRUS. Instituto Hórus de Desenvolvimento e Conservação Ambiental. **Base de dados nacional de espécies exóticas invasoras**. I3N Brasil, Florianópolis – SC, 2021. Disponível em: i3n.institutohorus.org.br. Acesso em: 25 outubro de 2021.

IUCN. **Guidelines for the Prevention of biodiversity loss caused by alien invasive species**.

Gland, Switzerland: IUCN Species Survival Commission, **Iucn**, n. February, p. 25, 2000.

JAMES, K.; BRADSHAW, K. Detecting plant species in the field with deep learning and drone technology. **Methods in Ecology and Evolution**, v. 11, n. 11, p. 1509-1519, 2020.

JENSEN, J. R. **Introductory digital image processing: A remote sensing perspective**, University of South Carolina, 2015

JENSEN, J. R. **Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres**. Tradução José Carlos Neves Epiphânio (coord.) [et al]. São José dos Campos: Parêntese, 2009. 598 p.

JENSEN, T. et al. Employing machine learning for detection of invasive species using Sentinel-2 and AVIRIS data: the case of Kudzu in the United States. **Sustainability**, v. 12, n. 9, p. 3544, 2020.

KÄFER, P. S. et al. Caracterização espectral e NDVI de espécies florestais das famílias Fabaceae, Myrtaceae, Rutaceae e Salicaceae. **Enciclopédia Biosfera**. v. 13, n. 23, p. 62, 2016.

KATTENBORN, T. et al. UAV data as alternative to field sampling to map woody invasive species based on combined Sentinel-1 and Sentinel-2 data. **Remote Sensing of Environment**, v. 227, p. 61–73, 2019.

KATTENBORN, T. et al. Convolutional Neural Networks accurately predict cover fractions of plant species and communities in Unmanned Aerial Vehicle imagery. **Remote Sens. Ecol.** v. 6, p. 472-486, 2020.

KAUFMAN, D. **A inteligência artificial irá suplantar a inteligência humana?** Estação das Letras e Cores. 1ª ed, 2019.

KIM, W.; KANEZAKI, A.; TANAKA, M. Unsupervised Learning of Image Segmentation Based on Differentiable Feature Clustering. **IEEE Transactions on Image Processing**, v. 29, p. 8055-8068, 2020.

LANDIS, J.; KOCH, G. G. The measurements of agreement for categorical data. **Biometrics**, v.33, n.3, p.159-179, 1977.

LARY, D. J. et al. Machine learning in geosciences and remote sensing. **Geoscience Frontiers**, v. 7, n. 1, p. 3–10, 2016.

LAURIERE, J. L. **Problem-solving and artificial intelligence**. Prentice Hall, 1990.

LECHNER, A. M.; FOODY, G. M.; BOYD, D. S. Applications in Remote Sensing to Forest Ecology and Management. **One Earth**, v. 2, n. 5, p. 405–412, 2020.

LEHMANN, J. R. K. et al. Analysis of unmanned aerial system-based CIR images in forestry- a new perspective to monitor pest infestation levels. **Forests**, v. 6, n. 3, p. 594–612, 2015.

LI, D. et al. Object-based urban tree species classification using bi-temporal WorldView-2

and WorldView-3 images. **Remote Sensing**, v. 7, n. 12, p. 16917-16937, 2015.

LI, S. Wildfire early warning system based on wireless sensors and unmanned aerial vehicle. **Journal of Unmanned Vehicle Systems**, v. 7, n. 1, p. 76-91, 2018.

LIMA, C. L. et al. Detecção da espécie exótica invasora *Hovenia dulcis* por meio de classificação supervisionada. **Brazilian Journal of Development**, v. 7, n. 5, p. 44110-44127, 2021

LIMA, D. R. M. et al. Detecção de espécie invasora na floresta ombrófila mista por meio de classificação orientada ao objeto. In: Anais do XIX Simpósio Brasileiro de Sensoriamento Remoto, 2019, Santos. **Anais...** Campinas, GALOÁ, 2019. Disponível em: <<https://proceedings.science/sbsr-2019/papers/deteccao-de-especie-invasora-na-floresta-ombrofila-mista-por-meio-de-classificacao-orientada-ao-objeto>> Acesso em: 20 de setembro de 2021.

LIMA, R. E. M. et. al. Native seed dispersers may promote the spread of the invasive Japanese raisin tree (*Hovenia dulcis* Thunb.) in seasonal deciduous forest in southern Brazil. **Tropical Conservation Science**. v. 8 Issue 3, p. 846-862. 2015.

LIN, Y.; HYYPPÄ, J.; JAAKKOLA, A. Mini-UAV-borne LIDAR for fine-scale mapping. **IEEE Geoscience and Remote Sensing Letters**, v. 8, n. 3, p. 426–430, 2011.

LÓPEZ-SERRANO, P. M. et al. Uma comparação de técnicas de aprendizado de máquina aplicadas aos dados espectrais do Landsat-5 TM para estimativa de biomassa. **Canadian Journal of Remote Sensing**, v. 42, n. 6, p. 690-705, 2016.

LU, H. et al. Segmentation of high spatial resolution remote sensing images of mountainous areas based on the improved mean shift algorithm. **Journal of Mountain Science**, v. 2, n.3, p. 671–681, 2015.

MA, L. et al. A review of supervised object-based land-cover image classification. **ISPRS J. Photogramm. Remote Sensing**, v. 130, p. 277–293, 2017.

MACHADO, V. P. **Inteligência artificial**. Universidade Federal do Piauí, 2011.

MAFANYA, M. et al. Evaluating pixel and object based image classification techniques for mapping plant invasions from UAV derived aerial imagery: *Harrisia pomianensis* as a case study. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 129, p. 1-11, 2017.

MALENOVSKÝ, Z. et al. Unmanned aircraft system advances health mapping of fragile polar vegetation. **Methods Ecol Evol**. v. 8, p. 1842-1857, 2017.

MALLMANN, C. L.; PRADO, D. A; FILHO, W. P. Índice de vegetação por diferença normalizada para caracterização da dinâmica florestal no parque estadual Quarta Colônia, estado do Rio Grande do Sul - Brasil. **Revista Brasileira de Geografia Física**, v. 8, n. 5, p. 1275–1291, 2015.

MALLMANN, C. L. **Espectroscopia de campo para a discriminação de espécies exóticas invasoras e nativas em floresta subtropical**. 2021. 134 p. Dissertação (Mestrado em

Geografia) - Universidade Federal de Santa Maria, Santa Maria, RS, 2021.

MCGEOCH, M. A. et al. Global indicators of biological invasion: Species numbers, biodiversity impact and policy responses. **Diversity and Distributions**, v. 16, n. 1, p. 95–108, 2010.

MCNEELY, J. A. et al. **A global strategy on invasive alien species: synthesis and ten strategic elements Invasive alien species: a new synthesis**. Island Press, Washington, DC, 2005.

MEDVECKÁ, J. et al. Forest habitat invasions – Who with whom, where and why. **Forest Ecology and Management**, v. 409, n. June 2017, p. 468–478, 2018.

MENEZES, P.; ALMEIDA, T. 2012. **Introdução ao processamento de Imagens de Sensoriamento Remoto**. UNB. Brasília. 2012. pag. 276

MICHEZ, A. et al. Mapping of riparian invasive species with supervised classification of Unmanned Aerial System (UAS) imagery. **Int. J. Appl. Earth Obs. Geoinf**, v. 44, p. 88–94, 2016.

MICHIE, D.; SPIEGELHALTER, D. J.; TAYLOR, C. C. **Machine Learning, Neural and Statistical Classification**. Ellis Horwood, Upper Saddle River, NJ, USA, 1994.

MIELKE, E. C. et al. Espécies exóticas invasoras arbóreas no parque da barreirinha em Curitiba: registros e implicações. **Ciência Florestal**, Santa Maria, v. 25, n. 2, p. 327–336, 2015.

MING, D. et al. Scale parameter selection by spatial statistics for GeOBIA: Using mean-shift based multi-scale segmentation as an example. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 106, p. 28–41, 2015.

MINISTÉRIO DO MEIO AMBIENTE – MMA, 2006. **Espécies exóticas invasoras: situação brasileira**. 24 p. ISBN 85-7738-019-X. Disponível em: <
https://www.mma.gov.br/estruturas/174/_publicacao/174_publicacao17092009113400.pdf>
Acesso em: 26 de julho de 2020.

MINISTÉRIO DO MEIO AMBIENTE – MMA, 2009. **Resolução CONABIO nº 05, de 21 de outubro de 2009**. Dispõe sobre a Estratégia Nacional sobre Espécies Exóticas Invasoras. Disponível em: <
https://www.mma.gov.br/estruturas/conabio/_arquivos/resoluo_conabio05_estrategia_32a_nacional_especies_exticas_invasoras_15.pdf> Acesso em: 26 de julho de 2020.

MISSIO., F. DE F.; LONGHI., S. J. Composição arbórea da floresta estacional decidual em relação a heterogeneidade ambiental no rebordo do planalto meridional, RS. **Agrarian Academy**, v. 6, n. 12, p. 15, 2019.

MOHAN, M. et al. Individual tree detection from unmanned aerial vehicle (UAV) derived canopy height model in an open canopy mixed conifer forest. **Forests**, v. 8, n. 9, p. 1–17, 2017.

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

MOUNTRAKIS, G.; IM, J.; OGOLE, C. Support vector machines in remote sensing: A review. **ISPRS Journal Photogrammetry Remote Sensing**, v. 66, p. 247-259, 2011.

MUCHONEY, D. M. Earth observations for terrestrial biodiversity and ecosystems. **Remote Sensing of Environment**, v. 112, n. 5, p. 1909–1911, 2008.

MÜLLEROVÁ, J. et al. Unmanned aircraft in nature conservation: an example from plant invasions. **International Journal of Remote Sensing**, v. 38, n. 8–10, p. 2177–2198, 2017.

MÜLLEROVÁ, J.; PERGL, J.; PYŠEK, P. Remote sensing as a tool for monitoring plant invasions: Testing the effects of data resolution and image classification approach on the detection of a model plant species *Heracleum mantegazzianum* (giant hogweed). **International Journal of Applied Earth Observation and Geoinformation**, v. 25, p. 55-65, 2013.

NOVO, E. **Sensoriamento Remoto: princípios e aplicações**. 3. ed. São Paulo: Blucher, 2008.

PÁDUA, L. et al. UAS, sensors, and data processing in agroforestry: a review towards practical applications. **International Journal of Remote Sensing**, v. 38, n. 8–10, p. 2349–2391, 2017.

PAL, M.; MATHER, P. M. Support vector machines for classification in remote sensing. **International Journal Remote Sensing**, v. 26, p. 1007–1011, 2005.

PANDA, S. S. et al. Remote Sensing Systems—Platforms and Sensors: Aerial, Satellite, UAV, Optical, Radar, and LiDAR. In: THENKABAIL, P. S. (Ed.). **Remotely Sensed Data Characterization, Classification, and Accuracies**. Boca Raton, FL: CRC Press, 2015. p. 3–57.

PAZ-KAGAN, T. et al. Multispectral Approach for Identifying Invasive Plant Species Based on Flowering Phenology Characteristics. **Remote Sensing**, v. 11, n. 8, p. 953, 2019.

PEDRALI, L. D. **Aplicação de sensor multiespectral a bordo de vant na determinação de graus de severidade de *erwinia psidii* em *eucalyptus urograndis***. 2017. 92 p. Dissertação (mestrado em engenharia florestal). Universidade Federal de Santa Maria – UFSM, Santa Maria – RS, 2017.

PEDRON, F. A. et al. Morfologia e Classificação Taxonômica de Neossolos e Saprólitos derivados de rochas vulcânicas da Formação Serra Geral no Rio Grande do Sul. **Revista Brasileira de Ciência do Solo**, v. 33, n. 1, p.119-128, 2009.

PEDRON, F. A.; DALMOLIN, R. S. D. Solos da região do rebordo do Planalto Meridional no Rio Grande do Sul. In: SCHUMACHER, M. V.; LONGHI S. J.; BRUN, E. J.; KILCA, V. R. (Eds.) **A Floresta Estacional Subtropical - caracterização e ecologia no Rebordo do Planalto Meridional**. Santa Maria: Editora Palloti, 2011. p. 33-51

PENONI, L. H. et al. Utilização do sensoriamento remoto na avaliação do antropismo NO Parque Nacional Da Serra da Canastra-MG. **Os Desafios da Geografia Física na Fronteira do Conhecimento**, v. 1, p. 5126-5136, 2017.

PIMENTEL, A. et al. Fitossociologia do sub-bosque do Parque Ambiental Rubens Dallegrave, Irati, PR. **Floresta**, Curitiba, v. 38, n. 3, p. 479-486, 2008.

PIMENTEL, D. et al. Economic and environmental threats of alien plant, animal, and microbe invasions. **Agriculture, Ecosystems and Environment**, v. 84, n. 1, p. 1–20, 2001.

PONZONI, F. J.; SHIMABUKURO, Y. E. **Sensoriamento Remoto no estudo da Vegetação**. ed. 2010. São Paulo: Oficina de textos, 2010. 131 p.

POULIOT, D. A. et al. Automated tree crown detection and delineation in high-resolution digital camera imagery of coniferous forest regeneration. **Remote Sensing of Environment**, v. 82, n. 2-3, p. 322-334, 2002.

PRIMACK, R. B.; RODRIGUES, E. 2000. **Biologia da conservação**. Ed. Planta, 327p. Disponível em: <https://www.academia.edu/40644193/Biologia_da_Conserva%C3%A7%C3%A3o_-_Primack_and_Rodrigues> Acesso em: 25 de julho de 2020.

PULITI, S.; SOLBERG, S.; GRANHUS, A. Use of UAV photogrammetric data for estimation of biophysical properties in forest stands under regeneration. **Remote Sensing**, v. 11, 2019.

PUZICHA, J.; HOFMANN, T.; BUHMANN, J. M. Histogram clustering for unsupervised image segmentation. Proceedings. **IEEE Computer Society Conference on Computer Vision and Pattern Recognition** 1999.

QI, J. et al. A modified soil adjusted vegetation index. **Remote sensing of environment**, v. 48, n. 2, p. 119-126, 1994.

RAFFERTY, J.P., 2019. **Invasive species**. Website Encyclopedia Britannica. Publicado por Encyclopedia Britannica, inc. February 07, 2019. Disponível em: <<https://www.britannica.com/topic/Invasive-Species-Exotic-Intruders-1717668>> Acesso em: 25 de julho de 2020.

R CORE TEAM. **R: A language and environment for statistical computing**. R Foundation for Statistical Computing, Vienna, Austria. Disponível em: <<http://www.R-project.org/>>. Acesso em: 21 de agosto de 2021.

REIS, B. P.; et al. Management recommendation generation for areas under forest restoration process through images obtained by UAV and LiDAR. **Remote Sensing**, v. 11, 2019.

REX, F. E.; KÄFER, P. S.; SANTOS, M.; SEBEM, E. Análise derivativa de dados de reflectância obtidos por espectrorradiometria para caracterização de espécies arbóreas. **Enciclopédia Biosfera**, v. 13, n. 24, 2016.

RICH, E.; KNIGHT, K. **Inteligência artificial**. 2. Ed. São Paulo, Makron Books, 1994.

RICHARDSON, D. M. et al. Naturalization and invasion of alien plants: Concepts and definitions. **Diversity and Distributions**, v. 6, n. 2, p. 93–107, 2000.

RICHARDSON, D. M.; REJMÁNEK, M. Trees and shrubs as invasive alien species - a global review. **Diversity and Distributions**, v. 17, n. 5, p. 788–809, 2011.

RICO-SÁNCHEZ, A. E. et al. Economic costs of invasive alien species in Mexico. **NeoBiota**, v. 67, p. 459-483, 2021.

RIO GRANDE DO SUL. **Atlas Socioeconômico do Rio Grande do Sul**. Secretaria de Planejamento, Governança e Gestão. 6ª ed, 203 p. Porto Alegre – RS, 2021.

RIO GRANDE DO SUL. Secretaria do Meio Ambiente e Infraestrutura. **Parque Estadual Quarta Colônia**. Disponível em: < <https://sema.rs.gov.br/parque-estadual-quarta-colonia>>. Acesso em: 26 de julho de 2020.

RIO GRANDE DO SUL. Secretaria Estadual do Meio Ambiente. **Portaria SEMA nº 79 de 31 de outubro de 2013**- Reconhece a lista de espécies exóticas invasoras RS e demais classificações, normas e outras providências. Disponível em:<http://www.sema.rs.gov.br/classificacoes_normativas> Acesso em: 26 de julho de 2020.

ROLIM, R. G. et al. How much do we know about distribution and ecology of naturalized and invasive alien plant species? A case study from subtropical southern Brazil. **Biological Invasions**, v. 17, n. 5, p. 1497–1518, 2015.

RONCERO, V. G. 2005. 70 f. Dissertação (Mestrado em Ciências). **Um estudo de segmentação de imagens baseado em um método de computação evolucionária**. Universidade Federal do Rio de Janeiro – UFRJ, Rio de Janeiro, 2005.

RONDEAUX, G.; STEVEN, M.; BARET, F. Optimization of soil-adjusted vegetation indices. **Remote sensing of environment**, v. 55, n. 2, p. 95-107, 1996.

ROSA, J. L. G. **Fundamentos da inteligência artificial**. Rio de Janeiro: LTC, v. 1, 2011.

ROUSE, J. W. et al. Monitoring the vernal advancement and retrogradation (green wave effect) of natural vegetation. **NASA/GSFC Type III Final Report, Greenbelt, Md**, v. 371, 1974.

ROUSE, J. W. et al. Monitoring vegetation systems in the Great Plains with ERTS. **NASA special publication**, v. 351, n. 1974, p. 309, 1974.

RUSSEL, S.; NORVIG, P. **Inteligência Artificial**. 3ª ed. Rio de Janeiro, 2013

SAARINEN, N. et al. UAV-based photogrammetric point clouds and hyperspectral imaging for mapping biodiversity indicators in boreal forests. **International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives**, v. 42, n. 3W3, p. 171–175, 2017.

- SABAT-TOMALA, A.; RACZKO, E.; ZAGAJEWSKI, B. Comparison of Support Vector Machine and Random Forest Algorithms for Invasive and Expansive Species Classification Using Airborne Hyperspectral Data. **Remote Sensing**, v. 12, p. 516, 2020.
- SALA, O. E. et al. Global biodiversity scenarios for the year 2100. **Science**, v. 287, n. 5459, p. 1770–1774, 2000.
- SAMPAIO, A. B.; SCHMIDT, I. B. Espécies exóticas invasoras em unidades de conservação federais do Brasil. **Biodiversidade Brasileira**, n. 2, p. 32–49, 2013.
- SCCOTI, M. S. V. et al. Dinâmica da chuva de sementes em remanescente de floresta estacional subtropical. **Ciência Florestal**, v. 26, p. 1179-1188, 2016.
- SCHÖLKOPF, B. et al. New Support Vector Algorithms. **Neural Comput.** v. 12, p. 1207-1245, 2000.
- SCHOWENGERDT, R. **Remote sensing: models and methods for image processing**. 3. ed. San Diego: Academic Press, 2007.
- SHALEV-SHWARTZ, S.; BEN-DAVID, S. **Understanding machine learning: From theory to algorithms**. [s.l.: s.n.]. v. 97
- SHAO, Z.; ZHANG, L. Estimating Forest Aboveground Biomass by Combining Optical and SAR Data: A Case Study in Genhe, Inner Mongolia, China. **Sensors**, v. 16, n. 6., 2016.
- SILVA, A. M. L. et al. Descoberta de conhecimento através de métodos de aprendizagem de máquina supervisionados aplicados ao ambiente virtual de aprendizagem sigaa/ufpi. **Revista de Sistemas e Computação**, v. 7, n. 1, p. 68–78, 2017.
- SILVA, O. F. **Análise de imagens multitemporais do sensor TM Landsat-5 da vegetação do cerrado, utilizando técnicas de NDVI, no Parque Nacional das Emas – Góias**. 2014. 95p. Dissertação (Mestrado em Tecnologia de processos sustentáveis). Instituto Federal de Educação Ciência e Tecnologia – IFG., Goiânia - GO, 2014.
- SIVIERO, M, R. L.; JÚNIOR, E. R. H. Aplicação de aprendizado de máquina em dados mensurados numa seção do Rio Atibaia/SP. **Anais... 30º Congresso Nacional de Saneamento e Meio Ambiente e 30º Feira Nacional de Saneamento e Meio Ambiente**. p. 1-5, 2019.
- SMITH, C. W. **Pest Plants of Hawaiian Native Ecosystems**. University of Hawaii, USA: Departamento of Botany, 1998. Disponível em:
<http://www.botany.hawaii.edu/faculty/cw_smith/aliens.htm> (acessado em 19/10/2020)
- SOMODI, I. et al. Recognition of the invasive species *Robinia pseudacacia* from combined remote sensing and GIS sources. **Biological Conservation**, v. 150, n. 1, p. 59–67, 2012.
- SOTHE, C.; et al. Tree species classification in a highly diverse subtropical forest integrating UAV-based photogrammetric point cloud and hyperspectral data. **Remote Sensing**. v. 11, 2019.

- SOUZA FILHO, C. R. et al. Detecção de exsudações de hidrocarbonetos por geobotânica e sensoriamento remoto multi-temporal: estudo de caso no Remanso do Fogo - MG. **Revista Brasileira de Geociências**, v. 38, p. 228-243, 2008.
- SOUZA, C. H. W. et al. Estudo da Banda Red Edge do satélite Rapideye na discriminação da cobertura vegetal. **In: Anais do XVII Simpósio Brasileiro de Sensoriamento Remoto - SBSR**, João Pessoa-PB, Brasil, 25 a 29 de abril de 2015.
- SPEAR, D. et al. Human population density explains alien species richness in protected areas. **Biological Conservation**, v. 159, p. 137–147, 2013.
- SPEAR, D.; MELODIE, A.; MCGEOCH, L. C. F. Alien species in South Africa's national parks. **Dian. Koedoe**, v. 53, n. 1, p. 1–35, 2011.
- STOHLGREN, T. J. et al. Widespread plant species: Natives versus aliens in our changing world. **Biological Invasions**, v. 13, n. 9, p. 1931–1944, 2011.
- STUCKENS, J.; COPPIN, P. R.; BAUER, M. E. Integrating contextual information with per-pixel classification for improved land cover classification. **Remote Sensing of Environment**, v. 71, n. 3, p. 282–296, 2000.
- TORRES-SÁNCHEZ, J. et al. Configuration and Specifications of an Unmanned Aerial Vehicle (UAV) for Early Site Specific Weed Management. **PLOS ONE**, v. 8, n. 3, 2013.
- TULLDAHL, H. M. et al. Accuracy evaluation of 3D lidar data from small UAV. **Electro-Optical Remote Sensing, Photonic Technologies, and Applications IX**, v. 9649, p. 964903, 2015.
- VAPNIK, V. **The Nature of Statistical Learning Theory**. 2nd ed. New York: Springer; 1999.
- VENZKE, T. S. L.; MATTEI, V. L.; DA COSTA, M. A. D. Exotic woody plants in Pelotas, Rio Grande do Sul, southernmost Brazil. **Check List**, v. 14, n. 1, p. 203–211, 2018.
- VLACHOPOULOS, O. et al. Delineation of Bare Soil Field Areas from Unmanned Aircraft System Imagery with the Mean Shift Unsupervised Clustering and the Random Forest Supervised Classification. **Canadian Journal of Remote Sensing**, v. 46, n. 4, p. 489-500, 2020.
- WANG, L. A multi-scale approach for delineating individual tree crowns with very high-resolution imagery. **Photogrammetric Engineering and Remote Sensing**, v. 76, n. 4, p. 371-378, 2010.
- WESSEL, M.; BRANDMEIER, M.; TIEDE, D. Evaluation of different machine learning algorithms for scalable classification of tree types and tree species based on Sentinel-2 data. **Remote Sensing**, v. 10, n. 9, 2018.
- WHITE, J. C. et al. Remote Sensing Technologies for Enhancing Forest Inventories: A Review. **Canadian Journal of Remote Sensing**, v. 42, n. 5, p. 619–641, 2016.

WIENS, J. et al. Selecting and Conserving lands for biodiversity: The role of remote sensing. **Remote Sensing of Environment** v. 113, p. 1370–1381, 2009

WOZIWODA, B.; KOPE, D.; WITKOWSKI, W. J. The negative impact of intentionally introduced *Quercus rubra* L. on a forest community. **Acta Societatis Botanicorum Poloniae**, v. 83, n. 1, p. 39–49, 2014.

YIN, D.; WANG, L. Individual mangrove tree measurement using UAV-based LiDAR data: Possibilities and challenges. **Remote Sensing of Environment**, v. 223, n. May 2018, p. 34–49, 2019.

ZARCO-TEJADA, P. J.; GONZÁLEZ-DUGO, V.; BERNI, J. A. J. Fluorescence, temperature and narrow-band indices acquired from a UAV platform for water stress detection using a micro-hyperspectral imager and a thermal camera. **Remote Sensing of Environment**, v. 117, p. 322–337, 2012.

ZENNI, R. D.; DECHOUM, M. de S. Paisagens Antropizadas e invasão por plantas exóticas. In: PERES, C. A.; BARLOW, J.; GARDENER, T. A.; VIEIRA, I.; C.; G. (Orgs.).

ZENNI, R. D.; ZILLER, R. S. Visão geral das plantas exóticas invasoras no Brasil. **Revista Brasileira de Botânica**, v. 34, n. 3, p. 431–446, 2011.

ZILLER, S. R.; DECHOUM, M. S. Plantas e vertebrados exóticos invasores em unidades de conservação no Brasil. **Biodiversidade Brasileira**, v. 3, n. 2, p. 4–31, 2013.

ZOU, X. et al. UAV-based high-throughput approach for fast growing *Cunninghamia lanceolata* (Lamb.) cultivar screening by machine learning. **Forests**, v. 10, n. 9, p. 815, 2019.

ZVIEJKOVSKI, I.P. et al. Potencial invasor de *Psidium guajava* em um intervalo de cinco anos (2002 - 2007) dentro de uma Unidade de Conservação. In: **W. Delitti** (org.). Anais do IX Congresso de Ecologia do Brasil, São Lourenço, 2009. p. 1-3.

APÊNDICE A – MATRIZ DE CONFUSÃO GERADAS PARA ESPÉCIE *H. DULCIS*

Tabela 11 - Matriz de confusão do desempenho da classificação *pixel a pixel* com o algoritmo *Random Forest*.

Classes	<i>H. dulcis</i>	Espécie similar	Sombra	Demais espécies	Total	AU*	Kappa
<i>H. dulcis</i>	32	5	0	1	38	0,84	-
Espécie similar	3	25	0	0	28	0,89	-
Sombra	1	0	30	0	31	0,97	-
Demais espécies	0	7	0	96	103	0,93	-
Total	33	37	30	100	200	-	-
AP*	0,97	0,68	1	0,96	-	0,915	-
Kappa	-	-	-	-	-	-	0,87

*AU: acurácia do usuário; AP: acurácia do produtor

Tabela 12 - Matriz de confusão do desempenho da classificação OBIA com o algoritmo *Random Forest*.

Classes	<i>H. dulcis</i>	Espécie similar	Sombra	Demais espécies	Total	AU*	Kappa
<i>H. dulcis</i>	25	12	1	0	38	0,66	-
Espécie similar	1	11	0	0	12	0,92	-
Sombra	0	0	21	1	22	0,95	-
Demais espécies	1	6	0	121	128	0,95	-
Total	27	29	22	122	200	-	-
AP*	0,93	0,38	0,95	0,99	-	0,89	-
Kappa	-	-	-	-	-	-	0,80

*AU: acurácia do usuário; AP: acurácia do produtor

APÊNDICE A – MATRIZ DE CONFUSÃO GERADAS PARA ESPÉCIE *H. DULCIS*

Tabela 13 - Matriz de confusão do desempenho da classificação *pixel a pixel* com o algoritmo *Support Vector Machine*.

Classes	<i>H. dulcis</i>	Espécie similar	Sombra	Demais espécies	Total	AU*	Kappa
<i>H. dulcis</i>	26	8	0	1	35	0,74	-
Espécie similar	1	23	0	2	26	0,88	-
Sombra	0	0	27	3	30	0,90	-
Demais espécies	0	3	1	105	109	0,96	-
Total	27	34	28	111	200	-	-
AP*	0,96	0,68	0,96	0,95	-	0,905	-
Kappa	-	-	-	-	-	-	0,85

*AU: acurácia do usuário; AP: acurácia do produtor

Tabela 14 - Matriz de confusão do desempenho da classificação OBIA com o algoritmo *Support Vector Machine*.

Classes	<i>H. dulcis</i>	Espécie similar	Sombra	Demais espécies	Total	AU*	Kappa
<i>H. dulcis</i>	27	9	0	0	36	0,75	-
Espécie similar	1	11	1	0	13	0,85	-
Sombra	0	1	19	0	20	0,95	-
Demais espécies	0	12	2	117	131	0,89	-
Total	28	33	22	117	200	-	-
AP*	0,96	0,33	0,86	1	-	0,87	-
Kappa	-	-	-	-	-	-	0,77

*AU: acurácia do usuário; AP: acurácia do produtor

APÊNDICE B – MATRIZ DE CONFUSÃO GERADAS PARA ESPÉCIE *P. GUAJAVA* COM A COMPOSIÇÃO DE IMAGENS RGB

Tabela 15 - Matriz de confusão do desempenho da classificação *pixel a pixel* com o algoritmo *Random Forest* utilizando a composição de imagens RGB.

Classes	<i>P. guajava</i>	Espécie similar	Sombra	Demais espécies	Total	AU*	Kappa
<i>P. guajava</i>	65	7	0	1	73	0,89	-
Espécie similar	8	30	0	2	40	0,75	-
Sombra	0	0	17	0	17	1	-
Demais espécies	5	4	0	61	70	0,87	-
Total	78	41	17	64	200	-	-
AP*	0,83	0,73	1	0,95	-	0,865	-
Kappa	-	-	-	-	-	-	0,81

*AU: acurácia do usuário; AP: acurácia do produtor

Tabela 16 - Matriz de confusão do desempenho da classificação OBIA com o algoritmo *Random Forest* utilizando a composição de imagens RGB.

Classes	<i>P. guajava</i>	Espécie similar	Sombra	Demais espécies	Total	AU*	Kappa
<i>P. guajava</i>	67	5	0	1	73	0,92	-
Espécie similar	2	26	0	0	28	0,93	-
Sombra	0	0	12	0	12	1	-
Demais espécies	0	7	0	80	87	0,92	-
Total	69	38	12	81	200	-	-
AP*	0,97	0,68	1	0,99	-	0,925	-
Kappa	-	-	-	-	-	-	0,89

*AU: acurácia do usuário; AP: acurácia do produtor

APÊNDICE B – MATRIZ DE CONFUSÃO GERADAS PARA ESPÉCIE *P. GUAJAVA* COM A COMPOSIÇÃO DE IMAGENS RGB

Tabela 17 - Matriz de confusão do desempenho da classificação *pixel a pixel* com o algoritmo *Support Vector Machine* utilizando a composição de imagens RGB.

Classes	<i>P. guajava</i>	Espécie similar	Sombra	Demais espécies	Total	AU*	Kappa
<i>P. guajava</i>	67	7	0	2	76	0,88	-
Espécie similar	4	36	0	2	42	0,86	-
Sombra	0	0	17	0	17	1	-
Demais espécies	8	1	1	55	65	0,85	-
Total	79	44	18	59	200		-
AP*	0,85	0,82	0,94	0,93	-	0,875	-
Kappa	-	-	-	-	-	-	0,82

*AU: acurácia do usuário; AP: acurácia do produtor

Tabela 18 - Matriz de confusão do desempenho da classificação OBIA com o algoritmo *Support Vector Machine* utilizando a composição de imagens RGB.

Classes	<i>P. guajava</i>	Espécie similar	Sombra	Demais espécies	Total	AU*	Kappa
<i>P. guajava</i>	69	5	0	1	75	0,92	-
Espécie similar	7	24	0	3	34	0,71	-
Sombra	0	0	13	0	13	1	-
Demais espécies	1	7	0	70	78	0,89	-
Total	77	36	13	74	200	-	-
AP*	0,90	0,67	1	0,95	-	0,88	-
Kappa	-	-	-	-	-	-	0,82

*AU: acurácia do usuário; AP: acurácia do produtor

APÊNDICE C – MATRIZ DE CONFUSÃO GERADAS PARA ESPÉCIE *P. GUAJAVA* COM A COMPOSIÇÃO DE IMAGENS RGCV

Tabela 19 - Matriz de confusão do desempenho da classificação *pixel a pixel* com o algoritmo *Random Forest* utilizando a composição de imagens RGCV.

Classes	<i>P. guajava</i>	Espécie similar	Sombra	Demais espécies	Total	AU*	Kappa
<i>P. guajava</i>	78	2	0	0	80	78	-
Espécie similar	8	37	0	2	47	8	-
Sombra	0	0	22	0	22	0	-
Demais espécies	1	1	2	47	51	1	-
Total	87	40	24	49	200	-	-
AP*	78	2	0	0	80	0,92	-
Kappa	-	-	-	-	-	-	0,89

*AC: acurácia do usuário; AP: acurácia do produtor

Tabela 20 - Matriz de confusão do desempenho da classificação OBIA com o algoritmo *Random Forest* utilizando a composição de imagens RGCV.

Classes	<i>P. guajava</i>	Espécie similar	Sombra	Demais espécies	Total	AU*	Kappa
<i>P. guajava</i>	82	4	0	0	86	0,95	-
Espécie similar	2	25	0	1	28	0,89	-
Sombra	0	0	16	0	16	1	-
Demais espécies	1	6	0	63	70	0,90	-
Total	85	35	16	64	200	-	-
AP*	0,96	0,71	1	0,98	-	0,93	-
Kappa	-	-	-	-	-	-	0,90

*AU: acurácia do usuário; AP: acurácia do produtor

**APÊNDICE C – MATRIZ DE CONFUSÃO GERADAS PARA ESPÉCIE *P. GUAJAVA*
COM A COMPOSIÇÃO DE IMAGENS RGCV**

Tabela 21 - Matriz de confusão do desempenho da classificação pixel a pixel com o algoritmo Support Vector Machine utilizando a composição de imagens RGCV.

Classes	<i>P. guajava</i>	Espécie similar	Sombra	Demais espécies	Total	AU*	Kappa
<i>P. guajava</i>	71	6	0	0	77	0,92	-
Espécie similar	10	34	0	3	47	0,72	-
Sombra	0	0	21	0	21	1	-
Demais espécies	2	0	1	52	55	0,95	-
Total	83	40	22	55	200	-	-
AP*	0,86	0,85	0,95	0,95	-	0,89	-
Kappa	-	-	-	-	-	-	0,84

*AU: acurácia do usuário; AP: acurácia do produtor

Tabela 22 - Matriz de confusão do desempenho da classificação OBIA com o algoritmo Support Vector Machine utilizando a composição de imagens RGCV.

Classes	<i>P. guajava</i>	Espécie similar	Sombra	Demais espécies	Total	AU*	Kappa
<i>P. guajava</i>	73	5	0	0	78	0,94	-
Espécie similar	5	24	0	0	29	0,82	-
Sombra	0	0	15	0	15	1	-
Demais espécies	3	1	1	73	78	0,94	-
Total	81	30	16	73	200	-	-
AP*	0,90	0,79	0,94	1	-	0,925	-
Kappa	-	-	-	-	-	-	0,89

*AU: acurácia do usuário; AP: acurácia do produtor