

CARLA TALITA PERTILLE

**SENSORIAMENTO REMOTO NO DIAGNÓSTICO DA SANIDADE DE
POVOAMENTOS DE *Pinus taeda* L. ATACADOS POR *Sapajus nigritus* Kerr (1972)**

Dissertação apresentada ao Curso de Pós-Graduação em Engenharia Florestal do Centro de Ciências Agroveterinárias, da Universidade do Estado de Santa Catarina, como requisito parcial para obtenção do grau de Mestre em Engenharia Florestal.

Orientador: Marcos Benedito Schimalski

Co Orientador: Veraldo Liesenberg

**LAGES, SC
2019**

**Ficha catalográfica elaborada pelo programa de geração automática da
Biblioteca Setorial do CAV/UEDESC,
com os dados fornecidos pelo(a) autor(a)**

Pertille, Carla Talita

Sensoriamento remoto no diagnóstico da sanidade de povoamentos de *Pinus taeda* L. atacados por *Sapajus nigritus* Kerr (1972) / Carla Talita Pertille. -- 2019.

191 p.

Orientador: Marcos Benedito Schimalski

Coorientador: Veraldo Liesenberg

Dissertação (mestrado) -- Universidade do Estado de Santa Catarina, Centro de Ciências Agroveterinárias, Programa de Pós-Graduação em Engenharia Florestal, Lages, 2019.

1. Imagens orbitais. 2. VANT. 3. Índice de vegetação. 4. Produção. I. Schimalski, Marcos Benedito . II. Liesenberg, Veraldo. III. Universidade do Estado de Santa Catarina, Centro de Ciências Agroveterinárias, Programa de Pós-Graduação em Engenharia Florestal. IV. Título.

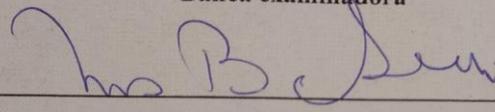
CARLA TALITA PERTILLE

SENSORIAMENTO REMOTO NO DIAGNÓSTICO DA SANIDADE DE
POVOAMENTOS DE *Pinus taeda* L. ATACADOS POR *Sapajus nigritus* Kerr
(1972)

Dissertação apresentada ao curso de Mestrado em Engenharia Florestal do Centro de Ciências Agroveterinárias da Universidade do Estado de Santa Catarina, como requisito parcial para a obtenção do grau de mestre em Engenharia Florestal.

Banca examinadora

Orientador: _____



(Prof. Dr. Marcos Benedito Schimalski)

Universidade do Estado de Santa Catarina – UDESC

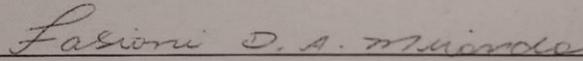
Membro: _____



(Prof. Dr. Edilson Batista de Oliveira)

Empresa Brasileira de Pesquisa Agropecuária – EMBRAPA

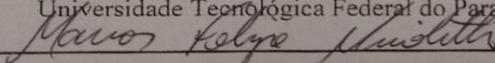
Membro: _____



(Prof. Dra. Fabiani das Dores Abati Miranda)

Universidade Tecnológica Federal do Paraná – UTFPR

Membro: _____



(Prof. Dr. Marcos Felipe Nicoletti)

Universidade do Estado de Santa Catarina - UDESC

Suplente: _____

(Prof. Dr. Veraldo Liesenberg)

Universidade do Estado de Santa Catarina – UDESC

Lages, 15 de fevereiro de 2019.

DEDICATÓRIA

Dedico esse trabalho a minha família, que sempre me incentivou, apoiou e lutou por mim.

AGRADECIMENTOS

Agradeço à Deus, por tudo o que tenho, por todas as bênçãos recebidas e pelo dom da vida.

Agradeço a minha família, minha base, meu porto seguro, meu maior exemplo de amor, coragem, superação e pelos incontáveis exemplos de dedicação e humildade.

Agradeço a minha melhor amiga Fabíola, que mesmo longe, sempre se fez presente me incentivando, apoiando e aconselhando.

Também gostaria de agradecer aos amigos da UTFPR para a vida, Raquel, Graziela e Maicon. Muito obrigada por estarem comigo em mais uma etapa e por sempre estarem perto, apesar da distância que nos separa.

Agradeço aos amigos que o mestrado me proporcionou, Bruno, Camila, Luana, Carolina, Francielle, Oiéler, Felipe, Ricardo, Rodrigo e Leonardo. E um agradecimento especial aos amigos do laboratório de tecnologia da madeira, pelos cafés e momentos de descontração.

Agradeço meu orientador, Marcos B. Schimalski, por sempre ter acreditado no meu potencial, pelos ensinamentos, pela orientação, paciência e pelos conselhos. Também agradeço ao meu co orientador, Veraldo Liesenberg, pela orientação recebida.

Agradeço ao professor Marcos F. Nicoletti, por todos os ensinamentos obtidos nos trabalhos desenvolvidos e pela amizade construída. À professora Fabiani A. Miranda, por todos os anos de orientação, por todos os aprendizados e por sempre vibrar com as minhas vitórias.

Ao pesquisador Edilson Batista de Oliveira, pelo aceite em participar e contribuir nessa pesquisa. Também agradeço ao professor Vilmar Picinatto Filho, pela ajuda e participação no desenvolvimento do projeto e por todas as sugestões que enriqueceram o trabalho.

Também agradeço ao Programa de Bolsas Universitárias de Santa Catarina/UNIEDU, Fundo de Apoio à Manutenção e ao Desenvolvimento da Educação Superior (FUMDES) pela concessão da bolsa.

Por fim, expresso meus agradecimentos a todos que contribuíram para que esse trabalho se tornasse realidade e atingisse os objetivos propostos.

Muito obrigada!

"Eu sei o preço do sucesso: dedicação, trabalho duro e uma incessante devoção às coisas que você quer ver acontecer."

(Frank Lloyd Wright)

RESUMO

PERTILLE, C. T. Sensoriamento remoto no diagnóstico da sanidade de povoamentos de *Pinus taeda* L. atacados por *Sapajus nigritus* Kerr (1972). 2019. 191 p. Dissertação (Mestrado em Engenharia Florestal) – Programa de Pós-Graduação em Engenharia Florestal, Universidade do Estado de Santa Catarina. Lages, 2019.

Danos causados por macacos (*Sapajus nigritus*) a plantios do gênero *Pinus* sp. foram registrados no estado de Santa Catarina, interferindo na cadeia produtiva da floresta. Visando gerar metodologias para subsidiar a identificação, monitoramento e cálculo de impactos destes danos em plantios de *Pinus taeda* L., esta pesquisa teve como objetivos: (i) testar a detecção de áreas atacadas em imagens orbitais, (ii) identificar por imagens aéreas, as árvores atacadas e (iii) avaliar o impacto desse ataque sobre as variáveis dendrométricas de povoamentos de *Pinus taeda* L. Para avaliar a porcentagem de danos no campo, foram alocadas 46 parcelas circulares, nas quais a porcentagem de dano foi classificada em quatro classes: I: sem dano, II: moderado, III: severo e IV: morto. As imagens foram obtidas da plataforma Sentinel-2 Sensor MSI (*Multispectral Instrument*) e processadas no aplicativo computacional ENVI (*Environment for Visualizing Images*). Os índices de vegetação foram calculados e, por meio de Análise de Componentes Principais, selecionou-se os índices de vegetação utilizados na construção de modelos de regressão pelas técnicas *Stepwise*, *Support Vector Machine* (SVM) e *Random Forest* (RF). Os índices mais robustos foram o MCARI (*Modified Chlorophyll Absorption in Reflectance Index*), NDI45 (*Normalized Difference Index 45*) e NDVIRR (*Red and Red-Edge Normalized Difference Vegetation Index*), os quais estimaram para as classes um percentual de ataque de *S. nigritus* por parcela com R^2 ajustado de 0,8042, 0,4603, 0,8815 e 0,9766; Syx de 13,49, 61,42, 15,11 e 8,69 (% $0,045 \text{ ha}^{-1}$) e RMSE de 1,95, 4,49, 2,11 e 0,32 (% $0,045 \text{ ha}^{-1}$), respectivamente. Imagens aéreas obtidas por um Veículo Aéreo Não Tripulado (VANT) foram processadas no aplicativo computacional *Agisoft Photo Scan Professional* para as áreas sobrevoadas. Foram derivados índices de vegetação e composições de bandas para os ortomosaicos. Por meio de fotointerpretação, foi realizada a contagem manual das árvores não atacadas, mortas e das atacadas com base na coloração da copa. As amostras foram coletadas e divididas em 75% em de treinamento e 25 % validação, considerando três diâmetros de copa: 0,5 m, 1 m e 1,5 m. Foram testados três algoritmos de classificação: *Maximum Likelihood Classification*, *Random Tree* e *Support Vector Machine* (SVM). A precisão da classificação foi avaliada por exatidão global e índice kappa. Foram detectadas manualmente 3773 árvores: 1478 atacadas, 197 mortas e 2098 não atacadas. Utilizando algoritmos de classificação, a maior acurácia foi representada pela composição do índice ExG e com o ortomosaico original, resultando em exatidão global de 0,8859 e 0,8347 e índice kappa de 0,8306 e 0,9105, respectivamente. Finalmente, o impacto do dano causado por *S. nigritus* foi avaliado no Simulador de Crescimento e Produção de *Pinus* (SisPinus). Das 675 árvores avaliadas, 172 árvores apresentaram anelamento com um volume danificado de $8,64 \text{ m}^3 \text{ ha}^{-1}$, atingindo 3,2% do volume da floresta. O janelamento foi encontrado em 48 árvores, causando perda de $3,23 \text{ m}^3 \text{ ha}^{-1}$, representando 1,2% do volume total. Essas informações podem contribuir para o manejo do povoamento florestal atacado favorecendo a adoção de novas estratégias de ordenamento florestal.

Palavras-chave: Imagens orbitais. VANT. Índice de vegetação. Produção.

ABSTRACT

PERTILLE, C. T. Remote sensing in the diagnosis of the health of stand of *Pinus taeda* L. attacked by *Sapajus nigritus* Kerr (1972). 2019. 191 p. Dissertação (Mestrado em Engenharia Florestal) – Programa de Pós-Graduação em Engenharia Florestal, Universidade do Estado de Santa Catarina. Lages, 2019.

Damage caused by monkeys (*Sapajus nigritus*) to plantations of the genus *Pinus* sp. were recorded in the state of Santa Catarina, interfering with the productive chain of the forest. The objective of this research was to: (i) test the detection of areas attacked in orbital images, (ii) identify individual trees attacked in aerial images, and (iii) to evaluate the impact of this attack on the dendrometric variables of a *Pinus taeda* L. To evaluate the percentage of damage in the field, 46 circular plots were allocated, in which the damage percentage was classified into four classes: I: without damage, II: moderate, III: severe and IV: dead. The images were obtained from the Sentinel-2 Sensor MSI (Multispectral Instrument) platform, processed in the ENVI (Environment for Visualizing Images) computer application. The vegetation indices were calculated and, through Principal Component Analysis, the vegetation indices used in the construction of regression models using the Stepwise, Support Vector Machine (SVM) and Random Forest (RF) techniques were selected. The most robust indexes were MCARI (Modified Chlorophyll Absorption in Reflectance Index), NDI45 (Normalized Difference Index 45) and NDVIRR (Red and Edge Normalized Difference Vegetation Index), which estimated for the classes an attack percentage of *S. nigritus* per plot with adjusted R² of 0.8042, 0.4603, 0.8815 and 0.9766; Syx of 13.49, 61.42, 15.11 and 8.69 (% 0.045 ha⁻¹) and RMSE of 1.95, 4.49, 2.11 and 0.32 (% 0.045 ha⁻¹), respectively. Aerial images obtained by an Unmanned Aerial Vehicle (UAV) were processed in the Agisoft Photo Scan Professional computer application for the overflowed areas. Indices of vegetation and band compositions were derived for the orthomosaic. Manual counting of the non-attacked, dead and attacked trees was performed based on the color of the crown. The samples were collected and divided into 75% of training and 25% validation, with three crown diameters: 0.5 m, 1 m and 1.5 m. Three classification algorithms were tested: Maximum Likelihood Classification, *Random Tree* and Support Vector Machine (SVM). The accuracy of the classification was assessed by global accuracy and kappa index. Manually detected 3773 trees: 1478 attacked, 197 dead and 2098 non-attacked. Using classification algorithms, the highest accuracy in the classification was represented by the composition of the ExG index and the original orthomosaic, resulting in an overall accuracy of 0.8859 and 0.8347 and kappa index of 0.8306 and 0.9105, respectively. Finally, the impact of damage caused by *S. nigritus* was evaluated in the Pinus Growth and Production Simulator (SisPinus). Of the 675 trees evaluated, 172 trees presented ringing with a damaged volume of 8.64 m³ ha⁻¹, reaching 3.2% of the forest volume. The windowing was found in 48 trees, causing a loss of 3.23 m³ ha⁻¹, representing 1.2% of the total volume. This information can contribute to the management of the forest stand, favoring the adoption of new forest management strategies.

Keywords: Orbital images. UAV. Vegetation index. Forest production.

LISTA DE ILUSTRAÇÕES

Figura 1 - Distribuição geográfica do <i>Sapajus nigrinus</i> no Brasil.	39
Figura 2 - Macaco-prego no Parque Nacional do Iguaçu, Argentina.	40
Figura 3 - Resolução espacial da missão Sentinel-2.	55
Figura 4: 1 - Localização do povoamento de <i>Pinus taeda</i> L. em Bocaina do Sul – SC.	86
Figura 4: 2 - Estatística descritiva da variável porcentagem de ataque por parcela (% 0,045 ha ⁻¹) em povoamento de <i>Pinus taeda</i> L. atacados por <i>Sapajus nigrinus</i>	94
Figura 4: 3 - Comportamento dos IV indicados pela PCA relacionados com as classes de ataque por parcela (% 0,045 ha ⁻¹) para as três imagens do Sentinel-2/MSI.	95
Figura 4: 4 - Dispersão gráfica dos resíduos dos modelos ajustados para as classes de dano pelas técnicas Stepwise, SVM e RF com os índices do Sentinel-2/MSI na estimativa do percentual de ataque de <i>S. nigrinus</i> por parcela (% 0,045ha ⁻¹) em um povoamento de <i>Pinus taeda</i> L. em Bocaina do Sul.	98
Figura 5: 1 - Localização da área florestal em Bocaina do Sul – SC.	118
Figura 5: 2 - Comportamento dos IV calculados com as classes de treinamento com o ortomosaico da Área 1.	125
Figura 5: 3 - Comportamento dos IV calculados com as classes de treinamento com o ortomosaico da Área 2.	126
Figura 5: 4 – Detecção manual das árvores em função de sua sanidade para as áreas analisadas de um povoamento de <i>Pinus taeda</i> L. localizado em Bocaina do Sul – SC.	128
Figura 5: 5 - Algoritmo SVM para a classificação das árvores não atacadas, mortas e atacadas por macaco prego na área 1 de um povoamento de <i>Pinus taeda</i> L. localizado em Bocaina do Sul – SC.	132
Figura 5: 6 - Algoritmo SVM para a classificação das árvores não atacadas, mortas e atacadas por macaco prego na área 2 de um povoamento de <i>Pinus taeda</i> L. Localizado em Bocaina do Sul – SC.	133
Figura 6: 1 - Localização do povoamento de <i>Pinus taeda</i> L. em Bocaina do Sul – SC.	150
Figura 6: 2 - Altura inferior do dano e idade das árvores aneladas e janeladas por <i>S. nigrinus</i> em um povoamento de <i>Pinus taeda</i> L. localizado em Bocaina do Sul, Santa Catarina.	154
Figura 6: 3 - Estatística descritiva das variáveis dendrométricas das árvores não atacadas e atacadas por <i>S. nigrinus</i> em um povoamento de <i>Pinus taeda</i> L. em Bocaina do Sul – SC.	152
Figura 6: 4 - Volumes danificados pelo anelamento e janelamento em um povoamento de <i>Pinus taeda</i> L. localizado em Bocaina do Sul – SC.	155

LISTA DE TABELAS

Tabela 1 - Bandas espectrais do Sentinel-2.	54
Tabela 2 - Lista de produtos de Nível 2A, 2B e Nível 3 da missão Sentinel-2.	56
Tabela 4: 1 - Imagens do sensor Sentinel-2/MSI para o povoamento de <i>Pinus taeda</i> L. atacado por <i>Sapajus nigritus</i> em Bocaina do Sul.	87
Tabela 4: 2 - Índices de vegetação calculados para as imagens do Sentinel-2/MSI para um povoamento de <i>Pinus taeda</i> L. localizado em Bocaina do Sul – SC.	88
Tabela 4: 3 - Seleção das variáveis regressoras utilizando PCA para um povoamento de <i>Pinus taeda</i> L. atacado por <i>S. nigritus</i> em Bocaina do Sul – SC.	94
Tabela 4: 4 - Estatísticas do ajuste dos modelos de regressão testados para o sensor Sentinel-2 visando estimar o percentual de classe de ataque de macaco-prego por parcela (% 0,045 ha ⁻¹) para um povoamento de <i>Pinus taeda</i> L. em Bocaina do Sul.	96
Tabela 4: 5 - Teste do Qui-Quadrado para os modelos desenvolvidos pela técnica <i>Stepwise</i> para cada classe de ataque causado pelo <i>S. nigritus</i> em um povoamento de <i>Pinus taeda</i> L.	100
Tabela 5: 1 - Índices de Vegetação derivados para um povoamento de <i>Pinus taeda</i> L. atacado por <i>S. nigritus</i> localizado em Bocaina do Sul – Santa Catarina.	121
Tabela 5: 2 - Contagem manual das árvores atacadas, não atacadas e mortas de <i>Pinus taeda</i> L. em Bocaina do Sul – SC.	127
Tabela 5: 3 - Acurácia dos métodos de classificação orientada a objeto testados para a Área 1, localizada em um povoamento de <i>Pinus taeda</i> L. em Bocaina do Sul – SC.	128
Tabela 5: 4 - Acurácia dos métodos de classificação orientada a objeto testados para a Área 2, localizada em um povoamento de <i>Pinus taeda</i> L. em Bocaina do Sul – SC.	129
Tabela 6: 1 - Relação do preço dos sortimentos de árvores de <i>Pinus taeda</i> L. atacadas e não atacadas por <i>S. nigritus</i> no Sul do Brasil.	152
Tabela 6: 2 - Relação dos danos físicos causados por <i>S. nigritus</i> a um povoamento de <i>Pinus taeda</i> L. localizado em Santa Catarina – SC.	153
Tabela 6: 3 - Número máximo de danos por árvore causados por <i>S. nigritus</i> em um povoamento de <i>Pinus taeda</i> L. localizado em Bocaina do Sul, Santa Catarina.	154
Tabela 6: 4 - Número de árvores de <i>Pinus taeda</i> L. aneladas ou janeladas por macaco-prego em função das classes de diâmetro à altura do peito (DAP).	155
Tabela 6: 5 - Perda do valor da produção de um povoamento de <i>Pinus taeda</i> L. atacado por <i>S. nigritus</i> em Bocaina do Sul.	156
Tabela 7: 1 - Modelos ajustados pelas técnicas <i>Stepwise</i> , <i>Support Vector Machine</i> e <i>Random Forest</i> na estimativa de ataque de <i>S. nigritus</i> por parcela (% 0,045 ha ⁻¹) em um povoamento de <i>Pinus taeda</i> L. localizado em Bocaina do Sul, Santa Catarina.	163
Tabela 7: 2 - Matriz de confusão do ortomosaico classificado pelo método <i>Maxver</i> para a área 1, com amostras de 0,5m.	165
Tabela 7: 3 - Matriz de confusão da composição 1 classificada pelo método <i>Maxver</i> para a área 1, com amostras de 0,5m.	165

Tabela 7: 4 - Matriz de confusão composição 2 classificada pelo método Maxver para a área 1, com amostras de 0,5m.	165
Tabela 7: 5 - Matriz de confusão composição 3 classificada pelo método Maxver para a área 1, com amostras de 0,5m.	165
Tabela 7: 6 - Matriz de confusão da composição 4 classificada pelo método Maxver para a área 1, com amostras de 0,5m.	166
Tabela 7: 7 - Matriz de confusão da composição 5 classificada pelo método Maxver para a área 1, com amostras de 0,5m.	166
Tabela 7: 8 - Matriz de confusão do ortomosaico classificado pelo método Random Tree para a área 1, com amostras de 0,5m.	166
Tabela 7: 9 - Matriz de confusão da composição 1 classificada pelo método Random Tree para a área 1, com amostras de 0,5m.	166
Tabela 7: 10 - Matriz de confusão da composição 2 classificada pelo método Random Tree para a área 1, com amostras de 0,5m.	167
Tabela 7: 11 - Matriz de confusão da composição 3 classificada pelo método Random Tree para a área 1, com amostras de 0,5m.	167
Tabela 7: 12 -Matriz de confusão da composição 4 classificada pelo método Random Tree para a área 1, com amostras de 0,5m.	167
Tabela 7: 13 -Matriz de confusão da composição 5 classificada pelo método Random Tree para a área 1, com amostras de 0,5m.	167
Tabela 7: 14 -Matriz de confusão do ortomosaico classificado pelo método SVM para a área 1, com amostras de 0,5m.	168
Tabela 7: 15 - Matriz de confusão da composição 1 classificada pelo método SVM para a área 1, com amostras de 0,5m.	168
Tabela 7: 16 - Matriz de confusão da composição 2 classificada pelo método SVM para a área 1, com amostras de 0,5m.	168
Tabela 7: 17 - Matriz de confusão da composição 3 classificada pelo método SVM para a área 1, com amostras de 0,5m.	168
Tabela 7: 18 - Matriz de confusão da composição 4 classificada pelo método SVM para a área 1, com amostras de 0,5m.	169
Tabela 7: 19 - Matriz de confusão da composição 5 classificada pelo método SVM para a área 1, com amostras de 0,5m.	169
Tabela 7: 20 - Matriz de confusão do ortomosaico classificado pelo método Maxver para a área 1, com amostras de 1m.	169
Tabela 7: 21 - Matriz de confusão da composição 1 classificada pelo método Maxver para a área 1, com amostras de 1m.	169
Tabela 7: 22 - Matriz de confusão da composição 2 classificada pelo método Maxver para a área 1, com amostras de 1m.	170
Tabela 7: 23 - Matriz de confusão da composição 3 classificada pelo método Maxver para a área 1, com amostras de 1m.	170

Tabela 7: 24 - Matriz de confusão da composição 4 classificada pelo método Maxver para a área 1, com amostras de 1m.	170
Tabela 7: 25 - Matriz de confusão da composição 5 classificada pelo método Maxver para a área 1, com amostras de 1m.	170
Tabela 7: 26 - Matriz de confusão do ortomosaico classificado pelo método Random Tree para a área 1, com amostras de 1m.	171
Tabela 7: 27 - Matriz de confusão da composição 1 classificada pelo método Random Tree para a área 1, com amostras de 1m.	171
Tabela 7: 28 - Matriz de confusão da composição 2 classificada pelo método Random Tree para a área 1, com amostras de 1m.	171
Tabela 7: 29 - Matriz de confusão da composição 3 classificada pelo método Random Tree para a área 1, com amostras de 1m.	171
Tabela 7: 30 - Matriz de confusão da composição 4 classificada pelo método Random Tree para a área 1, com amostras de 1m.	172
Tabela 7: 31 - Matriz de confusão da composição 5 classificada pelo método Random Tree para a área 1, com amostras de 1m.	172
Tabela 7: 32 - Matriz de confusão do ortomosaico classificado pelo método SVM para a área 1, com amostras de 1m.	172
Tabela 7: 33 - Matriz de confusão da composição 1 classificada pelo método SVM para a área 1, com amostras de 1m.	172
Tabela 7: 34 - Matriz de confusão da composição 2 classificada pelo método SVM para a área 1, com amostras de 1m.	173
Tabela 7: 35 - Matriz de confusão da composição 3 classificada pelo método SVM para a área 1, com amostras de 1m.	173
Tabela 7: 36 - Matriz de confusão da composição 4 classificada pelo método SVM para a área 1, com amostras de 1m.	173
Tabela 7: 37 - Matriz de confusão da composição 5 classificada pelo método SVM para a área 1, com amostras de 1m.	173
Tabela 7: 38 - Matriz de confusão do ortomosaico classificado pelo método Maxver para a área 1, com amostras de 1,5m.	174
Tabela 7: 39 - Matriz de confusão da composição 1 classificada pelo método Maxver para a área 1, com amostras de 1,5m.	174
Tabela 7: 40 - Matriz de confusão da composição 2 classificada pelo método Maxver para a área 1, com amostras de 1,5m.	174
Tabela 7: 41 - Matriz de confusão da composição 3 classificada pelo método Maxver para a área 1, com amostras de 1,5m.	174
Tabela 7: 42 - Matriz de confusão da composição 4 classificada pelo método Maxver para a área 1, com amostras de 1,5m.	174
Tabela 7: 43 - Matriz de confusão composição 5 classificada pelo método Maxver para a área 1, com amostras de 1,5m.	175

Tabela 7: 44 - Matriz de confusão do ortomosaico classificado pelo método Random Tree para a área 1, com amostras de 1,5m.	175
Tabela 7: 45 - Matriz de confusão da composição 1 classificada pelo método Random Tree para a área 1, com amostras de 1,5m.	175
Tabela 7: 46 - Matriz de confusão da composição 2 classificada pelo método Random Tree para a área 1, com amostras de 1,5m.	175
Tabela 7: 47 - Matriz de confusão da composição 3 classificada pelo método Random Tree para a área 1, com amostras de 1,5m.	176
Tabela 7: 48 - Matriz de confusão da composição 4 classificada pelo método Random Tree para a área 1, com amostras de 1,5m.	176
Tabela 7: 49 - Matriz de confusão composição 5 classificada pelo método Random Tree para a área 1, com amostras de 1,5m.	176
Tabela 7: 50 - Matriz de confusão do ortomosaico classificado pelo método SVM para a área 1, com amostras de 1,5m.	176
Tabela 7: 51 - Matriz de confusão da composição 1 classificado pelo método SVM para a área 1, com amostras de 1,5m.	177
Tabela 7: 52 - Matriz de confusão da composição 2 classificada pelo método SVM para a área 1, com amostras de 1,5m.	177
Tabela 7: 53 - Matriz de confusão da composição 3 classificada pelo método SVM para a área 1, com amostras de 1,5m.	177
Tabela 7: 54 - Matriz de confusão da composição 4 classificada pelo método SVM para a área 1, com amostras de 1,5m.	177
Tabela 7: 55 - Matriz de confusão da composição 5 classificada pelo método SVM para a área 1, com amostras de 1,5m.	178
Tabela 7: 56 - Matriz de confusão do ortomosaico classificado pelo método Maxver para a área 2, com amostras de 0,5m.	178
Tabela 7: 57 - Matriz de confusão da composição 1 classificada pelo método Maxver para a área 2, com amostras de 0,5m.	178
Tabela 7: 58 - Matriz de confusão da composição 2 classificada pelo método Maxver para a área 2, com amostras de 0,5m.	178
Tabela 7: 59 - Matriz de confusão da composição 3 classificada pelo método Maxver para a área 2, com amostras de 0,5m.	179
Tabela 7: 60 - Matriz de confusão da composição 4 classificada pelo método Maxver para a área 2, com amostras de 0,5m.	179
Tabela 7: 61 - Matriz de confusão da composição 5 classificada pelo método Maxver para a área 2, com amostras de 0,5m.	179
Tabela 7: 62 - Matriz de confusão do ortomosaico classificado pelo método Random Tree para a área 2, com amostras de 0,5m.	179
Tabela 7: 63 - Matriz de confusão da composição 1 classificada pelo método Random Tree para a área 2, com amostras de 0,5m.	180

Tabela 7: 64 - Matriz de confusão da composição 2 classificada pelo método Random Tree para a área 2, com amostras de 0,5m.	180
Tabela 7: 65 - Matriz de confusão da composição 3 classificada pelo método Random Tree para a área 2, com amostras de 0,5m.	180
Tabela 7: 66 - Matriz de confusão da composição 4 classificada pelo método Random Tree para a área 2, com amostras de 0,5m.	180
Tabela 7: 67 - Matriz de confusão composição 5 classificado pelo método Random Tree para a área 2, com amostras de 0,5m.	181
Tabela 7: 68 - Matriz de confusão do ortomosaico classificado pelo método SVM para a área 2, com amostras de 0,5m.	181
Tabela 7: 69 - Matriz de confusão da composição 1 classificada pelo método SVM para a área 2, com amostras de 0,5m.	181
Tabela 7: 70 - Matriz de confusão da composição 2 classificada pelo método SVM para a área 2, com amostras de 0,5m.	181
Tabela 7: 71 - Matriz de confusão da composição 3 classificada pelo método SVM para a área 2, com amostras de 0,5m.	181
Tabela 7: 72 - Matriz de confusão da composição 4 classificada pelo método SVM para a área 2, com amostras de 0,5m.	182
Tabela 7: 73 - Matriz de confusão da composição 5 classificada pelo método SVM para a área 2, com amostras de 0,5m.	182
Tabela 7: 74 - Matriz de confusão do ortomosaico classificado pelo método Maxver para a área 2, com amostras de 1m.	182
Tabela 7: 75 - Matriz de confusão da composição 1 classificada pelo método Maxver para a área 2, com amostras de 1m.	182
Tabela 7: 76 - Matriz de confusão composição 2 classificada pelo método Maxver para a área 2, com amostras de 1m.	183
Tabela 7: 77 - Matriz de confusão composição 3 classificada pelo método Maxver para a área 2, com amostras de 1m.	183
Tabela 7: 78 - Matriz de confusão da composição 4 classificada pelo método Maxver para a área 2, com amostras de 1m.	183
Tabela 7: 79 - Matriz de confusão da composição 5 classificada pelo método Maxver para a área 2, com amostras de 1m.	183
Tabela 7: 80 - Matriz de confusão do ortomosaico classificado pelo método Random Tree para a área 2, com amostras de 1m.	184
Tabela 7: 81 - Matriz de confusão da composição 1 classificada pelo método Random Tree para a área 2, com amostras de 1m.	184
Tabela 7: 82 - Matriz de confusão composição 2 classificada pelo método Random Tree para a área 2, com amostras de 1m.	184
Tabela 7: 83 - Matriz de confusão da composição 3 classificada pelo método Random Tree para a área 2, com amostras de 1m.	184

Tabela 7: 84 - Matriz de confusão da composição 4 classificada pelo método Random Tree para a área 2, com amostras de 1m.	185
Tabela 7: 85 - Matriz de confusão da composição 5 classificada pelo método Random Tree para a área 2, com amostras de 1m.	185
Tabela 7: 86 - Matriz de confusão do ortomosaico classificado pelo método SVM para a área 2, com amostras de 1m.	185
Tabela 7: 87 - Matriz de confusão da composição 1 classificada pelo método SVM para a área 2, com amostras de 1m.	185
Tabela 7: 88 - Matriz de confusão da composição 2 classificada pelo método SVM para a área 2, com amostras de 1m.	186
Tabela 7: 89 - Matriz de confusão da composição 3 classificada pelo método SVM para a área 2, com amostras de 1m.	186
Tabela 7: 90 - Matriz de confusão da composição 4 classificada pelo método SVM para a área 2, com amostras de 1m.	186
Tabela 7: 91- Matriz de confusão da composição 5 classificada pelo método SVM para a área 2, com amostras de 1m.	186
Tabela 7: 92 - Matriz de confusão do ortomosaico classificado pelo método Maxver para a área 2, com amostras de 1,5m.	187
Tabela 7: 93 - Matriz de confusão da composição 1 classificada pelo método Maxver para a área 2, com amostras de 1,5m.	187
Tabela 7: 94 - Matriz de confusão da composição 2 classificada pelo método Maxver para a área 2, com amostras de 1,5m.	187
Tabela 7: 95 - Matriz de confusão da composição 3 classificada pelo método Maxver para a área 2, com amostras de 1,5m.	187
Tabela 7: 96 - Matriz de confusão da composição 4 classificada pelo método Maxver para a área 2, com amostras de 1,5m.	188
Tabela 7: 97 - Matriz de confusão da composição 5 classificada pelo método Maxver para a área 2, com amostras de 1,5m.	188
Tabela 7: 98 - Matriz de confusão do ortomosaico classificado pelo método Random Tree para a área 2, com amostras de 1,5m.	188
Tabela 7: 99 - Matriz de confusão da composição 1 classificada pelo método Random Tree para a área 2, com amostras de 1,5m.	188
Tabela 7: 100 - Matriz de confusão da composição 2 classificada pelo método Random Tree para a área 2, com amostras de 1,5m.	188
Tabela 7: 101 - Matriz de confusão da composição 3 classificada pelo método Random Tree para a área 2, com amostras de 1,5m.	189
Tabela 7: 102 - Matriz de confusão da composição 4 classificada pelo método Random Tree para a área 2, com amostras de 1,5m.	189
Tabela 7: 103 - Matriz de confusão composição 5 classificada pelo método Random Tree para a área 2, com amostras de 1,5m.	189

Tabela 7: 104 - Matriz de confusão do ortomosaico classificado pelo método SVM para a área 2, com amostras de 1,5m.	189
Tabela 7: 105 - Matriz de confusão da composição 1 classificada pelo método SVM para a área 2, com amostras de 1,5m.	190
Tabela 7: 106 - Matriz de confusão da composição 2 classificada pelo método SVM para a área 2, com amostras de 1,5m.	190
Tabela 7: 107 - Matriz de confusão da composição 3 classificada pelo método SVM para a área 2, com amostras de 1,5m.	190
Tabela 7: 108 - Matriz de confusão da composição 4 classificada pelo método SVM para a área 2, com amostras de 1,5m.	190
Tabela 7: 109 -Matriz de confusão da composição 5 classificada pelo método SVM para a área 2, com amostras de 1,5m.	191

LISTA DE ABREVIATURAS E SIGLAS

- AIC – *Akaike Information Criterion*
- ANAC – Agência Nacional de Aviação Civil
- BIC – *Bayesian Information Criterion*
- CAP – Circunferência à altura do peito
- DAP – Diâmetro à altura do peito
- EMBRAPA – Empresa Brasileira de Pesquisa Agropecuária
- ESA – *European Space Agency*
- GIS – *Geographic Information System*
- GNSS – *Global Navigation Satellite System*
- GPS – Global Positioning System
- IUCN – *International Union for Conservation of Nature*
- IAF – Índice de Área Foliar
- IV – Índice de Vegetação
- LASER – *Light Amplification by Stimulated Emission of Radiation*
- MCARI – *Modified Chlorophyll Absorption in Reflectance Index*
- MSI – *MultiSpectral Instrument*
- NDI45 – *Normalized Difference Index 45*
- NDVIRR – *Red and Red-Edge Normalized Difference Vegetation Index*
- NIR – Infravermelho Próximo
- PDI – Processamento Digital de Imagens
- RADAR – *Radio Detection and Ranging*
- RFA – Radiação Fotossinteticamente Ativa
- RMSE – *Root Mean Square Error*
- SisPinus – Simulador de Crescimento e Produção de Pinus
- SNAP – *Sentinel Application Platform*
- SR – Sensoriamento Remoto
- SWIR – Infravermelho de Ondas Curtas
- VANT – Veículos Aéreos Não Tripulados
- VIS – Visível
- UAV – *Unmanned Aerial Vehicles*
- UTM – *Universal Transversa de Mercator*
- WGS 84 – *World Geodetic System*

SUMÁRIO

1	INTRODUÇÃO	31
2	OBJETIVOS	33
2.1	OBJETIVO GERAL	33
2.2	OBJETIVOS ESPECÍFICOS	33
	REFERÊNCIAS	35
3	APLICABILIDADE DE TÉCNICAS DE SENSORIAMENTO REMOTO PARA AVALIAÇÃO DA SANIDADE DE <i>Pinus taeda</i> L. ATACADO POR <i>Sapajus nigritus</i> Kerr (1972)	37
3.1	<i>Pinus</i> spp.	37
3.2	<i>Sapajus nigritus</i> Kerr (1972)	38
3.3	SENSORIAMENTO REMOTO	43
3.3.1	Comportamento espectral da vegetação	44
3.3.2	Diagnóstico da perda de vigor e a resposta espectral da vegetação	46
3.3.3	Índices de vegetação (IV)	48
3.4	SENSORES REMOTOS	52
3.4.1	Sentinel-2	53
3.5	VEÍCULOS AÉREOS NÃO TRIPULADOS - VANT	57
	REFERÊNCIAS	61
4	CAPÍTULO I:	83
	DETERMINAÇÃO DA SANIDADE DE UM POVOAMENTO DE <i>Pinus taeda</i> L. APÓS O ATAQUE DE <i>Sapajus nigritus</i> Kerr (1972) UTILIZANDO SENTINEL-2	83
	RESUMO	83
	ABSTRACT	83
4.1	INTRODUÇÃO	84
4.2	MATERIAL E MÉTODOS	85
4.2.1	Descrição da área	85
4.2.2	Coleta de dados	86
4.2.3	Dados remotamente situados	87
4.2.4	Seleção das variáveis	89
4.2.5	Métodos para ajuste de modelos de regressão	90
4.2.5.1	<i>Stepwise</i>	90
4.2.5.2	<i>Support Vector Machines</i> (SVM)	90
4.2.5.3	<i>Random Forest</i> (RF)	91
4.2.6	Seleção do melhor modelo de regressão	91
4.2.7	Análises estatísticas	93

4.3	RESULTADOS	93
4.4	DISCUSSÃO	100
4.5	CONCLUSÃO	106
	REFERÊNCIAS	107
5	CAPÍTULO II:	115
	USO DE VEÍCULOS AÉREOS NÃO TRIPULADOS (VANT) NA CLASSIFICAÇÃO DE ÁRVORES ATACADAS POR <i>Sapajus nigrinus</i> Kerr (1972) EM UM POVOAMENTO DE <i>Pinus taeda</i> L.	115
	RESUMO	115
	ABSTRACT	115
5.1	INTRODUÇÃO	116
5.2	MATERIAL E MÉTODOS	118
5.2.1	Descrição da área	118
5.2.2	Recobrimento aéreo	119
5.2.3	Processamento fotogramétrico	120
5.2.4	Índices de vegetação (IV)	121
5.2.5	Detecção manual das árvores individuais	121
5.2.6	Classificação orientada a objeto das árvores	122
5.2.7	Geração das amostras	122
5.2.8	Métodos testados	123
5.2.8.1	<i>Maximum Likelihood Classification</i> – Maxver	123
5.2.8.2	<i>Random Tree</i> - RT	123
5.2.8.3	<i>Support Vector Machine</i> - SVM	124
5.2.9	Acurácia da classificação	124
5.3	RESULTADOS	125
5.4	DISCUSSÃO	133
5.5	CONCLUSÃO	138
	REFERÊNCIAS	139
6	CAPÍTULO III:	147
	EFEITO DO ATAQUE DE <i>Sapajus nigrinus</i> Kerr (1972) NA PRODUÇÃO DE MADEIRA DE UM POVOAMENTO DE <i>Pinus taeda</i> L.	147
	RESUMO	147
	ABSTRACT	147
6.1	INTRODUÇÃO	148
6.2	MATERIAL E MÉTODOS	149
6.2.1	Descrição da área	149

6.2.2	Dados de campo	150
6.2.3	Avaliações econômicas	151
6.2.4	Análises estatísticas	152
6.3	RESULTADOS	152
6.4	DISCUSSÃO	156
6.5	CONCLUSÃO	158
	REFERÊNCIAS	159
7	CAPÍTULO IV:	161
	RECOMENDAÇÕES E PERSPECTIVAS PARA PESQUISAS FUTURAS	161
	ANEXO A	163
	ANEXO B	165

1 INTRODUÇÃO

A ocorrência de pragas e doenças é um dos principais fatores que afetam o crescimento das plantas, causando elevados prejuízos. Estima-se que 30% das perdas mundiais da produção agrícola são causadas por problemas fitossanitários (GHINI; BETTIOL, 2000). Já na área florestal, diversas pragas e doenças acometeram as florestas plantadas.

Nos últimos anos uma espécie de primata vem chamando a atenção do setor florestal. *Sapajus nigritus* (Goldfuss), popularmente conhecido como macaco-prego, está atingindo plantios florestais de *Pinus* spp. Há relatos de danos causados por macacos-prego a plantios comerciais de *Pinus* spp. no Sul do Brasil desde a década de 1950 (LIMA, 1993; KOEHLER; FIRKOWSKI, 1996; ROCHA, 2000). Entretanto, a frequência e a intensidade dos danos aumentaram a partir da década de 1990. Nos últimos anos, os danos vêm sendo registrados na região Sul e Sudeste, especialmente nos estados do Paraná e Santa Catarina, e em menor intensidade, nos estados do Rio Grande do Sul e São Paulo (LIEBSCH; MIKICH, 2009; MIKICH; LIEBSCH, 2009; MIKICH; LIEBSCH, 2014).

Segundo Hill (2000), espécies como *S. nigritus* são frequentemente tratadas como pragas ou pestes, uma vez que acarretam perdas aos produtores, incluindo perdas financeiras. Contudo, Santos et al. (2007) indicam que o termo adequado ao se referir a esse animal seja “populações problema”, tendo em vista que os danos são localizados e causados por grupos ou populações, e não pela espécie como um todo.

Diante da relevância do assunto para a área florestal, a EMBRAPA (Empresa Brasileira de Pesquisa Agropecuária) desenvolve linhas de pesquisa sobre o *S. nigritus* em parceria com empresas florestais desde 2003. Esses estudos visam desenvolver metodologias eficientes para a redução e/ou controle dos danos causados por esse primata aos plantios florestais.

Dessa forma, é possível perceber a importância do monitoramento das populações de macacos-prego, bem como a avaliação do seu impacto sobre áreas florestais. Tais informações podem subsidiar eventuais programas de manejo da espécie voltados à conservação dos fragmentos florestais, da produção florestal e futuras análises econômicas do prejuízo causado por esse primata (LIBESCH et al., 2015).

Inserida nessa temática, uma alternativa para esse cenário envolve a utilização de técnicas de Sensoriamento Remoto. Essa ciência dispõe de metodologias que podem ser usadas para

quantificação, detecção de plantas atacadas e monitoramento de áreas acometidas pelo macaco-prego.

O Sensoriamento Remoto envolve a utilização de sensores orbitais e imagens aéreas. Imagens orbitais apresentam limitações como a presença de nuvens e a interferência da atmosfera. Diante disso, a implementação da tecnologia conhecida como *Unmanned Aerial Vehicles* (UAVs), ou seja, Veículos Aéreos Não Tripulados (VANT), possibilitou uma nova fonte de dados remotamente situados. Esses equipamentos possuem diversas vantagens, como leveza e baixo custo. Além disso, são operacionalmente fáceis de implementar como plataformas seguras de aquisição de imagens de Sensoriamento Remoto (BERNI et al., 2009; ZHANG; KOVACS, 2012).

Nesse sentido, essa pesquisa visa contribuir para a geração de informações relacionadas ao monitoramento das áreas e árvores atacadas por esse primata em povoamentos florestais, por meio da utilização de metodologias de dados orbitais gratuitos oriundos do sensor Sentinel-2 e com maior resolução espacial e nível de detalhamento como as imagens obtidas por VANT. Com isso, a hipótese dessa pesquisa fundamenta-se no potencial de aplicação de duas plataformas de aquisição de dados (orbitais e aéreas), como métodos rápidos, aplicáveis e eficazes para subsidiar a identificação de árvores e áreas acometidas pelo macaco-prego e a determinação indireta da sua sanidade.

2 OBJETIVOS

2.1 OBJETIVO GERAL

Avaliar a eficácia de Sensoriamento Remoto no diagnóstico de danos provocados por *Sapajus nigrinus* em *Pinus taeda* L.

2.2 OBJETIVOS ESPECÍFICOS

- Identificar os melhores intervalos espectrais para o estudo da sanidade de um povoamento de *Pinus taeda* L.;
- Calcular Índices de Vegetação (IV) para a área de estudo, visando identificar as áreas atacadas para os dados orbitais;
- Ajustar modelos de regressão desenvolvidos com IV a fim de estimar o ataque de *S. nigrinus* no povoamento de *Pinus taeda* L. nos dados orbitais;
- Identificar as árvores acometidas pelo ataque do macaco-prego com o emprego de dados derivados a partir de Veículos Aéreos Não Tripulados (VANT);
- Estimar, por meio de simulação, a produção florestal de *Pinus taeda* L. em função dos níveis e ocorrência de ataque de *Sapajus nigrinus*.

REFERÊNCIAS

- BERNI, J.; ZARCO-TEJADA, P.; SUAREZ, L.; FERERES, E. Thermal and narrowband multispectral remote sensing for vegetation monitoring from an unmanned aerial vehicle. *Geoscience and Remote Sensing, IEEE Transactions on Geoscience and Remote Sensing*, v. 47, n. 3, p. 722-738, 2009.
- GHINI, R.; BETTIOL, W. Proteção de plantas na agricultura sustentável. **Cadernos de Ciência & Tecnologia**, Brasília, v.17, n.1, p. 61-70, 2000.
- HILL, C. M. Conflict of Interest Between People and Baboons: Crop Raiding in Uganda. **International Journal of Primatology**, v. 21, n. 2, p. 299-315, 2000.
- KOEHLER, A.; FIRKOWSKI, C. Descascamento de pinus por macaco-prego (*Cebus apella*). **Floresta**, Curitiba, v. 24, n. 1/2, p. 61-75, 1996.
- LIEBSCH, D.; MIKICH, S. B. Fenologia reprodutiva de espécies da Floresta Ombrófila Mista na região centro-sul do Estado do Paraná. **Revista Brasileira de Botânica**, São Paulo, v. 32, n. 2, p. 375-391, 2009.
- LIEBSCH, D.; MIKICH, S. B.; OLIVEIRA, E. B. de; MOREIRA, J. M. M. Á. P. Descascamento de Pinus taeda por macacos-prego (*Sapajus nigritus*): tipos e intensidades de danos e seus impactos sobre o crescimento das árvores. **Scientia Forestalis**, Piracicaba, v. 43, n. 105, p. 37-49, 2015.
- LIMA, G. S. Manejo e conservação de fauna silvestre em áreas de reflorestamento. **Estudos de Biologia**, v. 34, p. 5-15, 1993.
- MIKICH, S. B.; LIEBSCH, D. **O Macaco-prego e os Plantios de Pinus spp.** Comunicado Técnico, n 234. Embrapa Florestas. Colombo, PR, p.1-5. 2009.
- MIKICH, S. B.; LIEBSCH, D. Damage to forest plantations by tufted capuchins (*Sapajus nigritus*): too many monkeys or not enough fruits? **Forest Ecology and Management**, v. 314, p. 9-16, 2014.
- ROCHA, V. J. Macaco-Prego, como controlar essa nova praga florestal? **Floresta**, Curitiba, v. 30, n. 1/2, p. 95-99, 2000b.

ZHANG, C.; KOVACS, J. M. The application of small unmanned aerial systems for precision agriculture: a review. **Precision Agriculture**, n. 13, 2012, p. 693-712.

3 APLICABILIDADE DE TÉCNICAS DE SENSORIAMENTO REMOTO PARA AVALIAÇÃO DA SANIDADE DE *Pinus taeda* L. ATACADO POR *Sapajus nigrinus* Kerr (1972)

3.1 *Pinus* spp.

Dados do Instituto Brasileiro de Árvores (IBÁ, 2016) revelam a importância do plantio de árvores no país. Atualmente, são 7,8 milhões de hectares de árvores plantadas, sendo 1,6 milhões de hectares do gênero *Pinus* spp. com plantios concentrados no Paraná (42%) e em Santa Catarina (34%) com produtividade média de 31 m³.ha.ano⁻¹.

Pinus taeda L. é a espécie florestal mais plantada na região sul do país (IBÁ, 2017). Tal fato já ocorre há várias décadas. Kronka et al. (2005) destacaram que as principais causas para isso estão relacionadas com o crescimento rápido e alta produtividade na região. Além disso, essa espécie apresentou alta adaptabilidade aos solos ligeiramente ácidos, proporcionando a implantação de áreas extensas aliadas com práticas silviculturais adequadas. Esses fatores tornam as espécies desse gênero significativas fontes de matéria-prima, oriundas de plantios que seguem princípios de sustentabilidade.

A partir da madeira de *Pinus* spp. é possível produzir uma ampla gama de produtos. Dentre eles, pode-se citar: a celulose de fibra longa não branqueada, pasta mecânica, molduras, painéis de madeira reconstituída, lâmina, madeira serrada bruta e beneficiada, madeira bruta seca em estufa, móveis e pré-cortado para móveis, entre outros (SCHUCHOVSKI, 2003).

Para obter uma ampla gama de produtos a partir da madeira dessa espécie, a condução dos povoamentos exige desbastes planejados de forma adequada, sendo comum realizar o primeiro entre 8 a 12 anos e o segundo entre 14 a 18 anos. O corte raso é indicado próximo aos 25 anos. Todavia, já existem plantios sendo manejados com rotações relativamente curtas, de 15 a 20 anos, sem desbaste, cujos plantios objetivam produzir biomassa e toras de pequenas e médias dimensões (DOBNER JR et al., 2012).

Contudo, florestas plantadas formadas por grandes áreas de monoculturas contínuas de espécies dos gêneros *Pinus* spp. e *Eucalyptus* spp. possuem base genética restrita de espécies e procedências. Essas características predisõem as plantas aos riscos de ataques de pragas e populações-problema, como o caso do *Sapajus nigrinus*. Por apresentarem menor variabilidade genética, as monoculturas não dispõem de tantos subsídios no controle desses inimigos naturais (SCHÜHLI et al., 2016).

Existem diversos relatos de ataques de pragas aos plantios de *Pinus* spp., como as espécies *Cinara pinivora* e *Cinara atlantica*, populares pulgões da madeira. Outro pulgão, conhecido como o pulgão-da-califórnia, *Essigella californica* (Essig, 1909) também ataca espécies de *Pinus* spp., segundo os registros de Iede (2005). Outra praga com relatos de ataque é a *Eulachnus rileyi* (Williams, 1911), que pode causar clorose e até mesmo perda de agulha (SCHÜHLI et al., 2016). Lagartas da mariposa do *Dendrolimus* também causaram problemas a plantios, como *Dendrolimus pini* (L.) ou a mariposa do pinheiro, *Dendrolimus punctatus* (Walker) ou a lagarta do pinheiro Masson, *Dendrolimus sibiricus* Tschetverikov ou a mariposa da seda siberiana, e *Dendrolimus superans* (Butler) ou a traça da seda de Sakhalin (SCHÜHLI et al., 2016).

Nas últimas décadas, relatos de ataque de *Sapajus nigritus* tem se tornado frequentes em plantios de *Pinus* spp. no sul do Brasil. Contudo, essa espécie deve ser tratada como população-problema como sugere Santos et al. (2007), por não ser um comportamento padrão da espécie e sim de alguns indivíduos.

3.2 *Sapajus nigritus* Kerr (1972)

A espécie analisada nessa pesquisa é conhecida popularmente como macaco-prego e denominada como *Sapajus nigritus* Goldfuss (LYNCH ALFARO et al., 2012b). Anteriormente, esse gênero *Sapajus* chamava-se *Cebus* (GROVES, 2001; SILVA JUNIOR, 2001).

Macacos-prego pertencentes ao gênero *Cebus* (Primates: Cebidae) são um grupo taxonômico muito diversificado. Características morfológicas, ecológicas e comportamentais entre as espécies deste grupo incentivaram a divisão dos indivíduos em dois grupos distintos: um grupo com tufo e outro sem tufo (ELLIOT, 1913; SILVA JR, 2005). O principal critério foi a presença ou ausência de tufo. Assim, macacos-prego sem tufo foram agrupados no gênero *Cebus* (Erxleben, 1777), e os que apresentavam tufo no gênero *Sapajus* (Kerr, 1792). Com isso, foi considerada a existência de quatro espécies de macacos-prego pertencentes ao gênero *Cebus* (*Cebus albifrons*, *Cebus capucinus*, *Cebus olivaceus*, e *Cebus kaapori*) e de oito espécies pertencentes ao gênero *Sapajus* (*Sapajus apella*, *Sapajus macrocephalus*, *Sapajus libidinosus*, *Sapajus cay*, *Sapajus nigritus*, *Sapajus robustus*, *Sapajus xanthosternos*, e *Sapajus flavius*) (LYNCH ALFARO, 2012a; LYNCH ALFARO, 2012b).

Macacos-prego do gênero *Sapajus* possuem ampla distribuição geográfica pela América do Sul, ocupando diferentes tipos de *habitat*, desde florestas tropicais densas e úmidas até áreas de Cerrado e Caatinga (IUCN, 2012). No Brasil, o *Sapajus nigritus* é endêmico da Mata Atlântica e distribui-se entre as regiões sudeste e sul (Figura 1) – ocupando desde a margem direita do rio

Doce em Minas Gerais e Espírito Santo até o Rio Grande do Sul (VILANOVA et al., 2005; SILVA JR, 2005). Essa espécie apresenta ampla distribuição entre diferentes formações florestais, sendo encontrada em grandes remanescentes ou florestas contínuas, fragmentos muito pequenos e áreas degradadas (IZAWA, 1980; FRAGASZY et al., 1990; LUDWIG et al., 2005).

Figura 1 - Distribuição geográfica do *Sapajus nigrinus* no Brasil.



Fonte: Martins et al. (2015).

A Lista Vermelha da União Internacional para a Conservação da Natureza (*International Union for Conservation of Nature – IUCN*) (Versão 2016-3) classifica essa espécie na categoria “Quase Ameaçada” (*Near Threatened*), com fortes indicativos de diminuição da população (KIERULFF et al., 2017). A perda e a degradação de *habitats* bem como a caça ilegal, compreendem grandes ameaças à sua conservação.

A espécie primata em questão (Figura 2) apresenta hábitos alimentares onívoros, alimentando-se principalmente de frutos, ovos de aves, pequenos vertebrados, insetos, flores, bulbos e sementes (GALETTI; PEDRONI, 1994). Os serviços ambientais prestados pelo *Sapajus nigrinus* compreendem o consumo de frutos de espécies diferentes (MIKICH; SILVA, 2001; GRESSLER et al., 2006) e predador de insetos (GALETTI; PEDRONI, 1994; LUDWIG et al., 2005; MIKICH et al., 2015).

Figura 2 - Macaco-prego no Parque Nacional do Iguazu, Argentina.



Fonte: Peter Cook (Extraída de: <https://creativecommons.org/licenses/by-sa/2.0/deed.en>).

Além disso, possui dieta relacionada ao aprendizado, o que permite a inclusão de novos alimentos bem como a transmissão desse conhecimento para outros macacos (VISALBERGUI; FRAGASZY, 1995; ROCHA, 2000b). Um exemplo disso é a inclusão da seiva do *Pinus* spp. em sua dieta (ROCHA, 2000b), constituída por grandes quantidades de carboidratos e outras substâncias como aminoácidos, ácidos orgânicos, proteínas, sais minerais e íons (DINANT, 2008).

A exploração do bioma Mata Atlântica está diretamente relacionada com a perda da riqueza em seus remanescentes segundo Liebsch et al. (2008). Essa situação agravou a escassez de alimento na floresta em períodos de baixa frutificação, incentivando a busca por alimentos alternativos dos macacos-prego, como uma adaptação ecológica que permite a essa espécie suportar os efeitos negativos da redução e fragmentação de habitat (ROCHA, 2000b; BERNARDO; GALETTI, 2004; LUDWIG et al., 2006).

Ao consumir a seiva de *Pinus* spp., o macaco-prego retira a casca da árvore (ritidoma) em tiras longas, especialmente na parte superior do tronco, resultando em dois padrões de danos: padrão janelar e anelar. No primeiro, somente uma face do tronco é danificada, enquanto no padrão anelar o descascamento ocorre em toda a circunferência do caule, causando um anelamento, em um ou mais entre nós. Já em árvores jovens (quatro anos), o dano pode atingir o tronco, sendo pouco recorrente. Assim, indiferente ao tipo de dano causado, esse primata deseja consumir a seiva elaborada, interrompendo a condução do floema causando sérios problemas para a árvore (MIKICH; LIEBSCH, 2009).

As árvores podem ser descascadas diversas vezes em diferentes alturas e posições segundo Ferreira (1989). A primeira reação da árvore é o isolamento da área atacada a partir da exsudação abundante de resina para recobrir o tronco através do crescimento acelerado da casca e do xilema.

Contudo, dependendo da proporção do dano essa reação não tem resultados satisfatórios (KOEHLER; FIRKOWSKI, 1996).

As árvores aneladas têm parte do alburno sujeito às intempéries e aos agentes decompositores, por mais eficaz que seja a camada de resina. À medida do tempo, a eficiência de condução de seivas começa a diminuir, causando estresse ao resto da copa viva. A formação de novas camadas de alburno não ocorre nessa situação, de modo que, ao final, a parte superior da copa seca devido à impossibilidade de transporte de água e de nutrientes e/ou devido à ação de fungos apodrecedores, o que pode causar a morte da árvore (KOEHLER; FIRKOWSKI, 1996).

A seiva de *Pinus* spp. está presente durante todo o ano, mas o consumo ocorre especificamente entre junho e dezembro, por ser a época com produção insuficiente de frutos na Floresta Ombrófila Mista (MIKICH; LIEBSCH, 2009). Dessa maneira, a seiva do *Pinus* spp. pode ser classificada como alimento *fallback*, ou seja, alimentos que possuem baixa preferência de consumo, mas com alta importância sazonal, por serem consumidos quando os alimentos preferenciais não estão disponíveis (MARSHALL; WRANGHAM, 2007).

Estudos realizados indicam possíveis causas para explicar a predação desse primata em *Pinus* spp., sendo elas: alta palatabilidade da resina (LIMA, 1993; ROCHA, 2000b), escassez de alimento nas florestas nativas (ROCHA, 2000b) e super-população (ROCHA, 2000b). A primeira causa citada pode ser descartada pois esse animal consome a seiva elaborada e não tem contato com a resina, que começa a ser exsudada de 20 a 30 minutos após a remoção da casca. Durante esse intervalo, o animal não se encontra mais na árvore (MIKISCH; LIEBSCH, 2009). Já sobre a superpopulação, estudos revelaram que a densidade encontrada nos plantios é menor do que em remanescentes florestais (VIDOLIN; MIKICH, 2004; LUDWIG et al., 2005; AGUIAR, 2006).

É importante destacar a inviabilidade de alternativas para o controle populacional de macacos-prego, como a liberação de seu abate, translocação ou esterilização (ROCHA, 2000b). Além de ter proteção legal como espécie nativa pela Lei de Crimes Ambientais (Lei nº 9.605/1998) (BRASIL, 1998), o macaco-prego apresenta densidade populacional baixa nas áreas problema (MIKICH; LIEBSCH, 2014).

De acordo com o capítulo V, Seção I (Dos crimes contra a Fauna) da Lei nº 9.605/1998 (BRASIL, 1998), Art. 29, “Matar, perseguir, caçar, apanhar, utilizar espécimes da fauna silvestre, nativos ou em rota migratória, sem a devida permissão, licença ou autorização da autoridade competente, ou em desacordo com a obtida” resulta em uma pena de seis meses a um ano. Dessa forma, a caça ilegal bem como o impedimento da procriação da fauna, modificação do abrigo natural, venda ou guarda em cativeiro em depósito são agravantes para a pena. Assim, o macaco-

prego é protegido pelos termos dessa lei e necessita de estudos de viabilidade de outras alternativas para diminuir o impacto do seu ataque aos plantios florestais.

Diversas estratégias foram e continuam sendo testadas, como por exemplo: suplementação alimentar superficial, construção de aceiros e realização de desbastes, silhuetas de predadores naturais, substituição dos plantios de *Pinus* spp. por outras espécies arbóreas nativas (ROCHA, 2000b), repelentes químicos e por fim, enriquecimento por espécies nativas. Contudo, todas as alternativas mencionadas não se mostraram eficazes para reduzir os danos causados pelo macaco-prego. Em função disso, novas pesquisas para identificar formas de controle e manejo desse animal estão sendo desenvolvidas.

Existem estudos relacionados aos danos quantitativos ou econômicos causados por esses animais, podendo-se citar o trabalho de Koelher e Firkowski (1996) e Liebsch et al. (2015). A partir desses dados, foi possível desenvolver o aplicativo computacional Macaco-prego Calc (EMBRAPA FLORESTAS, 2017), para estimar perdas na produção de madeira de *Pinus taeda* L. provocadas por macaco-prego. Também é possível estimar através do Simulador de Crescimento e Produção de Pinus (SisPinus) o crescimento e a produção de povoamentos em função de diferentes níveis de ataque do macaco-prego e idade de ocorrência dos mesmos (OLIVEIRA et al., 2015). Para tanto, é imprescindível dispor de dados confiáveis dos danos. Tais informações são necessárias para subsidiar futuras análises econômicas do prejuízo causado por essa espécie de primata, bem como possíveis propostas de manejo florestal para prevenção e controle dos ataques.

A avaliação dos tipos e da intensidade dos danos causados pelo macaco-prego a povoamentos de *Pinus taeda* com avaliações anuais dos 5,5 aos 10 anos de idade foi estudada por Liebsch et al. (2015). Os resultados revelaram que o dano menos prejudicial é o janelamento. Já o anelamento é mais grave e compromete significativamente a qualidade da madeira. De maneira geral, os resultados revelaram que os maiores prejuízos econômicos são mais acentuados em indivíduos jovens (4 a 7 anos) atacados.

A susceptibilidade de nove espécies de *Pinus* spp. tropicais e temperados em plantios de quatro empresas nos estados de Paraná e Santa Catarina ao ataque de macaco-prego foi avaliada por Liebsch e Mikich (2017). A maior preferência foi por *Pinus taeda* e *Pinus greggi* enquanto que *Pinus patula* e *Pinus palustris* foram menos susceptíveis.

A perda física e financeira da madeira de um povoamento de *Pinus taeda* L. atacado por *Sapajus nigrurus* foi quantificada por Liebsch et al. (2018). Os resultados revelaram que os danos causaram a perda de incremento e volume de madeira. O anelamento resultou nas perdas mais acentuadas, especialmente pelas perdas de incremento, ao passo que as perdas causadas pela diminuição da qualidade da madeira foram maiores para janelamentos.

É perceptível o impacto do ataque desse animal aos povoamentos florestais, e por isso, estratégias e alternativas devem ser estudadas e implementadas de forma a minimizar e/ou controlar os prejuízos causados. Uma metodologia que possui potencial de aplicação nesses estudos refere-se ao emprego de Sensoriamento Remoto, descrito a seguir.

3.3 SENSORIAMENTO REMOTO

A tecnologia responsável pela obtenção de informações sobre elementos da superfície terrestre, através da detecção e mensuração das mudanças impostas ao espectro eletromagnético foi conceituada por Elachi (1987) como Sensoriamento Remoto (SR). Outro conceito importante foi apresentado por Novo (2008), o qual define SR como o uso conjunto de sensores, equipamentos para processamento de dados e equipamentos para transmissão de dados a bordo de plataformas com a finalidade de analisar os processos e fenômenos que ocorrem na superfície terrestre mediante o registro e estudo das interações entre a radiação eletromagnética (REM) com os objetos presentes na superfície. Já Meneses e Almeida (2012) consideram o SR a tecnologia capaz de obter imagens dos elementos da superfície da Terra sem que ocorra contato físico entre o sensor e o objeto.

O SR baseia-se no processo de interação entre a REM e os diversos objetos existentes. Para isso, podem ocorrer três diferentes fenômenos, tais como: absorção, transmissão e reflexão de REM incidente sobre o objeto. A intensidade da radiação refletida pode ser registrada sob diferentes formas e níveis de coleta de dados, como em laboratório, em campo, a bordo de aeronaves (aerotransportado) e a bordo de satélite (orbital) (PONZONI et al., 2015).

Segundo Vilela (2010), emite REM qualquer objeto que apresente temperatura superior a -273°C . Tal energia é emitida pelos diferentes comprimentos de onda do espectro, absorvida e espalhada na atmosfera, atingindo a superfície e retornando aos sensores. Esses equipamentos irão converter a energia oriunda da superfície em informações espaciais (forma e tamanho dos objetos), intensidade da energia (quantificação da temperatura e o brilho) e registro da variação da intensidade da radiação que deixa a superfície ao longo do espectro eletromagnético. Com isso, é possível determinar características geofísicas e geométricas dos objetos da superfície.

A utilização de imagens através do SR é uma maneira eficaz na aquisição de informações de uma dada região, pois os dados obtidos podem ser utilizados para analisar diferentes alvos espectrais, como solo, água, vegetação e rochas. Cada alvo, por sua vez, irá produzir uma curva espectral diferente em função da sua reflectância.

Deve-se destacar a relevância de estudos ambientais que envolvam técnicas de SR, pois os dados obtidos podem oferecer informações referentes aos tipos de vegetação, estrutura do dossel, estado fenológico, condições de estresse, carência de nutrientes, entre outros (TRENTIN, 2011) bem como para estimativas de Índice de Área Foliar (IAF), biomassa e outros parâmetros (ZHAO et al., 2012).

3.3.1 Comportamento espectral da vegetação

A interação entre a REM com a vegetação resulta na caracterização do comportamento espectral da vegetação, o qual, envolve o estudo dos fatores influentes na reflexão da radiação por folhas isoladas e por dosséis de vegetação (PONZONI; SHIMABUKURO, 2007).

O primeiro passo para o entendimento das interações entre a REM e a vegetação envolve o estudo das propriedades ópticas da folha (VANE; GOETZ, 1988). A folha é o principal órgão absorvedor da REM que influencia no sinal detectado pelos sensores remotos. Dessa forma, as características espectrais de uma folha resultam da sua composição química, morfologia e estrutura interna (D'ARCO, 2007).

A quantidade de REM refletida pelas folhas está relacionada com três fatores: pigmentos presentes nas folhas, espaços ocupados pela água e ar, e estrutura celular interna. A radiação solar ao atingir o dossel resulta em três frações, no qual, uma parte da radiação é absorvida ($\approx 50\%$ que chega a planta) pelos pigmentos da folha participando do processo de fotossíntese, alterando as estruturas moleculares (fotoconversão). A outra parte da radiação é refletida pela folha e a última parte é transmitida, por meio das camadas de folhas que compõem a copa (MOREIRA, 2001).

A planta utiliza somente uma parte da REM para realizar a fotossíntese, conhecida como radiação fotossinteticamente ativa (RFA, ou PAR, do inglês *Photosynthetically Active Radiation*). Esta faixa espectral faz parte da região do visível (Streit et al., 2005). Essa região junto com a região do infravermelho, são amplamente utilizadas em estudos relacionados ao imageamento da vegetação terrestre (LIU, 2006; NOVO, 2010; MENESES, 2012).

A região do visível (VIS) compreende o intervalo entre 0,4 a 0,7 μm do espectro eletromagnético. O comportamento da vegetação nesta região é representado pela alta absorção da radiação incidente, em função dos pigmentos fotossintéticos presentes nas folhas (clorofila, xantofila, carotenóides). Nessa faixa, a reflectância é menor que 20%. Porém, ocorre um aumento de reflexão no comprimento de onda de 0,55 μm (verde), o qual fornece a coloração esverdeada de algumas folhas. Já a região do vermelho apresenta uma relação inversamente proporcional entre a intensidade da REM refletida com a quantidade de clorofila presente no dossel. Dessa forma,

aumentando a cobertura vegetal e o incremento na quantidade de pigmentos celulares por área, a quantidade da REM refletida no vermelho irá diminuir, consequência do aumento da absorção da REM incidente (JENSEN, 2000). A clorofila se caracteriza como o fotorreceptor principal (65%) e os carotenos (6%) e xantofilas (29%) são os fotorreceptores auxiliares (LARCHER, 1986; PONZONI, 2001).

A região do infravermelho próximo (NIR) compreende à faixa espectral entre 0,7 a 1,3 μm e é onde segundo Ponzoni e Shimabukuro (2010) ocorre a maior reflexão da REM. Esse fato está relacionado com os índices de refração do conteúdo celular e do espaço intercelular, que provocam reflexões e refrações da REM no interior da folha (KNIPLING, 1970).

Já na região do infravermelho médio (SWIR), situada no intervalo de 1,3 a 2,6 μm do espectro eletromagnético, a reflectância das folhas diminui devido às fortes bandas de absorção da água (LILLESAND; KIEFER, 1999). Nessa faixa, o conteúdo de água da folha e a reflectância são inversamente proporcionais, quando o primeiro diminui o segundo aumenta (SOUSA, 1997). Assim, o comportamento espectral da vegetação nas faixas do espectro eletromagnético resulta em uma curva de reflectância específica (PONZONI et al., 2012).

As diferenças nos espectros de reflectância entre as plantas são causadas por propriedades estruturais, como o mesófilo foliar, o qual influencia no conteúdo de pigmentos e estrutura fisiológica. Quanto mais grossa for a folha, menor será a transmissão e maior a absorção da REM (CURRAN, 1986). Ponzoni (2012) indica que as principais estruturas das folhas que se relacionam com a REM são a celulose (presente nas paredes celulares), solutos (íons e moléculas), espaços intercelulares e pigmentos dentro dos cloroplastos.

O comportamento espectral da vegetação é mais complexo quando comparado com o do solo e da água (Richards e Jia, 1999). Pode ser diferente entre espécies e na mesma espécie em função da morfologia, a fisiologia e o teor de umidade das folhas (OLIVEIRA, 1998). E pode apresentar variações em relação às partes da árvore expostas à luz solar (HOWARD, 1991). Outros fatores que influenciam nesse processo são apresentados por Moreira (2001), como o estágio fenológico, os aspectos sanitários e as condições climáticas.

A reflectância das folhas na região do NIR não tem alteração significativa na fase de senescência. Contudo, ocorre diminuição dos pigmentos da planta, gerando um aumento da reflectância em comprimentos de onda relativos ao azul e ao vermelho (CURRAN, 1986). Segundo o mesmo autor, a reflectância das folhas pode ser afetada pela contribuição do solo dependendo do índice de área foliar e a geometria de visada e do sol.

Jensen (2009) considera que variações da resposta espectral da vegetação possuem ligação com o percentual de biomassa aérea da vegetação. Alguns estudos confirmaram que existe uma

relação direta entre a resposta no NIR e variáveis relacionadas com a biomassa, e uma relação inversa entre a resposta no visível, particularmente no vermelho. Assim, conforme o dossel vegetal se desenvolve, a sua reflectância aumenta no NIR e a sua absorvância aumenta na região do vermelho por causa do aumento da fotossíntese.

Segundo Meneses e Almeida (2012), a alta transmitância na região do NIR pode gerar um fenômeno conhecido como efeito das camadas múltiplas. Isso ocorre quando há sobreposição de várias camadas de folhas e a energia incidente na camada superior é parcialmente refletida e a porção transmitida atinge a segunda camada. Nessa superfície, uma fração da energia é novamente refletida em direção à face inferior da primeira camada, onde é novamente transmitida, desta vez, para fora do dossel. Assim, o total de energia refletida medida na superfície da primeira camada não é equivalente apenas à energia refletida por esta camada, mas representa a soma de parcelas refletidas pelas diferentes camadas superpostas.

3.3.2 Diagnóstico da perda de vigor e a resposta espectral da vegetação

Em relação às propriedades espectrais da vegetação, as folhas saudáveis apresentam um comportamento espectral característico em três regiões do espectro eletromagnético: região do visível (0,4 a 0,7 μm), região do infravermelho próximo (0,7 a 1,3 μm) e região do infravermelho médio (1,3 a 2,6 μm). Contudo, questões relacionadas à deficiência nutricional, idade, doenças, ataques de pragas e estresse podem influenciar nas características espectrais das folhas nas faixas já mencionadas do espectro eletromagnético (NAUE et al., 2010).

De acordo com Centeno (2009), quando a planta está doente ou seca, ocorre uma diminuição na produção da clorofila fazendo com que a planta não absorva muita energia. Dessa maneira, os pontos de absorção diminuem e a folha passa a refletir também nas faixas do azul e do vermelho, originando a cor amarelada ou marrom das folhas. A estrutura interna da folha controla a reflectância. Por isso, a análise da energia refletida no NIR auxilia na diferenciação de espécies e condições das folhas em imagens de satélite.

A detecção de doenças de plantas ou até mesmo sua quantificação por meio do SR, fundamenta-se na radiação refletida das folhagens. A quantidade e a qualidade da radiação refletida a partir das folhas depende da sanidade do tecido vegetal, que ao ser atacado ou infectado por algum fito patógeno reage causando o sintoma. O tipo de sintoma é uma informação importante, pois tecidos infectados apresentam menor reflectância na região do infravermelho, quando comparados com tecidos saudáveis, possibilitando a sua detecção e quantificação pelas diferenças de reflectância (GUAN; NUTTER, 2002; WEST et al., 2003).

A perda de vigor de uma planta pode ser causada por pragas e moléstias, deficiências nutricionais e hídricas e segundo PONZONI (2001), por estresses causados pelo ataque de insetos, doenças, problemas fisiológicos e condições ambientais adversas. Os sintomas característicos desse processo compreendem as cloroses foliares (degradação dos pigmentos da clorofila), a perda das folhas, a degradação da estrutura da copa da árvore e a mortalidade, como apontam Deshayes et al. (2006).

A folha sadia apresenta mesófilo túrgido e com vários espaços porosos devido à presença de água. Ao afetar o equilíbrio interno de água, ocorre perda de vigor e deformação do mesófilo. Isso irá causar perda de reflexão na faixa do NIR (GARCIA, 1982). Já a ausência da clorofila ocasiona a menor absorção de REM nas bandas da região espectral do visível, resultando na maior reflectância, principalmente no verde e no vermelho, fazendo com que as folhas tenham aparência amareladas ou cloróticas (CARTER, 1993).

A detecção de doenças de plantas através de SR depende dos dados iniciais que ligam respostas espectrais à gravidade da doença. Sendo assim, identificar a assinatura espectral da doença ou do fator que esteja causando o estresse na planta é o primeiro passo para dispor dessa tecnologia (Zhang 2011). Cada doença ou praga tem uma forma singular para alterar a reflectância do tecido foliar, permitindo identificar as assinaturas espectrais específicas para cada uma (Mahlein 2012).

O estado fitossanitário da vegetação florestal tem relação com o termo “dano florestal” definido por Murtha (1972) como “qualquer tipo e intensidade de um efeito em uma ou mais árvores, que temporária ou permanentemente reduz o valor financeiro, impede ou remove a habilidade biológica de crescimento, reprodução ou ambos”.

Nesse sentido, a avaliação de danos envolve a contagem de indivíduos doentes, atacados e/ou estressados, a determinação de área de ocorrência do dano, a estimativa de queda de produção decorrente do dano, a estratificação da área de acordo com a intensidade do dano e multiplicar a área de várias intensidades de dano por volumes pré-determinados (MURTHA, 1978).

Segundo Cibula e Carter (1992), as regiões do espectro do visível são mais sensíveis a estresse e localizam-se nos intervalos de 530 a 640 μm e de 680 a 700 μm . Valores maiores de reflectância nas proximidades de 700 μm representam o deslocamento da borda vermelha para o azul.

Jensen (2009) indica o intervalo espectral de 680 a 800 μm , denominado borda do vermelho (*red-edge*), para avaliar a alteração abrupta do comportamento da curva espectral de um vegetal, provenientes de fatores relacionados à absorção pela clorofila e do espalhamento interno da REM

na folha. Percebe-se assim, que essa faixa espectral é importante para avaliar a sanidade da vegetação.

A quantificação do *red-edge* geralmente é alcançada através do cálculo da posição de borda vermelha (REP). Essa região é reconhecida como o ponto de inclinação máxima ao longo da *red-edge* e tem sido argumentada para fornecer estimativas melhoradas do teor de clorofila na folha e o teor de clorofila no dossel (HORLER et al., 1983; CURRAN et al., 1990).

O posicionamento da banda *red-edge* no espectro eletromagnético coincide com o aumento brusco de reflectância da vegetação fotossinteticamente ativa na faixa de transição entre o vermelho e o NIR. No vermelho, a vegetação sadia absorve a radiação eletromagnética incidente para realizar fotossíntese, enquanto no NIR, a estrutura celular da folha produz uma forte reflexão. Portanto, as variações, tanto no conteúdo de clorofila como na estrutura da folha, relacionadas com diferentes classes de vegetação, podem ser registradas mais apropriadamente por sensores que possuem bandas nessa faixa espectral, como é o caso do Sentinel-2 (SCHUSTER et al., 2012).

A determinação da posição da borda do vermelho é de suma importância, pois essa posição está intrinsecamente relacionada com as taxas de nitrogênio e clorofila foliar (JU et al., 2010). A partir disso, infere-se que os valores obtidos na determinação dessa borda são indicadores sensíveis de estresse da vegetação (JENSEN, 2009). Quanto mais próxima a posição da borda do vermelho estiver da região do visível, os níveis de clorofila e nitrogênio serão menores, sendo fortes indicativos da saúde da planta (CHO et al., 2006).

O termo *red-edge* foi descrito primeiramente por Collins em 1978, e desde então ganhou destaque em estudos relacionados ao estresse da vegetação (JU et al., 2010). Desde então, surgiram inúmeras técnicas para avaliação da posição da borda do vermelho, como a interpolação linear por quatro pontos proposta por Guyot e Baret (1988); o método linear proposto por Clevers (1994); a determinação do maior espectro de primeira derivada estudado por Dawson e Curran (1998) e a técnica polinomial desenvolvida por Pu et al. (2003).

3.3.3 Índices de vegetação (IV)

Os IV foram desenvolvidos visando entender as variáveis do dossel (AHAMED et al., 2011) e para explorar as propriedades espectrais da vegetação, especialmente nas faixas do visível e NIR, relacionados a parâmetros, como cobertura vegetal, biomassa e índice de área foliar (PONZONI; SHIMABUKURO, 2009). Índices de vegetação podem ainda ser úteis na diferenciação entre plantas doentes e saudáveis e na quantificação de doenças (MAHLEIN et al., 2010),.

A fundamentação dos IV diz respeito ao comportamento antagônico da reflectância da vegetação na região do visível e do NIR (Ponzoni e Shimabukuro 2007). A primeira região é caracterizada pela menor reflectância e a segunda pela maior reflectância, em função do espalhamento múltiplo da radiação eletromagnética nas diferentes camadas de folhas (JACKSON; HUETE, 1991; MYNENI et al., 1995).

Os índices representam fatores de crescimento e vigor da vegetação. Também podem ser utilizados para entender características biofísicas como o IAF, biomassa, porcentagem de cobertura do solo, atividade fotossintética e produtividade (Ponzoni e Shimabukuro, 2010). Além disso, esses índices reduzem a interferência de alguns fatores como o solo, vegetação senescente, ângulo solar, inclinação do terreno e atmosfera (GUTMAN et al., 1995; ALMEIDA et al., 2005) e possibilitam análises espaciais e temporais da atividade fotossintética terrestre, atuando no monitoramento sazonal, interanual e variações de longo prazo dos parâmetros estruturais, fonológicos e biofísicos da vegetação (WANG et al., 2003).

O Índice de Vegetação pela Diferença Normalizada (*Normalized Difference Vegetation Index*) (NDVI) proposto por Rouse et al. (1973) compara a reflectância da radiação do vermelho (RED) com a reflectância da radiação do NIR. Esse índice foi desenvolvido para diminuir os efeitos de diferença de iluminação, sombra, atenuação atmosférica e variação topográfica (HUETE et al., 2002). É um índice sensível a radiação fotossinteticamente ativa, sendo uma forma simples e confiável de mensurar o vigor da vegetação (THENKABAIL et al., 2002).

Para o cálculo desse índice, foram escolhidas bandas espectrais influenciadas pela absorção pela clorofila na folhagem da vegetação verde e conseqüentemente pela densidade dessa vegetação na superfície (FRANCISCO et al., 2012).

O NDVI possui aplicações relacionadas com a dinâmica de cobertura, registrando alterações que possam ocorrer devido a situações climáticas isoladas e ciclos fenológicos anuais (JACÓBSEN et al., 2004). Ortiz et al. (2011) indicam que esse índice também é apropriado para analisar características da vegetação relacionadas à nutrição, crescimento, produtividade, estresse ou deficiências, presença de ervas daninhas e quanto a danos causados por agentes químicos.

Outro IV muito utilizando é o Índice de Vegetação Ajustado para o Solo (*Soil-Adjusted Vegetation Index*) (SAVI). Introduzido por Huete (1988), esse índice também considera as reflectâncias da banda do vermelho e da banda do infravermelho próximo.

O desenvolvimento desse índice teve como finalidade reduzir as interferências causadas nos valores do NDVI, causadas pela reflectância do solo, durante as medições de reflectância de dosséis, em que o solo aparece ao fundo da vegetação. Com a formulação do NDVI, Huete (1988) sugeriu acrescentar o fator “L” ao cálculo. O mesmo autor também propôs três valores numéricos

para o fator “L”, dispensando desse modo o conhecimento prévio do tipo de solo, sendo de $L=1$ para vegetações muito esparsas, $L = 0,5$ para vegetações de densidades intermediárias e $L = 0,25$ para vegetações densas.

A partir do SAVI, foi proposto o Índice de Vegetação Ajustado para o Solo Modificado (*Modified Soil Ajusted Vegetation Index*) (MSAVI₂). O MSAVI₂ dispõe de um fator L indutivo para minimizar o “ruído” do solo que não foi cancelado pelo produto NDVI (ROSENDO, 2005).

Índices relacionados ao teor de antocianina foram desenvolvidos por Gitelson et al. (2001). A criação do Índice de Reflectância de Antocianina 1 e do Índice de Reflectância de Antocianina 2 (*Anthocyanin Reflectance Index 1* (ARI1) e *Anthocyanin Reflectance Index 2* (ARI2)) foram desenvolvidos por Gitelson et al. (2001) teve como objetivo calcular o conteúdo de antocianina em folhas com ampla variação de pigmento, cujo valor foi comparado com o valor medido de antocianina.

A análise da diferença entre a reflectância de carotenoides e clorofila na faixa espectral de 510 μm resultou na geração dos índices de Reflectância de Carotenoide 1 e 2 (*Carotenoid Reflectance Index 1* (CRI1) e *Carotenoid Reflectance Index 2* (CRI2)) por Gitelson et al. (2002). Os autores afirmam que esses fatores interferem nas reflectâncias nas faixas espectrais de 550 e/ou 700 μm .

A relação entre as bandas verde e *red-edge* proporcionou o desenvolvimento do índice de clorofila *red-edge* (*Chlorophyll Red-Edge* – CHR) por Gitelson et al. (2003). Isso foi possível pela relação inversamente proporcional dessas bandas ao teor de clorofila na folha.

O Índice de Vegetação Realçado (*Enhanced Vegetation Index* - EVI), foi criado por Huete et al. (1997) para otimizar o sinal da vegetação em regiões de alta biomassa. Modificado por Jiang et al. (2008), o Índice de Vegetação Realçado 2 (*Enhanced Vegetation Index 2* – EVI2), foi desenvolvido para sensores que não possuem a banda do azul.

Gitelson et al. (1996) examinaram imagens orbitais sobre áreas de vegetação adulta e áreas ocupadas por vegetação sob estado de senescência, objetivando avaliar taxas de concentração de pigmentações fotossinteticamente ativos e deficiências das vegetações. A partir dessa análise, os autores desenvolveram o Índice de Vegetação Verde da Diferença Normalizada (*Green Normalized Difference Vegetation Index*) (GNDVI).

O índice desenvolvido para utilizar as bandas *red-edge* é designado como Índice de Clorofila da Borda Vermelha Invertida – (*Inverted Red Edge Chlorophyll Index*) (IRECI), para caracterizar a inclinação usando a reflectância a 740 μm e 705 μm , utilizando reflectâncias de vegetação máxima e mínima encontradas no infravermelho e vermelho a 783 μm e 665 μm . Assim,

esse índice não coloca ênfase somente o vermelho, evitando a saturação, enquanto utiliza o forte contraste sensível ao IAF (GUYOT; BARET, 1988; CLEVERS et al., 2000).

Daughtry et al. (2000) propuseram o Índice de Reflectância Modificado da Absorção da Clorofila-a (*Chlorophyll Absorption in Reflectance Index*) (MCARI). Esse índice relaciona as profundidades das folhagens no dossel na determinação das taxas de absorção realizadas pela clorofila-, utilizando os comprimentos de onda de 550 μm , 670 μm e 700 μm (KIM et al., 1994). Embora seja um índice muito utilizado, vários estudos demonstram que é bastante sensível ao ruído em áreas de vegetação pouco densas e com baixo índice de área foliar e baixos teores de clorofila (HABOUDANE et al., 2002; WU et al., 2008). Além disso, Daughtry et al. (2000) afirmam que essa sensibilidade também está relacionada à reflectância do solo ao fundo da vegetação sobre a do dossel, a elementos não fotossinteticamente ativos componentes do dossel e às baixas concentrações de clorofila, sendo assim de difícil interpretação em vegetações de baixo IAF.

A avaliação da posição da borda vermelha utilizando dados do sensor MERIS ocasionou o desenvolvimento do Índice de Clorofila Terrestre MERIS (*MERIS Terrestrial Chlorophyll Index*) (MTCI) (DASH; CURRAN, 2004), a partir de três bandas de ondas vermelhas e na região do NIR centradas em 681,25 μm , 705 μm e 753,75 μm (faixas 8, 9 e 10 na configuração da banda padrão MERIS). O MTCI provou a potencialidade do seu uso para estimar o teor de clorofila em áreas espaciais muito extensas com alta resolução temporal (DASH; CURRAN, 2006).

A relação entre as bandas infravermelho e infravermelho de ondas curtas resultou na criação do Índice Infravermelho de Diferença Normalizada (*Normalized Difference Infrared Index* – NDI11) e Índice de Razão de Queima Normalizada (*Normalized Burn Ratio* – NBR (NDI12) por Key et al. (2002) e Hardisky et al. (1983).

O índice NDI45 foi desenvolvido por Delegido et al. (2011), na investigação das melhores bandas para usar na fórmula do NDVI para dados oriundos do Sentinel-2 sintetizados. Os autores descobriram que as bandas vermelho (banda 4) e banda *red-edge* 1 (banda 5) tiveram o melhor desempenho, formulando o índice NDI45.

Blackburn (1998) sugeriu estudos para determinar faixas espectrais para quantificar a concentração de pigmentos fotossinteticamente ativos em quatro espécies de árvores, através de medições em folhas individuais, para avaliação de estágios de senescência. Dessa forma, o Índice de Vegetação da Razão Simples para Pigmentação Específica (*Pigment Specific Simple Ratio*) (PSSRa) foi desenvolvido por esse autor. Os resultados desse estudo indicam que os melhores comprimentos de onda para quantificação da concentração de pigmentos fotossinteticamente ativos foram os de 680 μm para a clorofila-a, 635 μm para clorofila-b e 470 μm para os

carotenóides. Foram obtidas fortes correlações positivas do índice PSSRa com as concentrações, a nível foliar, de clorofila e fracas correlações com as concentrações de carotenóides.

Já o Índice de Reflectância da Senescência da Planta (*Plant Senescence Reflectance Index Near Infrared* – PSRI) foi desenvolvido por Merzylac et al. (1999) para descrever a dinâmica dos processos de senescência em folhas e frutos. Esse índice é sensível à relação carotenoide/clorofila.

Uma modificação do NDVI foi proposta por Fernández-Manso et al. (2016), utilizando a banda red-edge. Dessa forma, o Índice de Vegetação por Diferença Normalizada da Borda Vermelha (*Red-edge NDVI*) foi criado.

Os índices melhorados (*Red and Red-Edge Normalized Difference Vegetation Index* NDVI (NDVIRR) e *Red and Red-Edge Modified Chlorophyll Index* (CHRR) são baseados no forte contraste das reflectâncias entre o vermelho e o infravermelho, sendo sensíveis ao IAF. Além disso, a combinação de informações espectrais vermelhas e infravermelhas reduz a saturação e não enfatiza a reflectância da borda vermelha, o que ajudará a evitar a interrupção da alteração do teor de clorofila (XIE et al., 2018).

O Índice de Posição da Borda Vermelha - (*Red Edge Position Index*) (S2REP) baseia-se na interpolação linear apresentada por Guyot e Baret (1988) no qual a reflectância no ponto de inflexão é estimada e a posição é recuperada através da interpolação da banda 5 e 6 posicionadas na inclinação *red-edge*. Esse método de interpolação linear foi aplicado anteriormente aos dados MERIS por Clevers et al. (2000) revelando-se mais robusto do que o método Lagrangeano (DAWSON; CURRAN, 1998), com o benefício de exigir um número limitado de bandas espectrais tornando-o adequado para sensores espaciais (CLEVERS et al., 2002).

3.4 SENSORES REMOTOS

Rocha (2000a) afirma que o progresso do SR ocorreu através de sensores remotos melhorados e com resoluções adequadas. Além disso, a evolução das técnicas de extração de informações provenientes do PDI tornou essa ciência aplicada a diversos objetivos de estudo, como levantamento de recursos ambientais, análise ambiental, geologia, agricultura, florestas, estudos urbanos, entre outros.

O SR orbital pode gerar dados importantes sobre a superfície terrestre e características a nível local ou em escala regional, imageando porções do espectro eletromagnético além da região do visível. Isso torna possível um maior detalhamento dos objetos, especialmente aqueles de maior sensibilidade à região do infravermelho, como é o caso de estudos que envolvam a cobertura de vegetação (JENSEN, 2009).

Novo (2007) afirma que os sensores possuem três características básicas de resolução: (1) a resolução espectral, que expressa a largura das faixas de sensibilidade de cada banda do sensor; (2) a resolução espacial e (3) a resolução radiométrica. Essa resolução compreende a maior ou menor capacidade de um sistema sensor em detectar e registrar diferenças de reflectância e/ou emitância dos elementos da paisagem, sendo a capacidade do sensor registrar o número de níveis de intensidade que compõem o pixel. A resolução espacial é conceituada por Rosa (2007) como a mínima distância entre dois objetos (alvos), na qual um sensor pode registrá-los como sendo objetos distintos e é medida em pixels;

Os sensores utilizados para estudos de SR podem ser classificados em relação a fonte de energia em sensores ativos e passivos. Os sensores ativos são aqueles que emitem as ondas eletromagnéticas e captam as ondas refletidas pelos objetos na superfície terrestre, como por exemplo, o RADAR (*Radio Detection And Ranging*). Já os sensores passivos não possuem fonte própria de energia e por isso, captam a radiação refletida ou emitida pelo sol na superfície terrestre. Neste caso, a radiação eletromagnética é emitida pelo sol (MENESES; NETO, 2001).

Com a evolução das técnicas de SR nos últimos anos e com a variedade de sistemas sensores, o uso de produtos orbitais para agricultura aumentou. Isso está diretamente relacionado com o avanço significativo nas resoluções espaciais e radiométricas, além da inserção de bandas multiespectrais específicas sensíveis à vegetação (ZENGEYA, 2013).

Com a disponibilidade de bandas específicas a detecção do estresse da vegetação, como a banda *red-edge* presente nos sistemas orbitais comerciais WorldView-2 e 3, na constelação RapidEye e na missão Sentinel-2, tornou-se possível a detecção de áreas agrícolas infestadas por parasitas e pragas por meio de classificadores (GARRITY et al., 2013; SANCHES et al., 2013) detecção de níveis de pigmentos foliares por meio da aplicação de índices multiespectrais (EITEL et al., 2011; RAMOELO et al., 2012) e determinação de métricas na paisagem.

3.4.1 Sentinel-2

A Agência Espacial Europeia (*European Space Agency*) (ESA) desenvolveu a missão de satélites Sentinel-2 através do programa *Copernicus* (DRUSCH et al., 2012; HAGOLLE et al., 2015; SEGL et al., 2015). O satélite Sentinel-2A foi lançado em 23 de junho de 2015 e o lançamento do Sentinel-2B ocorreu em março de 2017. Apesar de lançados separadamente, os satélites estão na mesma órbita, com um deslocamento a 180° um do outro e descrevem uma órbita heliossíncrona. A posição de cada satélite Sentinel-2 em sua órbita é determinada através de um

receptor de Sistema de Navegação Global por Satélite (*Global Navigation Satellite System – GNSS*) de dupla frequência (ESA, 2017).

A altitude orbital média das constelações Sentinel-2 é de 786 km. A inclinação da órbita é de 98,62° e o Tempo Solar Médio Local (MLST) no nó descendente é 10:30 (AM). Este valor de MLST foi escolhido como um compromisso entre um nível adequado de iluminação solar e a minimização da cobertura de nuvem potencial. O valor MLST está próximo ao tempo de *overpass* local do Landsat e quase idêntico ao do SPOT-5, permitindo a integração de dados Sentinel-2 com missões existentes e históricas, e contribuindo para a coleta de dados de séries temporais de longo prazo (ESA, 2015).

O Sentinel-2 possui um instrumento de captura multiespectral, sendo que a câmera é a mais avançada do seu tipo, por incluir três bandas no “*red-edge*” que geram informações de suma importância sobre o estado da vegetação (TAQUIA, 2015). O *design* óptico do telescópio MSI permite um campo de visão de 290 km (FOV) (ESA, 2015).

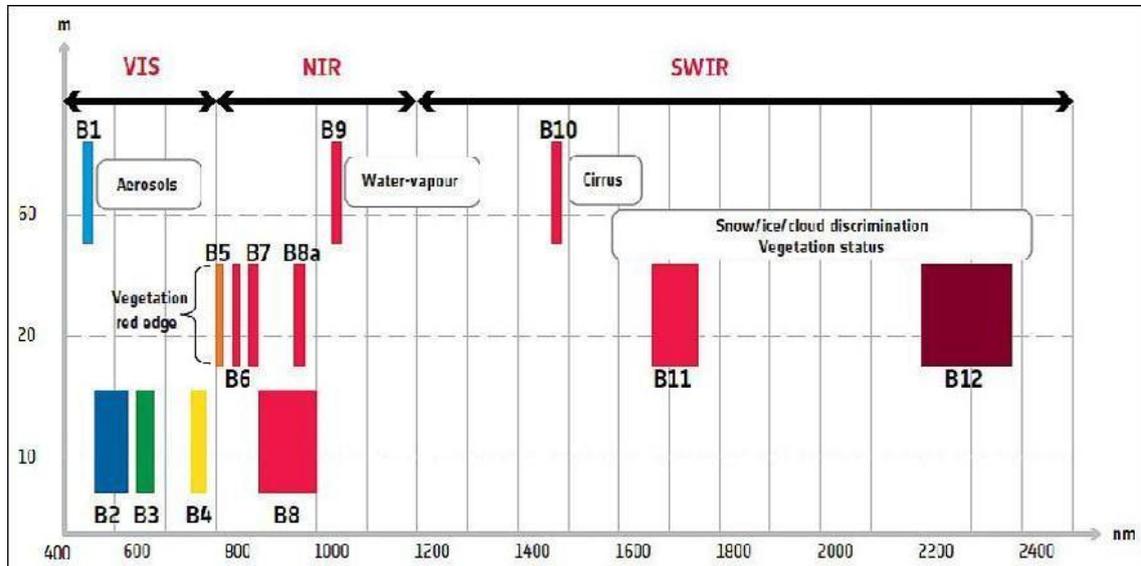
Cada satélite Sentinel-2 possui um sensor de imagem multiespectral (MSI) de alta resolução, com 13 bandas espectrais, que vão desde o visível ao infravermelho próximo ao infravermelho de ondas curtas, com quatro bandas a 10 m, seis bandas a 20 m e três bandas a 60 m de resolução espacial. As características das bandas espectrais estão descritas na Tabela 1 e podem ser visualizadas na Figura 6:

Tabela 1 - Bandas espectrais do Sentinel-2.

Bandas espectrais	Centro do λ (μm)	Resolução espacial (m)
1 (<i>Coastal aerosol</i>)	443	60
2 (<i>blue</i>)	490	10
3 (<i>green</i>)	560	10
4 (<i>red</i>)	665	10
5 (<i>red-edge 1</i>)	705	20
6 (<i>red-edge 2</i>)	740	20
7 (<i>red-edge 3</i>)	783	20
8 (NIR)	842	10
8A (<i>red-edge 4</i>)	865	20
9 (<i>water vapour</i>)	945	60
10 (<i>cirrus</i>)	1375	60
11 (SWIR 1)	1610	20
12 (SWIR 2)	2190	20
Resolução radiométrica	12 bits	
Resolução temporal	5 a 10 dias	
Dimensões da cena	100 x 100 km	
Sistema de projeção	UTM, Datum WGS 1984	

Em que: *Coastal aerossol*: aerossol; *blue*: azul; *green*: verde; *red*: vermelho; *red-edge 1*: borda vermelha 1; *red-edge 2*: borda vermelha 2; *red-edge 3*: borda vermelha 3; *red-edge 4*: borda vermelha 4; *NIR*: infravermelho próximo; *SWIR1*: infravermelho de ondas curtas 1; *SWIR2*: infravermelho de ondas curtas 2; UTM: *Universal Transversa de Mercator*; WGS: *World Geodetic System 1984*. Fonte: Elaborado pela Autora com base em ESA (2010).

Figura 3 - Resolução espacial da missão Sentinel-2.



Fonte: Elaborado pela Autora com base em ESA (2017).

Além disso, a missão Sentinel-2 possui resolução radiométricas de 12 bits, ou seja, as imagens podem ser adquiridas em um intervalo de 0 a 4095 números digitais (DN) e resolução temporal de 5 dias (ESA, 2017).

O sensor MSI coleta a REM refletida pelos alvos da superfície da Terra. À medida que o satélite se desloca em sua órbita, novos dados são obtidos. O feixe de luz que entra no sensor é dividido em um filtro e focado em dois conjuntos de plano focal separados dentro do instrumento; um para bandas da região do visível e NIR e um para bandas de SWIR (ESA, 2017).

Essas características espaciais (até 10 m) e novas capacidades espectrais (por exemplo, três bandas na borda vermelha mais duas bandas na SWIR), ampla cobertura (largura da faixa de 290 km) e tempo mínimo de revisão de cinco dias (com satélites gêmeos em órbita) gera dados extremamente úteis para uma vasta gama de aplicações terrestres (MALENOVSKÝ et al., 2012).

Ainda de acordo com ESA (2017), os objetivos da missão Sentinel-2 dizem respeito a: continuidade da imagem multiespectral fornecida pela série SPOT (*Système Pour l'Observation de la Terre*) de satélites e pelo instrumento de mapeamento temático da USGS (*United States Geological Survey*) Landsat (*Land Remote Sensing Satellite*) e fornecimento de dados relacionados a mapas de cobertura terrestre, mapas de detecção de mudanças de território e variáveis geofísicas.

Segundo Jaramaz et al. (2013), a missão Sentinel-2 fornecerá três níveis de produtos. O primeiro nível inclui produtos com correções radiométricas: correção de velocidade, exclusão de

pixels defeituosos, calibração relativa e absoluta e com correções geométricas. Já o segundo nível inclui correções atmosféricas e algoritmos de recuperação de variáveis geofísicas. O terceiro nível fornece a simulação de síntese de correções de nuvem dentro de uma imagem de Nível 2. A lista dos produtos de Nível 2A, 2B e Nível 3 necessários para a missão Sentinel-2 está representada na Tabela 2.

Tabela 2 - Lista de produtos de Nível 2A, 2B e Nível 3 da missão Sentinel-2.

Nome	Descrição	Nível de Produto
Reflectância de Fundo de Atmosfera - <i>Bottom-of-Atmosphere Reflectance</i> (ρ_{BOA})	Produto corrigido de forma atmosférica, incluindo rastreamento de nuvens e correção de efeitos de adjacência/ inclinação.	2A
Cobertura da Fração da Vegetação - <i>Fraction of Vegetation Cover</i> (FVC)	Porcentagem da superfície terrestre coberta pela vegetação.	2B
Índice de Área Foliar - <i>Leaf Area Index</i> (LAI)	Mapa com a área da folha verde por unidade de área do solo.	2B
Conteúdo de Clorofila na Folha - <i>Leaf Chlorophyll Content</i> (Cab)	Quantidade de clorofila por centímetro quadrado. Este produto tem relação com o índice MTCI, que diz respeito ao teor de clorofila da vegetação.	2B
Fração da radiação fotossinteticamente ativa absorvida - <i>Fraction of Absorbed Photosynthetically Active Radiation</i> (fAPAR)	Fração da radiação no domínio fotossintético (400-700nm) que é absorvida pelas folhas. Os valores variam entre 0 e 1.	2B
Conteúdo de Água na Folha - <i>Leaf Water Content</i> (Cw)	A quantidade de água em peso (gramas) ou volume (centímetros cúbicos) por unidade de peso foliar (gramas) ou volume (centímetros cúbicos). Este parâmetro pode ser detectado remotamente e é importante para estimar o potencial de transpiração e os balanços energéticos da vegetação.	2B
Capa Genérica da Terra - <i>Generic Land Cover</i> (GLC)	Capa terrestre com um conjunto de classes genéricas básicas compatíveis com as já utilizadas para serviços genéricos.	2B
Sintetizações Espaço-Temporal de produtos de Nível 1C ou 2A - STS	N/A	3

Fonte: Elaborado pela Autora com base em ESA (2010).

Em relação aos parâmetros biofísicos da vegetação, a Cobertura de Vegetação Fracionada (FVC) pode ser entendida como uma propriedade estrutural importante de um dossel vegetal, que corresponde ao complemento da unidade da fração do intervalo na direção do Nadir, representando a quantidade de vegetação distribuída em perspectiva horizontal (LSA SAF, 2012). A FVC também é um indicador sensível da degradação da terra e da desertificação em regiões áridas e semi-áridas e, se facilmente medido, pode ser usado para estudar esses processos (PUREVDORJ et al., 1998).

O Índice de Área da Folha (IAF) foi definido por Watson (1947) como a área unilateral total de tecido foliar por unidade de área de superfície do solo, dando um valor adimensional, representando o total de área unilateral de folhas verdes por área do solo (JONCKHEERE et al., 2004), caracterizando a estrutura e o funcionamento da cobertura vegetal (SCURLOCK et al., 2001). Este parâmetro biofísico está correlacionado com os teores de clorofila foliar e de dossel, taxa de fotossíntese, estágios de crescimento, ciclos de carbono e nutrientes e biomassa seca e fresca (CLEVERS et al., 2001; APARICIO et al., 2002; COYNE et al., 2009).

Já o teor de clorofila da folha (Cab) é um indicador da atividade fotossintética (HOLDEN, 1976; LICHTENTHALER, 1987) e está diretamente relacionado à capacidade das plantas para assimilar o CO₂, então o conhecimento do teor de clorofila em escala regional e global é importante na ecologia (CRAMER; FIELD, 1999).

Já a fração da radiação fotossinteticamente ativa absorvida (fAPAR) corresponde à fração de radiação fotossinteticamente ativa absorvida pelo dossel e expressa a capacidade de absorção de energia de um dossel (FENSHOLT et al., 2004). O valor fAPAR resulta diretamente do modelo de transferência radiativa no dossel que é computado e depende tanto da estrutura do dossel quanto das condições de iluminação; portanto, fAPAR depende da posição solar (BARET et al., 2006). O fAPAR é uma medida de quão grande parte das folhas da luz solar absorvem no espectro de 0.4-0.7 µm (FENSHOLT et al., 2004).

3.5 VEÍCULOS AÉREOS NÃO TRIPULADOS - VANT

De acordo com a Agência Nacional de Aviação Civil (ANAC, 2015), Veículos Aéreos não Tripulados (VANT), são conceituados como aeronaves projetadas para operações sem pilotos a bordo. Em inglês, esses veículos são denominados como *Unmanned Aerial Vehicles/Systems* (UAV/UAS) e são conhecidos popularmente como *Drones*.

Segundo a ABA - (Associação Brasileira de Aeromodelismo), a definição para Veículo Aéreo Não Tripulado (VANT) é: “um veículo capaz de voar na atmosfera, fora do efeito de solo, que foi projetado ou modificado para não receber um piloto humano e que é operado por controle remoto ou autônomo” (JORGE; INAMASU, 2014).

A primeira utilização do VANT foi para objetivos militares, porém, seu uso tem se tornado cada vez mais amplo (PURI, 2005). Tal potencial de uso está diretamente relacionado ao baixo custo, à alta mobilidade, à segurança oferecida e à velocidade de aquisição e transferência de dados, como imagens e vídeo. Além disso, os VANT podem ser utilizados em situações em que uma inspeção tripulada não seja possível (MORGENTHAL; HALLERMANN, 2014).

Diversos países estão desenvolvendo trabalhos utilizando VANT para diferentes mercados. Entre eles, destacam-se: Estados Unidos, Japão, Coreia do Sul, Austrália, França, Inglaterra, Itália, Alemanha e África do Sul (SIMPSON, 2003; DE GARMO, 2004).

No Brasil, os primeiros relatos de VANT ocorreram na década de 1980, quando o Centro Tecnológico Aeroespacial (CTA) desenvolveu o projeto Acauã com fins militares. Tal trabalho foi reativado em 2007 como uma iniciativa do governo de incentivo ao desenvolvimento de VANT no país. Mais tarde, o Centro de Pesquisas Renato Archer (CENPRA) desenvolveu o projeto do dirigível AURORA (*Autonomus Unmanned Remote Monitoring Robotic Airship*), que serviu para capacitar a equipe de desenvolvimento. Dentre as aplicações civis, principalmente focado na agricultura surgiu o projeto ARARA (Aeronave de Reconhecimento Assistida por Rádio e Autônoma) (JORGE, 2001). Entre os anos de 1999 a 2005, outra iniciativa de VANT surgiu no país, com o esforço na construção de uma aeronave com asa fixa, tendo um resultado satisfatório em 2006 (TRINDADE JUNIOR et al., 2004; JORGE et al., 2014).

Um VANT é formado por três elementos principais: estação de base, carga embarcada (câmeras e baterias) e a aeronave. A primeira se refere ao centro de controle, sendo instalada onde a aeronave será lançada. Esse local já foi definido previamente a partir de um planejamento e pode ocorrer do plano de voo ser realizado a partir de uma estação de controle central ou em um escritório (AUSTIN, 2010). A estação de base é responsável por informações sobre o voo, como velocidade, altitude, temperatura, posição geográfica da aeronave, entre outros. Já a carga embarcada refere-se aos equipamentos de filmagem e fotografia (câmeras fotográficas, de vídeo e câmeras de sensor infravermelho), equipamentos de comunicações, sensores aéreos e de georreferenciamento, receptores de sinais GPS (*Global Positioning System*) e sistemas inerciais (BARNHART et al., 2012).

Para realizar estudos envolvendo SR, o VANT deve dispor de receptores GNSS (*Global Navigation Satellite System*), sistema inercial (IMU), baterias e sistema sensor que podem ser multiespectrais e hiperspectrais, sensores termais, radares, LASER (*Light Amplification By Stimulated Emission Of Radiation*) scanners, espectrômetros (JENSEN, 2009; HONKAVAARA et al., 2013; BURKART et al., 2014; COLOMINA; MOLINA, 2014;). Também pode ser possível a transmissão em tempo real das imagens obtidas pelos instrumentos utilizando tecnologias sem fio para uma base principal ou ser armazenada em gravadores a bordo (JENSEN, 2009).

De acordo com Hakala et al. (2010) os aerolevantamentos realizados por VANT são mais flexíveis do que aqueles com as aeronaves tripuladas tradicionais. As imagens obtidas por esses veículos possuem uma resolução espacial de centímetros e com possibilidade de não sofrer com a cobertura de nuvens (ZHANG; KOVACS, 2012).

Os índices para caracterizar a vegetação extraídos de imagens obtidas por VANT dependem do tipo de sensor imageador instalado. Os mais comuns que podem ser calculados são: NDVI, GNDVI, SAVI. Tais índices são utilizados em estudos para quantificar parâmetros biofísicos da vegetação, incluindo o IAF (LELONG et al., 2008; HUNT JR et al., 2010, XIANG e TIAN, 2011; PRIMICIERO et al., 2012; EHSANI et al., 2012).

O VANT apresenta vantagens de utilização, como por exemplo: custo de aquisição variável, de sistemas de controle de voo e telemetria; apresentam a autonomia de voo compatível com o porte e custo do aparelho; baixo peso, segurança e confiabilidade na operação e capacidade de voo a baixas altitudes. Isso possibilita o registro de fotos aéreas sem obstáculos, o que não aconteceria se as imagens fossem obtidas por aviões convencionais e satélites (AMORIM et al., 2012).

Além do Modelo Digital de Superfície (MDS), o produto do mapeamento com VANT compreende um mosaico de imagens da área coberta pelo voo. O mosaico pode ser definido como um conjunto constituído por um bloco de imagens aéreas adjacentes e unidas sistematicamente pelo devido ajuste e sobreposição de suas margens vizinhas, de maneira a se obter uma representação contínua da superfície (RAFFO, 2000); podendo ser dividido em três classes: controlado, não controlado e semicontrolado (SANTOS, 2004).

Os mosaicos controlados necessitam da implantação de pontos de controle na área onde será realizado o voo como forma de orientação do modelo fotogramétrico em relação a vertical e corrigir sua escala (ROSALEN, 1997), com destaque para o uso de pontos de controle. Segundo Galvão (2014), pontos de controle possuem coordenadas definidas em campo a partir de métodos de posicionamento, destacando os que utilizam GNSS. Contudo, esse processo demanda tempo e recursos, podendo encarecer o mapeamento fotogramétrico via VANT.

O VANT pode ser classificado de acordo com sua categoria funcional como alvos, sistemas de reconhecimento ou monitoramento, combate e logística. Quanto ao alcance e altitude o VANT se classifica em: de mão, com 600m altitude e alcance 2km; curto alcance, com 1500m de altitude e 10km de alcance; OTAN, de 3000m de altitude e alcance até 50km; tático, de 5500m de altitude e alcance de 160km; MALE (altitude média, alcance longo), até 9000m de altitude e alcance de 200km; HALE (altitude alta, alcance longo), acima de 9100m e altitude e alcance indefinidos; HIPERSÔNICO, 15200m de altitude e alcance acima de 200km; ORBITAL em baixa órbita e CIS, transporte lua-terra. Além desses critérios, diferem em asa fixa ou rotativa. Os de asas rotativas, podem ser do tipo helicóptero convencional ou multirotor (JORGE; INAMASU, 2014).

O uso de VANT em agricultura de precisão tem focado no uso de sensores baseados na espectroscopia de reflectância, ou seja, em medidas da reflexão da radiação eletromagnética

(REM) após interação com diferentes superfícies em diferentes comprimentos de onda, oriunda do chamado espectro refletido, mais especificamente abrangendo a região do visível, NIR e SWIR (JORGE; INAMASU, 2014).

Nesse contexto, uma aplicação relevante para a área florestal é o monitoramento remoto da vegetação utilizando VANT, pois permite um monitoramento confiável e frequente quando comparado com satélites (Mulla, 2013). Isso se deve ao fato dessas aeronaves serem equipadas com sensores de ultra alta resolução espacial, como câmeras miniaturizadas de banda estreita e hiperespectrais e térmicas (BENDIG et al., 2012).

REFERÊNCIAS

AGÊNCIA NACIONAL DE AVIAÇÃO CIVIL (ANAC). **Regulamento Brasileiro da aviação Civil Especial (RBAC-E nº94)**. Brasília, DF: 2015. Disponível em: <<http://www2.anac.gov.br/transparencia/audiencia/2015/aud13/anexoI.pdf>>. Acesso em: 12 jun. 2017.

AGUIAR, L. M. **Os primatas do corredor do Alto Rio Paraná (região de Porto Rico, Estados do Paraná e Mato Grosso do Sul): ocorrência, georreferenciamento e parâmetros populacionais**. 2006. 110 f. Dissertação (Mestrado em Zoologia) – Universidade Federal do Paraná, Curitiba. 2006.

AHAMED, T.; TIAN, L.; ZHANG, Y.; TING, K. C. A review of remote sensing methods for biomass feedstock production. **Biomass and Bioenergy**, v. 35, n. 7, p. 2455–2469, 2011.

ALMEIDA, T. S.; FONTANA, D. C.; MARTORANO, L.G.; BERGAMASCH, H. Índices de vegetação para a cultura da soja em diferentes condições hídricas e de sistema de manejo do solo. In: Simpósio Brasileiro de Sensoriamento Remoto, 12. Goiânia. **Anais...** São José dos Campos: INPE, p.17-24, 2005.

AMORIM, A. L.; SILVA, L. S.; CHRISTAKOU, E. D. Uso de VANT em documentação arquitetônica. In: Seminário nacional de documentação do patrimônio arquitetônico como uso de tecnologias digitais, Belém. **Anais...** Belém: LACORE/UFPA, 2012.

APARICIO, N.; VILLEGAS, D.; ARAUS, J. L.; CASADESUS, J.; ROYO, C. Relationship between growth traits and spectral vegetation indices in durum wheat. **Crop Science**, v. 42, n.1, p. 1547– 1555, 2002. (DOI: 10.2134/agronj2000.92183x).

AUSTIN, R. **Unmanned Aircraft Systems: UAVs design, development and deployment**. Wiltshire: John Wiley & Sons Ltd, 332 p. 2010.

BARBIER, N.; COUTERON, P.; GASTELLY-ETCHEGORRY, J.P.; PROISY, C. Linking canopy images to forest structural parameters: potential of a modeling Framework. **Annals of Forest Sciences**, v. 69, p. 305-311, 2012. DOI 10.1007/s13595-011-0116-9.

BARET, F.; PAVAGEAU, K.; BÉAL, D.; WEISS, M.; BERTHELOT, B.; REGNER, P. **Algorithm Theoretical Basis Document for MERIS Top of Atmosphere Land Products (TOA_VEG)**. ESA. 2006. 25p.

BARNHARDT, R.K.; HOTTMAN, S.B.; MARSHALL, D.M.; SHAPPEE, E. **Introduction to Unmanned Aircraft Systems**. Boca Raton: CRC Press. 2012. 233 p.

BERNARDO, C. S. S.; GALETTI, M. Densidade e tamanho populacional de primatas em um fragmento florestal no sudeste do Brasil. **Revista Brasileira de Zoologia**, Curitiba, v. 21, n. 4, p. 827-832, 2004.

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

BLACKBURN, G. A. Hyperspectral remote sensing of plant pigments. **Journal of Experimental Botany**, v. 58, p. 844-867, 2007.

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. Publicado originalmente no Diário Oficial da República Federativa do Brasil, em 13 fev. 1998 e retificado em 17 fev. 1998. Disponível em: <http://www.planalto.gov.br/ccivil_03/leis/L9605.htm>. Acesso em: 8 jun. 2017.

BRASIL, 1965. Lei nº 4.771 de 15 de setembro de 1965. Código Florestal. **Diário Oficial da República Federativa do Brasil**, Poder Legislativo, Brasília, DF, 16 de set. Seção 1. p. 9529-9531.

BENDIG, J.; BOLTEN, A.; BARETH, G. Introducing a low-cost mini-UAV for thermal- and multispectral- imaging. **The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. XXXIX-B1, p. 345–349, 2012. DOI (<https://doi.org/10.5194/isprsarchives-XXXIX-B1-345-2012>).

BERNI, J.; ZARCO-TEJADA, P.; SUAREZ, L.; FERERES, E. Thermal and narrowband multispectral remote sensing for vegetation monitoring from an unmanned aerial vehicle. **Geoscience and Remote Sensing, IEEE Transactions on Geoscience and Remote Sensing**, v. 47, n. 3, p. 722-738, 2009.

BURKART, A.; COGLIATI, S.; SCHICKLING, A.; RASCHER, U. A novel uav-based ultra-light weight spectrometer for field spectroscopy. **IEEE Sensors Journal**, v. 14, n. 1, p. 62-67, 2014.

CALDERÓN, R.; NAVAS-CORTÉS, J.A.; ZARCO-TEJADA, P.J. Early Detection and Quantification of Verticillium Wilt in Olive Using Hyperspectral and Thermal Imagery over Large Areas. **Remote Sensing**, v. 7, p. 5584-5610, 2015.

CARTER, G. A. Primary and Secondary effects of the water content of the spectral reflectance of leaves. **American Journal of Botany**, v. 74, n. 7, p. 916-924, 1993.

CENTENO, J.A.S. **Sensoriamento Remoto e processos de imagens digitais**. Editora UFPR, Curitiba, 2009, 234 p.

CHO, M. A.; SKIDMORE, A. K. A new technique for extracting the red edge position from hyperspectral data: The linear extrapolation method. **Remote Sensing of Environment**, v. 101, p. 181–193, 2006.

CIBULA, W. G.; CARTER, G. A. Identification of a far-red reflectance response to Ectomycorrhizae in Slash Pine. **International Journal of Remote Sensing**, v. 13, n. 5, p. 925-932, 1992.

CLEVERS, J. G. P. W.; **Imaging Spectrometry in Agriculture**. Plant Vitality and Yield Indicators. Dordrecht, Netherlands: Kluwer Academic, p. 193-219, 1994.

CLEVERS, J.G.P.W. **Imaging spectrometry in agriculture, plant vitality and yield indicators**. In: *Imaging Spectrometry - A tool for environmental observations*. Eds. J. Hill and J. Megier. Kluwer Academic, Dordrecht, The Netherlands, p. 193-219, 1994.

CLEVERS, J.G.P.W., DE JONG, S.M., EPEMA, G.F., ADDINK, E. MERIS and the Red- Edge Index. Second EARSeL Workshop on Imaging Spectroscopy, Enschede. 2000.

CLEVERS, J. G. P. W.; DE JONG, S. M.; EPHAMA, G. F.; VAN DER MEER, F.; BAKKER, W. H.; SKIDMORE, A. et al. MERIS and the red-edge position. **International Journal of Applied Earth Observation and Geoinformation**. v. 3, p. 313–320, 2001.

CLEVERS, J.G.P.W., DE JONG, S.M., EPEMA, G.F., VAN DER MEER, F., BAKKER, W.H., SKIDMORE, A.K. Derivation of the red edge index using MERIS standard band setting. **International Journal of Remote Sensing**. v. 23, n. 16. p. 3169–3184. 2002.

CLEVERS, J.G.P.W.; GITELSON, A.A. Remote estimation of crop and grass chlorophyll and nitrogen content using red-edge bands on Sentinel-2 and -3. **International Journal of Applied Earth Observation and Geoinformation**, v. 23, p. 344–351, 2013.

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

COYNE, P. I.; AIKEN, R. M.; MAAS, S. J.; LAMM, F. R. Evaluating yield tracker forecasts for maize in western Kansas. **Agronomy Journal**, v. 101, n. 3, p. 671–680, 2009.

CRAMER, W.; FIELD, C.B. The potsdam NPP model intercomparison. **Global Change Biology**, v. 5, n. 1, p. 76, 1999.

CURRAN, P.J. **Principles of Remote Sensing**. Logman, New York, p. 8-55, 1986.

CURRAN, P.J., DUNGAN, J.L., GHOLZ, H.L. Exploring the relationship between reflectance red edge and chlorophyll content in slash pine. **Tree Physiology**. v. 7, p. 33–48, 1990.

D'ARCO, E. **O uso de geotecnologias para estimativa de área plantada de arroz irrigado no Estado do Rio Grande do Sul**. 2007. 206f. Tese (Doutorado) - Programa de Pós-graduação em Sensoriamento Remoto, Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2007.

DASH, J.; CURRAN, P. J. The MERIS terrestrial chlorophyll index. **International Journal of Remote Sensing**, v. 25, n. 23, p. 5403-5413, 2004.

DASH, J.; CURRAN, P.J. Relationship between herbicide concentration during the 1960s and 1970s and the contemporary MERIS Terrestrial Chlorophyll Index for southern Vietnam. **International Journal of Geographical Information Science**, v. 20, n. 8, p. 929–939, 2006.

DAUGHTRY, C.S.T.; WALTHALL, C.L.; KIM, M.S.; BROWN DE COLSTOUN, E.; MCMURTREY III, J.E. Estimating corn leaf chlorophyll concentration from leaf and canopy reflectance. **Remote Sensing of Environment**, v. 74, p. 229-239, 2000.

DAWSON, T.P., CURRAN, P.J. A new technique for interpolating the reflectance red edge position. **International Journal of Remote Sensing**, v. 19, p. 2133–2139, 1998.

DE GARMO, M. T. **Issues Concerning Integration of Unmanned Aerial Vehicles in Civil Airspace**. Center for Advanced Aviation System Development – Mitre, McLean, Virginia. 2004.

DELEGIDO, J.; VERRELST, J.; ALONSO, L.; MORENO, J. Evaluation of Sentinel-2 rededge bands for empirical estimation of green LAI and chlorophyll content. **Sensors**, v. 11, p. 7063–7081, 2011.

DESHAYES, M.; GUYON, D.; JEANJEAN, H.; STACH, N.; JOLLY, A.; HAGOLLE, O. The contribution of remote sensing to the assessment of drought effects in forest ecosystems. **Annales Forest Science**, v. 63, p. 579-595, 2006.

DINANT, S. Phloem, transport between organs and long-distance signalling. **Comptes Rendus Biologies**, v. 331, n. 5, p. 334-346, 2008.

DOBNER JR, M.; HIGA, A. R.; TOMAZELLO FILHO, M. Manejo de Povoamentos de *Pinus taeda* L. e de *Eucalyptus dunnii* MAIDEN para usos múltiplos da madeira. In: 4º Congresso Florestal Paranaense, 2012, Curitiba. **Anais**, 2012.

DRONAR. Tudo sobre o mercado de DRONES. Disponível em: <http://dronar.com.br/phantom-4-pro-tudo-sobre-o-novo-drone-dji-preco-especificacoes/>. Acesso em: 16 jun 2017.

EHSANI, R.; SANKARAN, S.; MAJA, J. M.; CAMARGO NETO, J. Affordable multi-rotor remote sensing plataforma for applications in precision horticulture. In: 11 th International **Conference Precision Agriculture**, July 15-18, 2012, Indianapolis.

EITEL, J. U. H; VIERLING, L. A.; LITVAK, M. E.; LONG, D. S.; SCHULTHESS, U.; AGER, A. A.; KROFCHECK, D. J.; STOSCHECK, L. Broadband, red-edge information from satellites improves early stress detection in a New Mexico conifer woodland. **Remote Sensing of Environment**, v. 115, i. 12, 15, p. 3640–3646, 2011.

ELACHI, C. **Introduction to the Physics and Techniques of Remote Sensing**. XVII +. Chichester, New York, 1987. 413 p.

ELLIOT, D. G. **Review of the Primates**. New York: American Museum of Natural History, 1913. 382 p.

EMBRAPA FLORESTAS. **Aplicativo para cálculo de perdas por macaco-prego: Macaco-prego Calc**. Disponível em: <<https://www.embrapa.br/florestas/programa-macaco-prego>>. Acesso em: 14 jun. 2017.

EPAGRI. **Empresa de Pesquisa Agropecuária e Extensão Rural de Santa Catarina**. Disponível em <<http://www.epagri.sc.gov.br/>>. Acesso em 09 jun 2017.

ERBERT, M.; HAERTEL, V. **Uso da análise discriminante regularizada (RDA) no reconhecimento de padrões em imagens digitais hiperespectral de Sensoriamento Remoto**. 118p. 2001. Dissertação (Mestrado no Programa de Pós-Graduação em Sensoriamento Remoto). Universidade Federal do Rio Grande do Sul, Porto Alegre. 2001.

ESA. **GMES Sentinel-2 Mission required document**. 2010. Disponível em: http://esamultimedia.esa.int/docs/GMES/Sentinel-2_MRD.pdf. Acesso em: 09 set. 2017.

ESA. **Introducing Sentinel-2**. Disponível em: http://www.esa.int/Our_Activities/Observing_the_Earth/Copernicus/Sentinel-2/Introducing_Sentinel-2. Acesso em: 06 jun. 2017.

FENSHOLT, R.; SANDHOLT, I.; RASMUSSEN, M.S. Evaluation of MODIS LAI, fAPAR and the relation between fAPAR and NDVI in a semi-arid environment using in situ measurements. **Remote Sensing of Environment**, v. 91, n. 3–4, p. 490-507, 2004.

FERNÁNDEZ-MANSO, A.; FERNÁNDEZ-MANSO, O.; QUINTANO, C. SENTINEL-2A red-edge spectral indices suitability for discriminating burn severity. **International Journal of Applied Earth Observation and Geoinformation**, v. 50, p. 170–175, 2016.

FERREIRA, F.A. **Patologia Florestal: Principais Doenças Florestais no Brasil**. Sociedade de Investigações Florestais, Viçosa, p. 1-570, 1989.

FRAGASZY, D. M.; VISALBERGHI, E.; ROBINSON, J. G. Variability and adaptability in the genus *Cebus*. **Folia Primatologica**, v. 54, n. 3-4, 1990.

FRANCISCO, P. R. M.; CHAVES, I. B.; LIMA, E. R. V.; BANDEIRA, M. M.; SILVA, B. B. Mapeamento da Caatinga com uso de geotecnologia e análise da umidade antecedente em bacia hidrográfica. **Revista Brasileira de Geografia Física**, Recife, v. 5, n. 3, p. 676-693, 2012.

FOSTER, A.C.; WALTER, J.A.; SHUGART, H.H. SIBOLD, A.; NEGRON, J. Spectral evidence of early-stage spruce beetle infestation in Engelmann spruce. **Forest Ecology and Management**, v. 384, p. 347-357, 2017.

GALETTI, M.; PEDRONI, F. Seasonal Diet of capuchin monkeys (*Cebus apella*) in a semideciduous forest in South East Brazil. **Journal of Tropical Ecology**, v. 10, p. 27-39, 1994.

GALVÃO, G. M. **Acurácia da mosaicação gerada por veículo aéreo não tripulado utilizado na agricultura de precisão**. 2014. ix, 39 f. Trabalho de conclusão de curso (Bacharelado - Agronomia) - Universidade Estadual Paulista, Faculdade de Ciências Agrárias e Veterinárias de Jaboticabal, 2014.

GARCIA, G. J. **Sensoriamento remoto: princípios e interpretação de imagens**. Editora Nobel, UNESP, Campos de Rio Claro (SP), 1982. p. 248-293.

GHINI, R.; BETTIOL, W. Proteção de plantas na agricultura sustentável. **Cadernos de Ciência & Tecnologia**, Brasília, v.17, n.1, p. 61-70, 2000.

GITELSON, A. A.; KAUFMAN, Y. J.; MERZLYAK, M. N. Use of a channel in remote sensing of global vegetation from EOS-MODIS. **Remote Sensing of Environment**, New York, v. 58, n. 3, p. 289-298, 1996.

GITELSON, A.A.; MERZLYAK, M.N.; CHIVKUNOVA, O. B.; GITELSON, A.A.; MERZLYAK, M.N.; CHIVKUNOVA, O.B. Optical properties and nondestructive estimation of anthocyanin content in plant leaves. **Photochemistry and Photobiology**, v. 74, n. 1, p. 38–45, 2001.

GITELSON, A.A.; ZUR, Y.; CHIVKUNOVA, O.B.; MERZLYAK, M. N. Assessing carotenoid content in plant leaves with reflectance spectroscopy. **Photochemistry and Photobiology**, v. 75, n. 3, p. 272–281, 2002.

GITELSON, A. A.; VIÑA, A.; ARKEBAUER, T. J.; RUNDQUIST, D. C.; KEYDAN, G.; LEAVITT, B. Remote estimation of leaf area index and green leaf biomass in maize canopies. **Geophysical Research Letters**, v. 30, n. 5, n/a-n/a, 2003.
<https://doi.org/10.1029/2002GL016450>

GITELSON, A. A. Remote estimation of canopy chlorophyll content in crops. **Geophysical Research Letters**, v. 32, n. 8, p. L08403, 2005.

GRESSLER, E.; PIZO, M. A.; MORELLATO, L. P. C. Polinização e dispersão de sementes em Myrtaceae do Brasil. **Revista Brasileira de Botânica**, São Paulo, v. 29, n. 4, p. 509-530, 2006.

GROVES, C.P. **Primate Taxonomy**. Smithsonian Institution Press, Washington, D.C, 2001. 350p.

GUAN, J., NUTTER JR., F.W. Relationships between defoliation, leaf area index, canopy reflectance, and forage yield in the alfalfa-leaf spot pathosystem. **Computers and Electronics in Agriculture**, v. 37, p. 97–112, 2002.

GUTMAN, G.; TARPLEY, D.; IGNATOV, A. The enhanced NOAA global land dataset from the Advanced Very High Resolution Radiometer. **Bulletin of the American Meteorological Society**, v. 76, n. 7, p. 1141-1156, 1995.

GUYOT, G. BARET, F. Utilization de la haute resolution spectrale pour suivre l'état des couverts vegetaux. In: Proceedings, 4th International Colloquium "Spectral Signatures of Objects in Remote Sensing", Aussois, 18–22 January 1988, Paris: ESA, ESA, Publication SP-287, pp. 279–286. 1998.

HABOUDANE, D.; MILLER, J. R.; TREMBLAY, N.; ZARCO-TEJADA, P. J.; DEXTRAZE, L. Integrated narrow-band vegetation indices for prediction of crop chlorophyll content for application to precision agriculture. **Remote Sensing of Environment**, v. 81, n. 2, p. 416-426, 2002.

HAGOLLE, O.; SYLVANDER, S.; HUC, M.; CLAVERIE, M.; CLESSE, D.; DECHOZ, C.; LONJOU, V.; POULAIN, V. SPOT-4 (Take 5): simulation of Sentinel-2 time series on 45 large sites. **Remote Sensing**, v. 7, n. 9, p. 12242-12264, 2015.

HAKALA, T.; SUOMALAINEN, J.; PELTONIEMI, J. Acquisition of bidirectional reflectance factor dataset using a micro unmanned aerial vehicle and a consumer camera. **Remote Sensing**, n. 2, p. 819-832, 2010.

HAVAŠOVÁ, M.; BUCHA, T.; FERENČÍK, J.; JAKUŠ, R. Applicability of a vegetation indices-based method to map bark beetle outbreaks in the High Tatra Mountains. **Annals of Forest Research**, v. 58, n. 2, p. 295-310, 2015.

HARDISKY, M.; KLEMAS, V.; SMART, R. The Influences of Soil Salinity, Growth Form, and Leaf Moisture on the Spectral Reflectance of *Spartina Alterniflora* Canopies. **Photogrammetric Engineering and Remote Sensing**, v. 49, 77–83, 1983.

HOLDEN, M. **Chlorophylls**. In: Goodwin, T.W. (Ed.), London: Academic Press. Chemistry and Biochemistry of Plant Pigments, v. 2, p. 1-37, 1976.

HONKAVAARA, E.; SAARI, H.; KAIVOSOJA, J.; PÖLÖNEN, I.; HAKALA, T.; LITKEY, P.; MÄKYNEN, J.; PESONEN, L. Processing and assessment of spectrometric, stereoscopic imagery collected using a lightweight UAV Spectral Camera for Precision Agriculture. **Remote Sensing**, n. 5, p. 5006-5039, 2013.

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

HOWARD, J. A. **Remote sensing of forest resources: theory and application**. Chapman & Hall, London, 1991. 419 p.

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

HUETE, A. R.; LIU, H.Q.; LEEUWEN, W.V. A Comparison of Vegetation Indices over a Global Set of TM Images for EOS-MODIS. **Remote Sensing of Environment**, New York, n.59, p.440-451, 1997.

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

HUNT JR., E. R.; HIVELY, W. D.; FUJIKAWA, S. J.; LINDEN, D. S.; DAUGHTRY, C. S. T; MCCARTY, G. W. Acquisition of NIR-Green-Blue digital photographs from unmanned aircraft for crop monitoring. **Remote Sensing**, n. 2, p. 290-305, 2010.

IEDE, T. E., PENTEADO, S. R. C., REIS-FILHO, W., SCHAITZA, E. G. Situação atual do Programa de Manejo Integrado de *Sirex noctilio* no Brasil. Instituto de Pesquisas e Estudos Florestais – IPEF, **Série Técnica IPEF**, n. 33, v. 13, p. 11-20, 2000.

IEDE, E.T. Importância das pragas quarentenárias florestais no comércio internacional: estratégias e alternativas para o Brasil. Colombo: Embrapa Florestas. **Boletim de pesquisa e desenvolvimento**, 22, 2005. 35 p.

INDÚSTRIA BRASILEIRA DE ÁRVORES. **IBÁ: Indústria Brasileira de Árvores**. Brasília, DF, 2014. 97 p. Relatório Ibá 2014. Indicadores de desempenho do setor nacional de árvores plantadas referentes ao ano de 2013. Disponível em: <http://www.iba.org/images/shared/iba_2014_pt.pdf>. Acesso em: 8 jun. 2017.

INDÚSTRIA BRASILEIRA DE ÁRVORES. **IBÁ: Indústria Brasileira de Árvores**. Anuário Estatístico 2016. Disponível em: <<http://www.iba.com.br/>>. Acesso em 04 jun. 2017.

IUCN. **The IUCN Red List of Threatened Species**. Version 2012.1. Disponível em: <<http://www.iucnredlist.org>>, 2012. Acesso em: 08 jun 2017.

IZAWA, K. Social behavior of the wild black-capped capuchin (*Cebus apella*). **Primates**, Kyoto, v. 21, n. 4, p. 443-467, 1980.

JACKSON, R.D.; HUETE, A.R. Interpreting vegetation indices. **Journal of Preventive Veterinary Medicine**, v. 11, n. 2, p. 185- 200, 1991.

JACÓBSEN, L. O; FONTANA, D. C; SHIMABUKURO, Y. E. Efeitos associados a El nino e La nina na vegetação do Estado do Rio Grande do Sul, observados através do IVDN/NOAA. **Revista Brasileira de Meteorologia**, v.19, n. 2, p.129-140, 2004.

JARAMAZ, D.; PEROVIC, V.; BELANOVIC, S.; SALJNIKOV, E.; CAKMAK, D.; MRVIC, V.; ZIVOTIC, L. **The ESA Sentinel-2 mission vegetation variables for remote sensing of plant monitoring**. 2nd Int. Sci. Conf. RESPAG 2013, 950-961, 2013.

JENSEN, J. R. **Remote sensing of vegetation**. In. __. Remote sensing of the environment, an earth resource perspective. Upper Saddle River, NJ: Prentice Hall, 2000. 544 p, cap.10. p. 333-377.

JENSEN, J.R. **Sensoriamento remoto do ambiente**: uma perspectiva em recursos terrestres. Tradução José Carlos Neves Epiphânio – São José dos Campos, SP: Parêntese. 2009. 598p.

JIANG, Z.; HUETE, A. R.; DIDAN, K.; MIURA, T. Development of a two-band enhanced vegetation index without a blue band. **Remote Sensing of Environment**, New York, v. 112, p. 3833-3845, 2008.

JONCKHEERE, I.; FLECK, S.; NACKAERTS, K.; MUYS, B.; COPPIN, P.; WEISS, M.; BARET, F. Methods for leaf area index determination. Part I: Theories, techniques and instruments. **Agricultural and Forest Meteorology**, v. 121, p. 19-35, 2004.

JORGE, L.A.C. **Determinação da cobertura de solo em fotografias aéreas do Projeto Arara**. 97f. Dissertação (Mestrado em Ciências da Computação) Universidade de São Paulo, São Carlos. 2001.

JORGE, L. A. C.; BRANDÃO, Z. N.; INAMASU, R. Y. Insights and recommendations of use of UAV platforms in precision agriculture in Brazil. (C. M. U. Neale & A. Maltese, Eds.) **Remote Sensing for Agriculture, Ecosystems, and Hydrology XVI**, v. 9239, n. 2004, p. 923911, 2014.

JORGE, L. A. D. C.; INAMASU, R. Y. Uso de veículos não tripulados (VANT) em agricultura de precisão. São Carlos: Embrapa, **Circular Técnica**, 2014.

JU, C. H.; TIAN, Y. C.; YAO, X.; CAO, W. X.; ZHU, Y.; HANNAWAY, D. Estimating Leaf Chlorophyll Content Using Red Edge. **Pedosphere**, v. 20, n. 5, p. 633–644, 2010.

KEY, C. H.; ZHU, Z.; OHLEN, D.; HOWARD, S.; MCKINLEY, R.; BENSON, N. **The normalized burn ratio and relationships to burn severity: ecology, remote sensing and implementation**. In J. D. Greer (Ed.), Rapid Delivery of Remote Sensing Products. Proceedings of the Ninth Forest Service Remote Sensing Applications Conference, San Diego, CA 8–12 April, 2002. Bethesda: American Society for Photogrammetry and Remote Sensing, 2002.

KIERULFF, M.C.M.; MENDES, S.L.; RYLANDS, A.B. *Sapajus nigritus*. **The IUCN red of list threatened species**, 2015. Disponível em: <<http://dx.doi.org/10.2305/IUCN.UK.2015-1.RLTS.T136717A70614145.en>> Acesso em: 20/10/2017.

KIM, S.; IRIZARRY, J. Exploratory study on factors influencing UAS performance on highway construction projects: as the case of safety monitoring systems. In: Conference on Autonomous and Robotic Construction of Infrastructure, Ames, 2015. **Proceedings...2015**.

KNIPLING, E. B. Physical and psysiological basis for the reflectance visible and near infrared radiation from vegetation. **Remote Sensing of Environment**, New York, v.1, n.3, p. 155-159, 1970.

KOEHLER, A.; FIRKOWSKI, C. Descascamento de pinus por macaco-prego (*Cebus apella*). **Floresta**, Curitiba, v. 24, n. 1/2, p. 61-75, 1996.

KRONKA, F. J. N.; BERTOLANI, F.; PONCE, R. H. **A Cultura do Pinus no Brasil**. São Paulo: Sociedade Brasileira de Silvicultura, 2005. 160p.

KUPLICH, T. M. Estudos florestais com imagens de radar. **Espaço & Geografia**, v. 6, n. 1, p.71-96, 2003.

LAND SURFACE ANALYSIS SATELLITE APPLICATIONS FACILITY - LSA SAF (2012). Disponível em: <http://landsaf.meteo.pt/algorithms.jsp?seltab=8&starttab=8>. Acesso em: 09 set. 2017.

LARCHER, W. **Ecofisiologia vegetal**. Editora E.P.U., São Paulo, p.33-182, 1986.

LAMB, D. W.; BROWN, R. B. Remote-Sensing and mapping of weeds in crops. **Journal of Agricultural Engineering Research**, v. 78, n.2, p. 117-125, 2001.

LEE, W. S.; ALCHANATIS, V.; YANG, C.; HIRAFUJI, M.; MOSHOU, D.; LI, C. Sensing Technologies for precision specialty crop production. **Computers and electronics in Agriculture**, n. 74, p. 2-33. 2010.

LELONG, C. C. D.; BURGER, P.; JUBELIN, G.; ROUX, B.; LABBÉ, S.; BARET, F. Assessment of unmanned aerial vehicles imagery for quantitative monitoring of wheat crop in small plots. **Sensors**, n.8, p. 3557-3585, 2008.

LICHTENTHALER, H.K. **Chlorophylls and carotenoids: pigments of photosynthetic biomembranes**. In: COLOWICK, S.P.; KAPLAN, N.O. (Eds.). *Methods in Enzymology*, v. 148, p. 350–382, 1987.

LIEBSCH, D.; MARQUES, M. C. M.; GOLDENBERG, R. How long does the Atlantic Rain Forest take to recover after a disturbance? Changes in species composition and ecological features during secondary succession. **Biological Conservation**, v. 141, n. 6, p. 1717-1725, 2008. ISSN 0006-3207.

LIEBSCH, D.; MIKICH, S. B. Fenologia reprodutiva de espécies da Floresta Ombrófila Mista na região centro-sul do Estado do Paraná. **Revista Brasileira de Botânica**, São Paulo, v. 32, n. 2, p. 375-391, 2009.

LIEBSCH, D.; MIKICH, S. B.; OLIVEIRA, E. B. de; MOREIRA, J. M. M. Á. P. Descascamento de *Pinus taeda* por macacos-prego (*Sapajus nigritus*): tipos e intensidades de danos e seus impactos sobre o crescimento das árvores. **Scientia Forestalis**, Piracicaba, v. 43, n. 105, p. 37-49, 2015.

LIEBSCH, D.; OLIVEIRA, E. B. de; MOREIRA, J. M. M. Á. P.; MIKICH, S. B. Inventário e aplicativo computacional para avaliação de danos causados por macaco-prego em plantios de pinus. **Comunicado Técnico**, n. 384. Embrapa Florestas. Colombo, PR, p.1-8, 2016.

LIEBSCH, D.; MIKICH, S.B. Damage caused by brown-capuchin monkeys to nine *Pinus* species and the implications for forest management. **Floresta**, Curitiba, v.47, n.1, p. 37-42, 2017.

LIEBSCH, D.; MOREIRA, J.M.M.A.P.; OLIVEIRA, E.B.; MIKICH, S.B. Impacto do descascamento de árvores de *Pinus taeda* L. por macacos-prego na produção e receita em plantios com desbastes. **BIOFIX Scientific Journal**, Curitiba, v.3, n.1, p. 48-55, 2018.

LILLESAND, T.M.; KIEFER, R.W. **Remote Sensing and Image Interpretation**. 2a Edition. New York. John Wiley & Sons. 2000. 721p.

LIU, W. T. H. **Aplicações de Sensoriamento Remoto**. Campo Grande: UNIDERP, 2006, 908 p.

LIMA, G. S. Manejo e conservação de fauna silvestre em áreas de reflorestamento. **Estudos de Biologia**, v. 34, p. 5-15, 1993.

LUDWIG, G.; AGUIAR, L. M.; ROCHA, V. J. Uma avaliação da dieta, da área de vida e das estimativas populacionais de *Cebus nigritus* (Goldfuss, 1809) em um fragmento florestal no norte do Estado do Paraná. **Neotropical Primates**, v. 13, n. 3, p. 12-18, 2005.

LUDWIG, G., AGUIAR, L. M., ROCHA, V. J. Comportamento de obtenção de *Manihot esculenta* Crantz (Euphorbiaceae), mandioca, por *Cebus nigritus* (Goldfuss) (Primates, Cebidae) como uma adaptação alimentar em períodos de escassez. **Revista Brasileira de Zoologia**, Curitiba, n. 3, v. 23, p. 888–890, 2006.

LYNCH ALFARO, J. W. BOUBLI, J.P.; OLSON, L.E.; DIFIORE, A.; WILSON, B.; GUTIERREZ-ESPELETA, G.A. CHIOU', K.L.; SCHULTE, M.; NEITZEL, S.; ROSS, V.; SCHWOCHOW, D.; FARIAS, I.; NGUYEN, M.T.T.; JANSON, C.H.; ALFARO, M.E. Explosive Pleistocene range expansion leads to widespread Amazonian sympatry between robust and gracile capuchin monkeys. **Journal of Biogeography**, v. 39, n. 2, p.272-288, 2012a.

LYNCH ALFARO, J. W.; DE SOUSA E SILVA, J., JR.; RYLANDS, A. B. How Different Are Robust and Gracile Capuchin Monkeys? An Argument for the Use of *Sapajus* and *Cebus*. **American Journal of Primatology**, v. 74, n. 4, p. 273-286, 2012b.

MAHLEIN, A. K.; STEINER, U.; DEHNE, H.W.; OERKE, E.C. Spectral signatures of sugar beet leaves for the detection and differentiation of diseases. **Precision Agriculture**, v. 11, n. 4, p. 413-431, 2010.

MAHLEIN, A.-K.; STEINER, U.; HILLNHÜTTER, C.; DEHNE, H.-W.; OERKE, E.-C. Hyperspectral imaging for small-scale analysis of symptoms caused by different sugar beet diseases. **Plant methods**, v. 8, n. 1, p. 3, 2012.

MALENOVSKÝ, Z.; ROTT, H.; CIHLAR, J.; SCHAEPMAN, M.E.; García-Santos, G.; Fernandes, R.; Berger, M. Sentinels for science: Potential of Sentinel-1,-2 and -3 missions for scientific observations of ocean, cryosphere, and land. **Remote Sensing Environment**, New York, v. 120, p. 91–101, 2012.

MARSHALL, A.J.; BOYKO, C.M.; FEILEN, K.L.; BOYKO, R.H.; LEIGHTON, M. Defining fallback foods and assessing their importance in primate ecology and evolution. **American Journal Physical Anthropology**, v. 140, p. 603–614, 2009.

MARSHALL, A. J.; WRANGHAM, R. W. Evolutionary consequences of fallback foods. **International Journal of Primatology**, v. 28, n. 6, p. 1219-1235, 2007.

MARTINS, W. P.; MIRANDA, J. M. D.; ALFARO, J. W. L. ALONSO, A. C.; LUDWIG, G.; MARTINS, J. N. 2015. Avaliação do Risco de Extinção de *Sapajus nigritus nigritus* (Goldfuss, 1809) no Brasil. Processo de avaliação do risco de extinção da fauna brasileira. ICMBio. Disponível em: <http://www.icmbio.gov.br/portal/biodiversidade/fauna-brasileira/estado-de-conservacao/7277-mamiferos-sapajus-nigritus-nigritus-macaco-prego.html>. Acesso em: 27 jun 2018.

MENESES, P. R.; NETTO, J. S. M. **Sensoriamento Remoto**: reflectância dos alvos naturais. Brasília, DF: UnB; Planaltina: Embrapa Cerrados, 2001. 262p.

MENESES, P.R.; ALMEIDA, T.M. **Introdução ao processamento de imagens digitais de sensoriamento remoto**. Ed. UNB, Brasília, 2012, 276 p.

MENESES, P. R. **Sensores imageadores multiespectrais na faixa óptica (0,45-2,5 µm)**. In: MENESES, P. R.; ALMEIDA, T. (Org.). **Introdução ao Processamento de Imagens de Sensoriamento Remoto**. Brasília: UnB, 2012, p. 34-46.

MIKICH, S. B.; SILVA, S. M. Composição florística e fenologia das espécies zoocóricas de remanescentes de floresta estacional semidecidual no centro-oeste do Paraná, Brasil. **Acta Botânica Brasilica**, Belo Horizonte, v. 15, n.1, p. 89-113, 2001.

MIKICH, S. B.; LIEBSCH, D. O Macaco-prego e os Plantios de *Pinus* spp. **Comunicado Técnico**, n. 234. Embrapa Florestas. Colombo, PR, p.1-5. 2009.

MIKICH, S. B.; LIEBSCH, D. Damage to forest plantations by tufted capuchins (*Sapajus nigritus*): too many monkeys or not enough fruits? **Forest Ecology and Management**, v. 314, p. 9-16, 2014.

MIKICH, S. B.; LIEBSCH, D.; ALMEIDA, A.; MIYAZAK, R. D. O papel do macaco-prego *Sapajus nigritus* na dispersão de sementes e no controle potencial de insetos-praga em cultivos agrícolas e florestais. In: PARRON, L. M.; GARCIA, J. R.; OLIVEIRA, E. B.; BROWN, G. G.; PRADO, R. B. (Org.). Serviços ambientais em sistemas agrícolas e florestais do Bioma Mata Atlântica. Brasília, DF: Embrapa, 2015a. p. 257-265.

MOREIRA, M. A. **Fundamentos do Sensoriamento Remoto e Metodologias de Aplicação**. 1ª Edição. São José dos Campos. 2001. 250 p.

MORGENTHAL, G.; HALLERMANN, N. Quality assessment of Unmanned Aerial Vehicle (UAV) based visual inspection of structures. **Advances in Structural Engineering**, v. 17, n. 3, p. 289-302, 2014.

MULLA, D. Twenty five years of remote sensing in precision agriculture: Key advances and remaining knowledge gaps. **Biosystems Engineering**, v.114, p. 358–371, 2013.

MURTHA, P. A. **A guide to air photo interpretation of forest damage in Canadá**. Information Canada, Ottawa, 1972.

MYNENI, R.B.; HALL, F.G.; SELLERS, P.J.; MARSHAK, A.L. The interpretation of spectral vegetation indexes. **IEEE Transactions on Geoscience and Remote Sensing**, v.33, n. 2, p. 481-486, 1995.

NAUE, C.R.; MARQUES, M.W.; LIMA, N.B.; GALVÍNCIO, J.D. Sensoriamento Remoto como ferramenta aos estudos de doenças de plantas agrícolas: uma revisão. **Revista Brasileira de Geografia Física**, Recife, v. 3, p. 190-195, 2010.

NOVO, E. Monitoramento de quantidade e qualidade da água e Sensoriamento Remoto, São Paulo, p.1- 20, In: Simpósio Brasileiro de Recursos Hídricos, 17. – **Anais**: Associação Brasileira de Recursos Hídricos. 2007.

NOVO, E. M. L. M. **Sensoriamento Remoto**: princípios e aplicações. São Paulo, SP: Editora Blucher, 2008. 333p.

NOVO, E. M. L. M. **Sensoriamento Remoto**: princípios e aplicações. São Paulo: Blucher, 2010, 387 p.

OLIVEIRA, T.M. **Cartografia Quantitativa de Formações Arbustivas Empregando Dados de Detecção Remota (Região Florestal do Alto-Dão e Lafões)**. 127p. 1998. Dissertação (Mestrado em Gestão de Recursos Naturais). Instituto Superior de Agronomia, Universidade Técnica de Lisboa, Lisboa. 1998.

OLIVEIRA, E. B. de; MOREIRA, J. M. M. A. P.; LIEBSCH, D.; MIKICH, S. B. Ferramenta computacional para estimar perdas na produção de madeira de *Pinus taeda*, atacadas por macaco-prego (*Sapajus nigritus*). In: CONGRESSO FLORESTAL PARANAENSE, 5. 2015, Curitiba. Novas tecnologias florestais: **Anais...** [Curitiba]: Associação Paranaense de Empresas de Base Florestal, 2015. 10 p.

ORTIZ, B.V.; THOMSON, S.J.; HUANG, Y.; REDDY, K.N.; DING, W. Determination of differences in crop injury from aerial application of glyphosate using vegetation indices. **Computers and Electronics in Agriculture**. n. 77, p. 204–213, 2011.

PADILHA, R. C. B. L. A., KURKDJIAN, M. L. N. O. Aplicação da técnica de segmentação em imagens HRV/SPOT para a discriminação dos vazios urbanos. [CD-ROM]. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 8. Salvador, 1996, **Anais...** São Paulo: Image Multimídia, 1996. Seção de Comunicações Técnicos-Científicas.

PARKINSON, C. L. “Earth from above”. University Sciences Books, Sansalito. Land vegetation, p.107- 111, 1997.

PEREIRA, J. A. **Percepção do uso do solo e desenvolvimento rural: um estudo de etnopedologia no Planalto Sul de Santa Catarina**. 145f. 2004. Dissertação (Mestrado em Ciências do Solo) - Universidade do Estado de Santa Catarina, 2004.

PEREIRA, J.P. **Mensuração automática de copas de *Araucaria Angustifolia* (Bertol.) Kuntze a partir de dados LiDAR para estimativa de variáveis dendrométricas**. 176p. 2014. Dissertação (Mestrado em Engenharia Florestal). Universidade do Estado de Santa Catarina, 2014.

PONZONI, F. J. **Comportamento Espectral da Vegetação**. In. Sensoriamento Remoto – Reflectância dos alvos naturais. Editora UnB, Embrapa, Brasília (DF), p. 157-199, 2001.

PONZONI, F. J.; SHIMABUKURO, Y. E. **Sensoriamento Remoto no estudo da vegetação**. São José dos Campos: Parêntese, 2007. 144p.

PONZONI, F. J.; SHIMABUKURO, Y. E. **Sensoriamento Remoto no Estudo da Vegetação**. São José dos Campos, SP: Ed. A.Silva Vieira, 2009. 135p.

PONZONI, F. J.; SHIMABUKURO, Y. E. **Sensoriamento Remoto no estudo da vegetação**. São José dos Campos: A. Silva Vieira Ed., 2010, 136 p.

PONZONI, F. J.; SHIMABUKURO, Y. E.; KUPPLICH, T. M. **Sensoriamento Remoto da Vegetação**. São José dos Campos, SP, Oficina de Textos, 2ª edição, 176 p., 2012.

PONZONI, F.J.; PINTO, C.T.; LAMPARELLI, R.A.C.; JUNIOR, J.Z.; ANTUNES, M.A.H. **Calibração de sensores orbitais**. São Paulo. Oficina de textos, 2015, 96 p.

PRIMICIERO, J.; GENNARO, S. F. D.; FIORILLO, E.; GENESIO, L.; LUGATO, E.; MATESE, A.; VACCARI, F. P. A flexible unmanned aerial vehicle for precision agriculture. **Precision Agriculture**, n. 13, p. 517-523, 2012.

PU, R.; GONG, P.; BIGING, G. S.; LARRIEU, M. R. Extraction of red edge optical parameters from Hyperion data for estimation of forest leaf area index. **IEEE Transactions on Geoscience and Remote Sensing**, v. 41, n. 4, p. 916-921, 2003.

PURI, A. **A Survey of Unmanned Aerial Vehicles (UAV) for Traffic Surveillance**. Department of computer science and engineering, University of South Florida, 2005. 29p.

PUREVDORJ, T.; TATEISHI, R.; ISHIYAMA, T.; HONDA, Y. Relationships between percent vegetation cover and vegetation indices. **International Journal of Remote Sensing**, v. 19, n. 18, p. 3519–3535, 1998.

RAFFO, J. G.G. **Retificação virtual de fotografias de pequeno formato e sua aplicação para voos aerofotográficos**. Tese (Doutorado), Departamento de Geografia da Faculdade de Filosofia, Letras e Ciências Humanas, Universidade de São Paulo, São Paulo. 2000.

RAMOELO, A.; SKIDMORE, A. K.; CHOA, M. A.; SCHERLEF, M.; MATHIEUA, R.; HEITKÖNIG, I. M. A. Regional estimation of savanna grass nitrogen using the red-edge band of the spaceborne RapidEye sensor. **International Journal of Applied Earth Observation and Geoinformation**, v.19 p.151–162, 2012.

RICHARDS, J.A.; JIA, X. **Remote Sensing Digital Image Analysis: An Introduction**. (3.ed.) (Springer). 1999.

ROCHA, C. H. B. **Geoprocessamento: tecnologia transdisciplinar**. Juiz de Fora: Ed. Autor, 2000a. 220 p.

ROCHA, V. J. Macaco-Prego, como controlar essa nova praga florestal? **Floresta**, Curitiba, v. 30, n. 1/2, p. 95-99, 2000b.

ROSA, R. **Introdução ao Sensoriamento Remoto**. 6. ed. Uberlândia: EDUFU, 2007. 135p.

ROSALEN, D. L. **Estudo do processo de captação de imagens aplicado à fotogrametria digital**. 1997. Dissertação (Mestrado em Engenharia dos Transportes) - Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 1997.

ROSENDO, J. S.; ROSA, R. Exemplo de aplicação do Produto MOD13Q1 disponibilizado pelo sensor MODIS/Terra. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 12. 2005, Goiânia. **Anais...** Goiânia: INPE, 2005. p. 3285-3292.

ROSENDO, J. S. **Índices de Vegetação e Monitoramento do uso do solo e cobertura vegetal na Bacia do rio Araguari -MG - utilizando dados do sensor Modis**. 130 p. 2005. Dissertação (Mestrado em Geografia e Gestão do Território) - Programa de Pós-Graduação em Geografia, Universidade Federal de Uberlândia, Uberlândia. 2005.

ROUSE, J. W.; HAAS, R. H.; SCHELL, J. A.; DEERING, D. W. Monitoring vegetation systems in the great plains with ERTS. In: Earth Resources Technology Satellite-1 Symposium, 3, 1974, Washington. **Proceedings...** Washington: NASA, 1974. p.309-317, 1973.

SANCHES I. D.; SOUZA FILHO, C. R.; MAGALHÃES, L. A.; QUITÉRIO, G. C. M.; ALVES M. N.; OLIVEIRA, W. J. Unravelling remote sensing signatures of plants contaminated with gasoline and diesel: An approach using the red edge spectral feature. **Environmental Pollution**, v.174, p.16-27, 2013.

SANKARAN, S.; MISHRA, A.; EHSANI, R.; DAVIS, C.A review of advanced techniques for detecting plant diseases. **Computers and Electronics in Agriculture**, v. 72, p. 1–13, 2010.

SANTA CATARINA. **Atlas de Santa Catarina**. Governo do Estado de Santa Catarina. Gabinete de Planejamento e Coordenação Geral. Rio de Janeiro. 1986.

SANTOS, C. V.; MORAIS JR. M.M.; OLIVEIRA, M.M.; MIKICH, S.B.; C.R. RUIZ-MIRANDA, C.R.; MOORE, K.P.L. **Ecologia, comportamento e manejo de primatas invasores e populações-problema**. In: BICCA-MARQUES, J. C. (Ed.). *A Primatologia no Brasil*. Porto Alegre, RS: EDIPUCRS, v.10, p.101-118, 2007.

SANTOS, R. B. **Metodologias para geração e atualização de mosaicos de fotos aéreas no Projeto ARARA**. 2004. Dissertação (Mestrado em Ciências de Computação e Matemática Computacional) - Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo, São Carlos. 2004.

SCHUCHOVSKI, M. S. **Diagnóstico e planejamento do consumo de madeira e da produção em plantações florestais no estado do Paraná**. 2003. 78 f. Dissertação (Mestrado em Ciências Florestais) – Universidade Federal do Paraná, Curitiba, 2003.

SCHÜHLI, G.S.; PENTEADO, S.C.; BARBOSA, L.R.; FILHO, W.R.; IEDE, E.T. A review of the introduced forest pests in Brazil. **Pesquisa Agropecuária Brasileira**, v. 51, n. 5, p. 397-406, 2016.

SCHUSTER, C.; FÖRSTER, M.; KLEINSCHMIT, B. Testing the red edge channel for improving land-use classifications based on high-resolution multi-spectral satellite data. **International Journal of Remote Sensing**, v. 33, n. 17, p. 5583–5599, 2012.

SCURLOCK, J.M.O.; ASNER, G.P.; GOWER, S.T. Worldwide Historical Estimates and Bibliography of Leaf Area Index, 1932-2000. ORNL Technical Memorandum TM-2001/268; Oak Ridge National Laboratory: Oak Ridge, TN, USA, December 2001. 40p.

SEGL, K.; GUANTER, L.; GASCON, F.; KUESTER, T.; ROGASS, C.; MIELKE, C. S2eteS: An end-to-end modeling tool for the simulation of Sentinel-2 image products. **IEEE Transactions on Geoscience and Remote Sensing**, v. 53, n. 10, p. 5560-5571, 2015.

SELLERS, P. Canopy reflectance, photosynthesis and transpiration. **International Journal Remote Sensing**, v. 6, n.8, p. 1335–1372, 1985.

SHIMIZU, J. Y. Silvicultura de Pinus para o sul do Brasil. **Revista da Madeira**, v.6, n.37, p.32-35, 1997.

SILVA JÚNIOR, J. S. **Especiação nos macacos-prego e caiararas, gênero Cebus Erxleben, 1777 (Primates, Cebidae)**. 2001, 377 f. Tese (Doutorado) – Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2001.

SILVA JUNIOR, J. S. Especiação nos macacos-prego e caiararas, gênero Cebus Erxleben, 1777 (Primates, Cebidae). **Boletim da Sociedade Brasileira de Mastozoologia**. v.42, p. 11-12. 2005.

SILVA, E. J. **Aspectos da região serrana catarinense e a influência da empresa Klabin**. 2010. 65p. Monografia (Curso de Ciências Econômicas) - Universidade Federal de Santa Catarina. 2010.

SILVA, J. B. **Sensoriamento Remoto aplicado ao estudo do ecossistema manguezal em Pernambuco**. 2012. 191p. Tese (Doutorado em Geografia). Universidade Federal de Pernambuco, Recife. 2012a.

SILVA, E.A.Ç MARANGON, G.P.; DESSBESELL, L.; MORAIS, W.W.; LIPPERT, D.B.; PEREIRA, R.S. Caracterização espectral na reflectância de *Eucalyptus grandis*. **Floresta**, v. 42, n. 2, p. 285-292, 2012b.

SIMPSON, A.D. **Development of an unmanned aerial vehicle for low-cost remote sensing and aerial photography**. Master of Science Thesis. University of Kentucky, Lexington, Kentucky. 2003.

SOUSA, C. L. **Uso de imagens-índice de imagens-proporção para avaliar a quantidade de madeira em povoamentos de *Pinus spp.*** 1997. 137f. Dissertação (Mestrado em Sensoriamento Remoto). Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 1997.

STEFFEN, C.A. **Introdução ao sensoriamento remoto**, 2008. 11p. Disponível em: <<http://www.inpe.br/unidades/cep/atividadescep/educasere/apostila.htm>> Acesso em: 06 jun 2017.

STREIT, N.M.; CANTERLE, L. P.; CANTO, M.W.; HECKTHEUER, L.H.H. As clorofilas. **Ciência Rural**, v. 35, n.3, p. 748-755, 2005.

TRENTIN, C. B. **Análise da resposta espectral da vegetação da área de proteção ambiental (APA) do Ibirapuitã em imagens do sensor EOS/MODIS associadas ao solo e aos elementos do clima**. 2011. 73 f., il. Dissertação (Mestrado em Sensoriamento Remoto e Meteorologia) — Universidade Federal do Rio Grande do Sul, Porto Alegre, 2011.

THENKABAIL, P. S.; SMITH, R. B.; PAUW, E. Evaluation of narrowband and broadband vegetation indices for determining optimal hyperspectral wavebands for agricultural crop characterization. **Photogrammetric Engineering e Remote Sensing**, v. 68, n.6, p. 607-621, 2002.

TRINDADE JUNIOR, O.; JORGE, L.A.C.; AGUIAR, J.G.B. **Using UAVs for Precision Farming - First Results**. In: Unmanned Systems North America, AUVERSI 2004, 2004, Baltimore, Maryland, USA. Anais of AUVERSI 2004, 2004.

VANE, G.; GOETZ, A. F. H. Terrestrial imaging spectrometry. **Remote Sensing of Environment**, v.24, p.1-29, 1988.

VERSTRAETE, M. M.; PINTY, B. Designing optimal spectral indices for remote sensing applications. **IEEE Transactions on Geoscience and Remote Sensing**, v.34, p. 1254-1265, 1996.

VIDOLIN, G. P.; MIKICH, S. B. *Cebus nigrinus* (Primates: Cebidae) no P. E. Vila Rica do Espírito Santo, Fênix – PR: estimativa populacional e área de vida, composição e dinâmica dos grupos. In: CONGRESSO BRASILEIRO DE UNIDADES DE CONSERVAÇÃO, 4., 2004, CURITIBA. Anais. [Curitiba]: Fundação O Boticário de Proteção à Natureza: Rede Nacional Pró-Unidades de Conservação, 2004. p. 196-205.

VILANOVA, R.; SILVA JÚNIOR, J.S.; GRELLE, C.E.V.; MARROIG, G.; CERQUEIRA, R. Limites Climáticos e Vegetacionais das Distribuições de *Cebus nigrinus* e *Cebus robustus* (Cebinae, Platyrrhini). **Neotropical Primates**, v. 13, n. 1, p. 14-19, 2005.

VILELA, M.A.M.A. **Metodologia para Monitoramento da Qualidade da Água de Reservatórios utilizando Sensoriamento Remoto**. 2010. 123p. Dissertação (Mestrado em Engenharia Civil). Universidade Federal de Uberlândia, 2010.

VISALBERGHI, E.; FRAGASZY, D. The Behaviour of Capuchin Monkeys, *Cebus apella*, with Novel Food: the Role of Social Context. **Animal Behaviour**, n.49, p. 1089-1095, 1995.

VON DEM BUSSCHE, G. H.; VAN DER ZEE, D. Damage by Samango monkeys, *Cercopithecus (mitis) albogularis*, to pine trees in the Northern Transvaal. **South African Forestry Journal**, n. 6, p. 43-48, 1985.

XIANG, H.; TIAN, L. Development of a low-cost agricultural remote sensing system based on an autonomous unmanned aerial vehicle (UAV). **Elsevier Biosystems Engineering**, n. 108, p. 174-190, 2011.

XU, Q.; HOU, Z.; TOKOLA, T. Relative radiometric correction of multi-temporal ALOS AVNIR-2 data for the estimation of forest attributes. **Journal of Photogrammetry and Remote Sensing**, v. 68, p. 69-78, 2012.

WANG, Z.X.; LIU, C.; HUETE, A. **Ecologica Sinica**, Amsterdam, v. 23, n. 5, p. 979-988, 2003.

WANG, J.; SAMMIS, T.; GUTSHICK, V. Review of satellite remote sensing use in forest health studies. **The Open Geography Journal**, v. 3, p. 28-42, 2010.

WATSON, D. J. Comparative physiological studies in the growth of field crops I. Variation in net assimilation rate and leaf area between species and varieties, and within and between years. **Annals of Botany**, v. 11, p. 41-76, 1947.

XIE, Q.; DASH, J.; HUANG, W.; PENG, D.; QIN, Q.; MORTIMER, H.; CASA, R.; PIGNATTI, S.; LANEVE, G.; PASCUCCHI, S.; DONG, Y.; HUICHUN, Y. Vegetation indices combining the red and red-edge spectral information for leaf area index retrieval. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 5, n. 11, p. 1482-1493, 2018. doi:10.1109/JSTARS.2018.2813281.

WEST, J.S.; BRAVO, C.; OBERTI, R.; LEMAIRE, D.; MOSHOU, D.; MCCARTNEY, H.A. The potential of optical canopy measurements for targeted control of field crop diseases. **Annual Review Phytopathology**, v.41, p. 593-614, 2003.

WU, C.; NIU, Z.; TANG, Q.; HUANG, W.; Estimating chlorophyll content from hyperspectral vegetation indices: Modeling and validation. **Agricultural and Forest Meteorology**, v. 14, n. 8, p. 1230-1241, 2008.

ZENGEYA, F.M.; MUTANGA, O.; MURWIRA, A. Linking remotely sensed forage quality estimates from WorldView-2 multispectral data with cattle distribution in a savanna land-scape. **International Journal of Applied Earth Observation and Geoinformation**, v. 21, p. 513-524, 2013.

ZHANG, H.; HU, H.; ZHANG, X. et al. Estimation of rice neck blasts severity using spectral reflectance based on BP-neural network. **Acta Physiologiae Plantarum**, v. 33, n. 6, p. 2461-2466, 2011.

ZHANG, C.; KOVACS, J. M. The application of small unmanned aerial systems for precision agriculture: a review. **Precision Agriculture**, n. 13, 2012, p. 693-712.

ZHAO, D.; YANG, T.; AN, S. Effects of crop residue cover resulting from tillage practices on LAI estimation of wheat canopies using remote sensing. **International Journal of Applied Earth Observation and Geoinformation**, v.14, 2012.

4 CAPÍTULO I:

DETERMINAÇÃO DA SANIDADE DE UM POVOAMENTO DE *Pinus taeda* L. APÓS O ATAQUE DE *Sapajus nigrinus* Kerr (1972) UTILIZANDO SENTINEL-2

RESUMO

Essa pesquisa objetivou ajustar modelos de regressão e classificação utilizando os IV mais robustos derivados a partir de imagens digitais de Sentinel-2/MSI para a detecção de áreas atacadas por *Sapajus nigrinus*. Os dados de campo foram obtidos em um povoamento de *Pinus taeda* L. localizado em Bocaina do Sul, estado de Santa Catarina. Foram alocadas 46 parcelas, nas quais os indivíduos arbóreos foram classificados de acordo com a intensidade do ano em: I: sem dano, II: moderado, III: severo e IV: morto. Foram utilizadas três imagens orbitais da constelação Sentinel-2/MSI em datas coincidentes ao pré ataque (maio/2017), ataque (novembro/2017) e pós ataque (abril/2018). Por meio de Análise de Componentes Principais, foram selecionados os índices de vegetação como variáveis regressoras para o desenvolvimento de modelos de regressão por *Stepwise*, *Support Vector Machine* (SVM) e *Random Forest* (RF) para a estimativa do percentual das classes de ataque por parcela. A seleção de melhor modelo foi baseada em estatísticas de ajuste de modelos de regressão. Os índices mais robustos foram o MCARI, NDI45 e NDVIRR, os quais estimaram para as classes um percentual de ataque de *S. nigrinus* por parcela com R^2 ajustado de 0,8042, 0,4603, 0,8815 e 0,9766; Syx de 13,49, 61,42, 15,11 e 8,69 (% 0,045 ha⁻¹) e RMSE de 1,95, 4,49, 2,11 e 0,32 (% 0,045 ha⁻¹), respectivamente. Foi possível estimar/identificar áreas atacadas por esse primata no povoamento avaliado, destacando a modelagem *Stepwise*, seguida por SVM e RF. Entretanto, recomenda-se testar imagens digitais de alta/ultra alta resolução espacial para corroborar com tal metodologia.

Palavras-chave: Índices de vegetação, Sensoriamento Remoto; *red-edge*.

ABSTRACT

This study aimed to identify regression and classification models using the most robust IV derived from Sentinel-2/MSI digital images for the detection of areas attacked by *Sapajus nigrinus* in a *Pinus taeda* L. stand located in Bocaina do Sul, State of Santa Catarina. In order to do this, three orbital images of the Sentinel-2/MSI constellation were used in pre-attack (May/2017), attack (November/2017) and post-attack (April/2018) dates. A total of 46 field plots were allocated, in which tree individuals were classified according to the intensity of the year in: I: no damage, II: moderate, III: severe and IV: dead. Using Principal Component Analysis, vegetation indices were selected as regressor variables for the development of regression models by *Stepwise*, *Support Vector Machine* (SVM) and *Random Forest* (RF) to estimate the percentage of attack classes per plot. The best model selection was based on regression model fit statistics. The most robust indexes were MCARI, NDI45 and NDVIRR, which estimated for the classes a percentage of attack of *S. nigrinus* per plot with adjusted R^2 of 0.8042, 0.4603, 0.8815 and 0.9766; Syx of 13.49, 61.42, 15.11 and 8.69 (% 0.045 ha⁻¹) and RMSE of 1.95, 4.49, 2.11 and 0.32 (% 0.045 ha⁻¹), respectively. It was possible to estimate/identify areas attacked by this primate in the evaluated settlement, highlighting the *Stepwise* model, followed by SVM and RF. However, it is recommended to test digital images of high/ultra-high spatial resolution to corroborate with such methodology.

Keywords: Vegetation indexes, Remote Sensing; *red-edge*.

4.1 INTRODUÇÃO

A espécie *Sapajus nigritus* Kerr (1972) conhecida popularmente como macaco-prego, é endêmica da Mata Atlântica, com distribuição geográfica desde o estado de Minas Gerais até o norte do Rio Grande do Sul (LYNCH ALFARO et al., 2012). Além disso, de acordo com Hendges et al. (2017), o macaco-prego possui significativa capacidade de adaptação as alterações ocorridas em determinado local e de ocupação de novas áreas, como por exemplo, ambientes degradados e fragmentados.

A exploração da Mata Atlântica interferiu diretamente nas condições de vida dessa espécie em função da perda de riqueza dos remanescentes desse bioma. Isso causou escassez de alimentos durante a época de baixa frutificação (LIEBSCH et al., 2008) fazendo com que os macaco-prego buscassem alimentos alternativos, como a inclusão da seiva do *Pinus* sp. em sua dieta (ROCHA, 2000). Contudo, esse consumo causa danos aos povoamentos florestais do gênero *Pinus* spp., pois ao retirar a casca da árvore, o macaco-prego causa dois tipos de dano: janelamento (somente uma parte da casca do tronco é retirada) e anelamento (ocorre a retirada da casca em toda a circunferência do tronco). Tais danos irão comprometer o crescimento da árvore e o ataque de pragas florestais como a vespa da madeira (*Sirex noctilio* F.) ou ainda, causar sua morte (KOHLER; FIRKOWSKI, 1996; MIKICH; LIEBSCH, 2009; MIKICH; LIEBSCH, 2014).

Diante disso, uma alternativa para monitorar os impactos desse primata sobre plantios florestais refere-se à utilização de Sensoriamento Remoto (SR), tecnologia que possibilita a avaliação e o monitoramento da sanidade florestal de forma remota (PAUSE et al., 2016). Para isso, podem ser utilizados indicadores da sanidade florestal, como avaliação visível dos níveis de infestação, características das folhas, como desfolhação e descoloração, danos no tronco, número de árvores mortas ou caídas, fechamento da coroa ou índice de área foliar (IAF) (LAUSCH et al., 2016). O entendimento da influência dos fatores de estresse deve ser aliado com observações *in situ* (nível de parcela) e a utilização de imagens de SR (TRUMBORE et al., 2015) em diferentes escalas temporais e espaciais (LAUSCH et al., 2017).

Diversas pesquisas já foram conduzidas visando avaliar o potencial de utilização de dados de SR no monitoramento da sanidade florestal, utilizando imagens aéreas (MOZGERIS; AUGUSTAITIS, 2013), varredura a LASER (*Light Amplification by Stimulated Emission of Radiation*) (KANTOLA et al., 2010) e imagens de satélite (ADELABU et al., 2014) derivando Índices de Vegetação (IV) (TOWNSEND et al., 2012). Existem diversos IV na literatura, porém, o Índice de Vegetação pela Diferença Normalizada (*Normalized Difference Vegetation Index* – NDVI) é um dos mais utilizados para diagnosticar a sanidade dos plantios (RULLAN-SILVA et

al., 2013). Em outros estudos, como o de Sanguesa-Barreda et al. (2014) e Townsend et al. (2012), índices baseados no infravermelho de ondas curtas (SWIR) foram superiores ao NDVI. Já na pesquisa de Adelabu et al. (2014), índices baseados em *red-edge* demonstraram performance satisfatória. Por isso, Rullan-Silva et al. (2013) recomendam testar diferentes IV para cada caso específico.

A derivação de IV a partir de imagens multiespectrais possibilita o desenvolvimento de modelos de regressão para a predição da variável resposta desejada. Além de modelos lineares, outras modelagens podem ser utilizadas, como as máquinas de aprendizado ou *Machine Learning* (ML). Contudo, a utilização desse tipo de modelagem ainda é limitada na área florestal, pois poucos estudos foram desenvolvidos com essa abordagem, como pode-se citar: Kantola et al. (2010), Adelabu et al. (2014), Marx e Kleinschmit (2017) e Hawrylo et al. (2018).

Uma potencial fonte de dados para estudos nesse âmbito refere-se à missão de satélites Sentinel-2, produzida pela Agência Espacial Europeia (ESA). Tal constelação de satélites apresenta diversas vantagens para a utilização em estudos que visam o diagnóstico da sanidade florestal, como por exemplo: dados gratuitos com resolução espacial comparável a satélites comerciais, bandas espectrais de borda vermelha específicos para estudos de vegetação e resolução temporal de 5 dias (ESA, 2010). Em função disso, nota-se a importância de utilização de imagens desse sensor para estudos relacionados com a sanidade de povoamentos florestais, monitorando o estágio e a extensão dos níveis de ataque e/ou infestação (WALTER; PLATT, 2013).

Nesse cenário, essa pesquisa objetivou ajustar modelos de regressão utilizando os IV mais robustos derivados a partir de imagens multiespectrais de Sentinel-2 para a detecção de áreas atacadas por *Sapajus nigritus* em um povoamento de *Pinus taeda* L. localizado em Bocaina do Sul, estado de Santa Catarina.

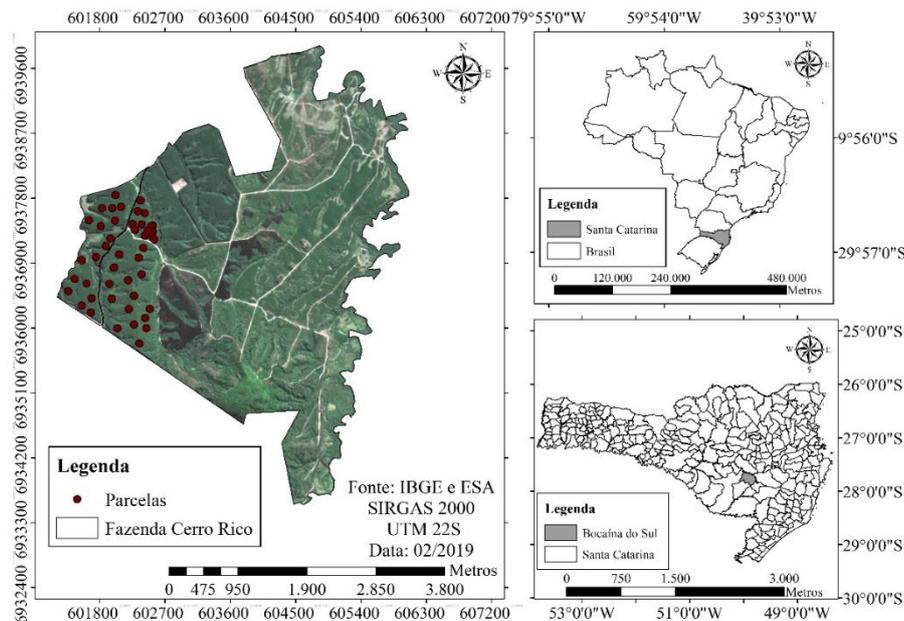
4.2 MATERIAL E MÉTODOS

4.2.1 Descrição da área

A pesquisa foi conduzida na fazenda Cerro Rico (Figura 4:1) localizada em Bocaina do Sul, no estado de Santa Catarina, com coordenadas médias UTM (*Universal Transversa de Mercator*) E: 602272 metros e N: 6936448 metros e com área de 1535,57 hectares. O município apresenta clima Cfb (clima mesotérmico subtropical úmido), segundo a classificação de Köppen, temperatura média de 16,5° C, umidade relativa do ar de 79,3% e precipitação bem distribuída ao longo do ano, com média anual de 1500 mm (ALVARES et al., 2013).

A área possui plantios de *Pinus taeda* L., *Eucalyptus* spp. e remanescentes florestais nativos. A área de efetivo plantio de *Pinus taeda* L. foi plantada em 2002 e 2003, totalizando 236,21 ha, com espaçamento de 3 metros x 2,5 metros. Não houve intervenção silvicultural (desbastes) e o sistema de colheita utilizado foi o *full tree*.

Figura 4: 1 - Localização do povoamento de *Pinus taeda* L. em Bocaina do Sul – SC.



Fonte: Elaborado pela Autora (2018) com base em IBGE/ESA.

4.2.2 Coleta de dados

O processo de amostragem utilizado foi o de amostragem aleatória simples, representando a mesma probabilidade de seleção das parcelas. Assim, foram instaladas 46 parcelas circulares de raio variável de 5 a 10 metros na área, para atender a suficiência amostral (Equação 1) com base em Neto et al. (2002).

$$N = \left(\frac{Z \cdot \sigma}{L} \right)^2 \quad (1)$$

Em que: N: número de parcelas; Z: ponto de distribuição normal padrão para o nível de confiança escolhido (95%); σ : desvio padrão; L: precisão desejada.

O tamanho e formato das parcelas foram definidos em função do padrão de ataque do *S. nigritus*, o qual acomete árvores isoladas e aleatórias no povoamento. Por isso, foram utilizadas parcelas circulares de raio variável de 5 a 10 metros, para permitir a inclusão de árvores atacadas

e não atacadas. Das 46 parcelas, 3 apresentaram raio de 5 metros e 43 tiveram raio de 10 metros. É importante ressaltar que não houve sobreposição das parcelas.

Em todas as parcelas, a posição geográfica foi obtida utilizando um receptor de sinais GPS (*Global Positioning System*) do modelo *Garmin Etrex Legend®*, com dados georreferenciados no sistema de coordenadas WGS – 84 (*World Geodetic System 1984*). O método de posicionamento geodésico utilizado foi o absoluto.

Para a avaliação do dano causado por *S. nigritus* nas árvores de *Pinus taeda* L., foram propostas quatro classes qualitativas de dano, sendo elas: I: sem dano; II: moderado; III: severo e IV: 100%. A avaliação foi realizada de forma visual, obedecendo aos seguintes critérios: árvores sem danos (não apresentavam nenhum tipo de dano); moderado (apresentavam o dano janelamento), severo (apresentavam os dois tipos de danos: janelamento e anelamento ou só anelamento) e morto (parte superior da copa seca). Assim, obteve-se a porcentagem de ataque de cada classe pela razão do número de árvores da respectiva classe de dano pelo número total de árvores da parcela.

4.2.3 Dados remotamente situados

Foram utilizadas três imagens oriundas da constelação de satélites Sentinel-2/MSI (*Multispectral Instrument*) (Tabela 4:1) em datas correspondentes a três épocas com o intuito de realizar uma análise temporal dos ataques desse primata na área. Todas as imagens foram adquiridas no portal *Copernicus Open Access Hub*, com as bandas e características descritas em ESA (2010), na órbita 221 e ponto 79.

Tabela 4: 1 - Imagens do sensor Sentinel-2/MSI para o povoamento de *Pinus taeda* L. atacado por *Sapajus nigritus* em Bocaina do Sul.

Imagem	Época	Data
1	Pré ataque	15/05/2017
2	Ataque	11/11/2017
3	Pós ataque	22/04/2018

Fonte: Adaptado pela Autora (2018).

As imagens foram obtidas como dados no nível 1C, ou seja, dados com reflectância no topo da atmosfera (*Top Of the Atmosphere* (TOA)). No aplicativo computacional ENVI versão 5.3 (*Environment for Visualizing Images*) (EXELIS, 2018), as imagens foram processadas para o nível 2A, com reflectância na base da atmosfera (*Bottom Of the Atmosphere* (BOA)). A correção atmosférica foi realizada utilizando o algoritmo FLAASH (*Fast Line-of-Sight Atmospheric Analysis of Hypercubes*). Em seguida, as imagens foram reamostradas para a resolução espacial

de 10 metros utilizando o aplicativo computacional SNAP (*Sentinel Application Platform*) (ESA, 2018).

Com as imagens devidamente processadas, foram derivados os índices de vegetação descritos na Tabela 4:2. Tais IV foram escolhidos em função das faixas espectrais que abordam e pelos relatos encontrados na literatura acerca da sanidade florestal.

Tabela 4: 2 - Índices de vegetação calculados para as imagens do Sentinel-2/MSI para um povoamento de *Pinus taeda* L. localizado em Bocaina do Sul – SC.

IV	Abreviatura	Equação	Referência
Anthocyanin Reflectance Index	ARI1	$(1/B3) - (1/B5)$	Gitelson et al. (2001)
Anthocyanin Reflectance Index	ARI2	$(B8/B3) - (B8/B5)$	Gitelson et al. (2001)
Chlorophyll Red-Edge	CHR	$(B5/B8) - 1$	Gitelson et al. (2003a)
Red and red-edge modified chlorophyll index	CHRR	$(B8) / (1 * B4 + (1 - a) * B5) - 1$	Xie et al. (2018)
Carotenoid Reflectance Index 1	CRI1	$(1/B2) - (1/B3)$	Gitelson et al. (2002)
Carotenoid Reflectance Index 1	CRI2	$(1/B2) - (1/B5)$	Gitelson et al. (2002)
Enhanced Vegetation Index	EVI	$2,5 * (B8 - B4) / (B8 + 6 * B4 + 7,5 * B2 + 1)$	Jiang et al. (2008)
Enhanced Vegetation Index 2	EVI2	$2,5 * (B8 - B4) / (B8 + 2,4 * B4 + 1)$	Jiang et al. (2008)
Green Normalized Difference Index	GNDVI	$(B8 - B3) / (B8 + B3)$	Gitelson et al. (1996)
Inverted Red-Edge Chlorophyll Index	IRECI	$(B7 - B4) * B6/B5$	Clevers et al. (2000)
Modified Chlorophyll Absorption in Reflectance Index	MCARI	$1 - 0,2 * (B5 - B3) / (B5 - B4)$	Daughtry (2000)
Modified Soil Adjusted Vegetation Index	MSAVI	$\frac{(B8 - B4)}{(B8 + B4 + L)} (1+L)$	Qi et al. (1994)
Second Modified Soil Adjusted Vegetation Index	MSAVI ₂	$(B8 + 1) - 0,5 * \text{sqrt}((2 * B8 - 1)^2 + 8 * B4)$	Qi et al. (1994)
MERIS Terrestrial Chlorophyll Index	MTCI	$(B6 - B5) / (B5 - B4)$	Dash e Curran (2007)
Normalized Difference Infrared Index	NDI11	$(B8 - B11) / (B8 + B11)$	Hardisky et al. (1983)
Normalized Burn Ratio	NDI12	$(B8 - B12) / (B8 + B12)$	Key et al. (2002)
Normalized Difference Index 45	NDI45	$(B5 - B4) / (B5 + B4)$	Frampton et al. (2013)
Normalized Difference Vegetation Index	NDVI	$(B8 - B4) / (B8 + B4)$	Rouse et al. (1973)
Red Edge NDVI	NDVIR	$(B8 - B6) / (B8 + B6)$	Fernández-Manso et al. (2016)
Red and red-edge normalized difference vegetation index	NDVIRR	$(B8 - (1 * B4 + (1 - a) * B5)) / (B8 + (1 * B4 + (1 - a) * B5))$	Xie et al. (2018)

Plant Senescence Reflectance Index Near Infrared	PSRI	$(B4 - B2) / (B6)$	Mezylak et al. (1999)
Pigment Specific Simple Ratio	PSSRa	$(B8/B4)$	Blackburn (1998)
Soil Adjusted Vegetation Index	SAVI	$1,5 * (B8 - B4) / (B8 + B4 + 0,5)$	Huete (1988)
Sentinel-2 Red-Edge Position	S2REP	$705 + 35 * (0,5 * (B7 + B4) - B5) / (B6 - B5)$	Guyot e Baret (1988)

Em que: IV: índices de vegetação; B2: *blue* (490 nm); B3: *green* (560 nm); B4: *red* (665 nm); B5: *red-edge 1* (705 nm); B6: *red-edge 2* (740 nm); B7: *red-edge 3* (783 nm); B8: *NIR* (842 nm); B8A: *red-edge 4* (865 nm); B11: *SWIR 1* (1610 nm); B12: *SWIR 2* (2190 nm); L e a: fatores de ajuste (considerados como 0,5).

A delimitação das parcelas nas imagens foi feita a partir das coordenadas do ponto central da parcela. Este ponto serviu para a delimitação de uma circunferência com raio de 12 m, pois a criação de parcelas com raio maiores poderia diminuir o erro do posicionamento GPS. Isso se deve ao erro no método de posicionamento GNSS. Pela existência desse erro, construiu-se uma área de influência de 12 metros de raio para gerar a área das parcelas nas imagens. Esse procedimento foi realizado em ambiente GIS (*Geographic Information System*) (ESRI, 2018) utilizando a ferramenta *buffer*. Em seguida, obteve-se o valor médio de cada IV por parcela para cada uma das três imagens utilizadas.

4.2.4 Seleção das variáveis

As variáveis regressoras (IV) foram selecionadas pela Análise de Componentes Principais (*Principal Components Analysis – PCA*). Essa análise é empregada quando o objetivo é reduzir o número de variáveis sem causar perda de informação e qualidade (ANDRADE et al., 2007) e também para reduzir a variância dos dados. Na PCA, as variáveis são transformadas e cada uma pode ser analisada como um eixo de variabilidade com correlação com as demais variáveis. A partir disso, os dados são transformados para a descrição da variabilidade total existente e com o mesmo número de eixos originais, contudo, sem correlação entre si. De forma gráfica, a PCA realiza a rotação de pontos existentes em um espaço multidimensional formando eixos ou componentes principais. Quando dispostos em um espaço com duas dimensões esses eixos representam a variabilidade suficiente para indicar um padrão a ser interpretado (BERNARDI et al., 2001).

A PCA tem início com o cálculo dos autovalores e autovetores originários de uma matriz de variâncias, covariâncias ou matriz de correlação entre variáveis. O primeiro autovalor deverá corresponder a maior porcentagem da variabilidade total. O mesmo procedimento deverá ocorrer para os demais autovalores. Os autovetores dizem respeito às componentes principais,

compreendendo uma medida da relativa importância de cada variável em relação as componentes principais (BERNARDI et al., 2009). A partir disso, obtém-se os escores de cada variável em relação as componentes principais. Tais valores podem ser representados em um diagrama de dispersão, com as duas componentes mais importantes como eixos (BERNARDI et al., 2001).

Para cada classe de dano, os IV com porcentagem de importância igual ou maior que 85% foram considerados como variáveis preditoras na construção de modelos de regressão para estimar o percentual de ataque por parcela (% 0,045 ha⁻¹).

4.2.5 Métodos para ajuste de modelos de regressão

4.2.5.1 *Stepwise*

O método *Stepwise* é uma técnica de regressão que determina quais variáveis possuem maior influência nas variáveis dependentes (conjunto de saída). Essa técnica pode diminuir o número de variáveis que irão constituir o modelo de regressão e é utilizada em estudos exploratórios e para descrever a relação entre as variáveis (ABADD; TORRES, 2002).

As variáveis são selecionadas de forma iterativa, pois a seleção da sequência de entrada dos preditores baseia-se na análise estatística, sem seguir um modelo teórico. Existem duas metodologias de seleção de variáveis para compor o modelo: adição de variáveis pelo *forward* e remoção de variáveis pelo *backward*. O critério de escolha das variáveis é um fator estatístico como o teste F, coeficiente de correlação linear múltipla, erro quadrático total ou Critério de Informação de Akaike (AIC). Nesse estudo, o critério utilizado foi o de AIC, por ser o critério estatístico que apresenta uma medida de discrepância entre as linhas do modelo verdadeiro e o modelo aproximado.

4.2.5.2 *Support Vector Machines (SVM)*

SVM é uma classe de modelagem poderosa e altamente flexível. Inicialmente, foi desenvolvida para modelos de classificação, mas foi transformada para modelos de regressão robusta que visa reduzir o efeito de dados discrepantes sobre as equações de regressão. A modelagem por SVM utiliza a função de Huber com o critério de definição de um limiar pelo usuário. Os dados das amostras de treinamento com resíduos dentro desse limiar não contribuem para o ajuste de regressão, enquanto que os pontos de dados com uma diferença absoluta maior que o limiar contribuem com uma quantidade de escala linear. Isso causa a não utilização dos

resíduos quadrados, fazendo com que os valores discrepantes tenham um efeito limitado na equação de regressão. Além disso, as estimativas do modelo com resíduos pequenos também não têm impacto na equação de regressão. Isso ocorre devido ao limiar, um alto valor fazendo com que os pontos discrepantes definam a linha de regressão, chamados de vetores de suporte (KUHN; JOHSON, 2013).

As características do SVM para regressão utilizadas foram: *kernel* do tipo radial e polinomial, *degree* variando de 1 a 3 e *cost* de 0,5, 1, 2 a 4, conforme Hawrylo et al. (2018).

4.2.5.3 *Random Forest* (RF)

A metodologia RF utiliza um conjunto versátil de árvores de decisão, tendo bom desempenho para estimativas de modelos lineares e não lineares, por equilibrar viés e variância (BREIMAN, 2001). Esse método de aprendizado constitui-se de conjunto de árvores sucessivas que crescem a partir de outras árvores. Cada árvore é determinada de maneira independente utilizando uma amostra de *bootstrap* do conjunto de dados (LIAW; WIENER, 2002). Para o emprego dessa técnica, dois parâmetros devem ser definidos: o número de variáveis de entrada escolhidas aleatoriamente em cada divisão (*mtry*) e o número de árvores (*ntree*). A partir de testes que determinar a baixa variabilidade nos dados, o *mtry* foi de 2 e o *ntree* de 3 e 6. Esses parâmetros foram utilizados seguindo a orientação de Hawrylo et al. (2018).

Os modelos ajustados por todas as técnicas mencionadas estão descritas no Anexo A.

4.2.6 Seleção do melhor modelo de regressão

A escolha da melhor equação foi realizada a partir das estatísticas de ajuste e precisão, maior coeficiente de determinação ajustado (R^2_{aj}) (Equação 1), menor erro padrão da estimativa (S_{yx}) (Equação 2) e menor erro padrão da estimativa em porcentagem ($S_{yx\%}$) (Equação 3) como sugerem Nicoletti et al. (2016). O fator estatístico apontado por Schneider et al. (2009), teste F com o nível de significância de 5% de probabilidade, também foi considerado.

$$R^2_{aj} = 1 - \left\{ (1 - R^2) * \left(\frac{n-1}{n-p} \right) \right\} \quad (1)$$

$$S_{yx} = \sqrt{\frac{\sum (y - y_i)^2}{n - p}} \quad (2)$$

$$S_{yx\%} = \frac{S_{yx}}{Y} * 100 \quad (3)$$

Em que: R^2 aj: coeficiente de determinação ajustado; n: número de árvores medidas; p: número de parâmetros da equação; Sy_x : erro padrão da estimativa (% 0,045 ha⁻¹); Sy : erro padrão da estimativa (% 0,045 ha⁻¹); y: ataque observado (% 0,045 ha⁻¹); y_i : ataque estimado (% 0,045 ha⁻¹); Y: média dos valores observados (% 0,045 ha⁻¹).

Outras métricas de qualidade de ajuste foram avaliadas, sendo elas: Critério de Informação de Akaike (AIC) e Critério de Informação Bayesiano (BIC). A primeira reflete a perda de informação associada as predições de um modelo e os valores observados. Dessa forma, quanto menor o valor do AIC, mais explicativo será o modelo (MOSER; OLIVEIRA, 2011). Já o BIC também aumenta com a Soma de Quadrados dos resíduos e quanto menor for seu valor, melhor será o modelo (MOSER; OLIVEIRA, 2011). O AIC foi obtido pela Equação 4 enquanto que o BIC foi calculado pela Equação 5:

$$AIC = n * \ln (SQ_{res}) - n * \ln (n) + 2p \quad (4)$$

$$BIC = -2 \log (L_p) + [(p+1)+1] \log (n) \quad (5)$$

Em que: AIC: Critério de Informação de Akaike; n: número de observações da amostra; p: número de parâmetros do modelo; SQ_{res} : Soma de Quadrados dos resíduos obtidos pela ANOVA; BIC: Critério de Informação Bayesiano; L_p : função de máxima verossimilhança do modelo.

A Raiz do Erro Quadrático Médio (*Root Mean Squared Error* - RMSE) (Equação 6) é uma métrica que representa a qualidade de predição de um modelo, pois avalia as diferenças entre os valores observados e os valores estimados pelo modelo de regressão (MOSER; OLIVEIRA, 2011). Essa estatística é calculada na escala original da variável resposta e é muito utilizada na área florestal (TEMESGEN et al., 2014).

$$RMSE = \sqrt{\frac{\sum(y - y_i)^2}{n}} \quad (6)$$

Em que: RMSE: Raiz do Erro Quadrático Médio (% 0,045 ha⁻¹); y: ataque observado (% 0,045 ha⁻¹); y_i : ataque estimado (% 0,045 ha⁻¹); n: número de observações.

Para a validação do melhor modelo, foram separados 20% dos dados, nos quais aplicou-se o teste de Qui-Quadrado (X^2) ao nível de significância de 95% de probabilidade. O teste do Qui-Quadrado foi proposto por Pearson (1990) e é expresso pela letra grega χ^2 . Nesse método, verifica-se se a hipótese de existência ou não de diferenças entre os valores observados e preditos. Esse índice estatístico foi obtido pela Equação 7:

$$\chi^2 = \sum \frac{(y - \hat{y}_i)^2}{y_i} \quad (7)$$

Em que: y: valores observados (% 0,045 ha⁻¹); \hat{y}_i : valores estimados (% 0,045 ha⁻¹).

4.2.7 Análises estatísticas

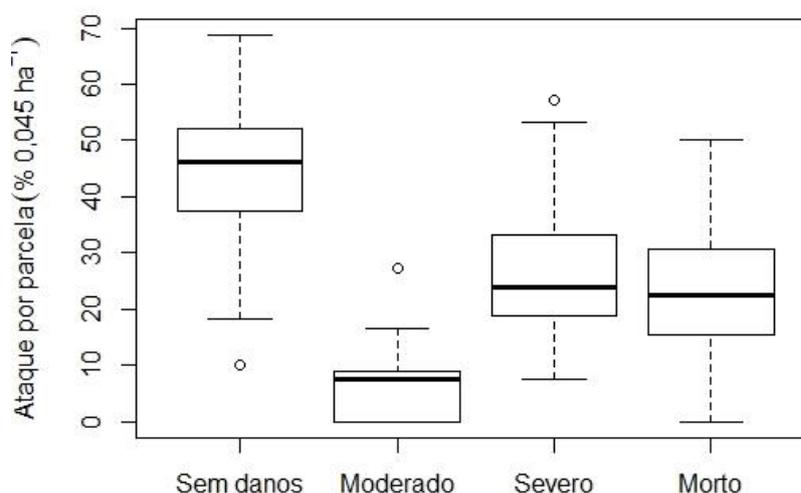
Para cada classe de dano avaliada, as análises estatísticas envolveram o teste de normalidade pelo teste de Kolmogorov-Smirnov a 5% de probabilidade. O delineamento foi o inteiramente casualizado com quatro tratamentos (percentual de ataque observado a campo, percentual de ataque estimado pelo modelo da técnica *Stepwise*, percentual de ataque estimado pelo modelo da técnica SVM e percentual de ataque estimado pelo modelo RF). As análises foram realizadas no *software* R versão 3.4.1. (R CORE TEAM, 2018).

4.3 RESULTADOS

A partir dos dados de inventário de campo verificou-se que os valores do percentual de ataque por parcela diferiram para cada classe analisada. Em todas as parcelas, pode-se perceber o maior número de árvores não atacadas do que atacadas, como nota-se nas estatísticas da classe sem danos: variação de 10% a 68,75%, média de 44,58% e coeficiente de variação de 27,68%. Já a classe de ataque moderado variou de 0% a 27,27%, com média de 6,79% e apresentou o maior coeficiente de variação (90,25%). Isso pode ser explicado pelo menor número de árvores com ataque do tipo janelamento. Em relação as árvores atacadas, a classe de ataque severo foi maior que as demais, com amplitude de 49,45%, coeficiente de variação de 41,32% e média de 27,15%. E a classe morto, por sua vez, apresentou média de 12,57%, amplitude de 50% e coeficiente de variação de 57,01%.

A Figura 4:2 ilustra a porcentagem de ataque nas classes de dano das 46 parcelas circulares de raio variável (5 a 10 m) instaladas no povoamento de *Pinus taeda* L. atacados por *Sapajus nigritus*.

Figura 4: 2 - Estatística descritiva da variável porcentagem de ataque por parcela (% 0,045 ha⁻¹) em povoamento de *Pinus taeda* L. atacados por *Sapajus nigritus*.



A seleção dos índices mais representativos por classe pela PCA para serem utilizados na construção dos modelos de regressão revelou que, para cada imagem analisada, dos 24 índices derivados apenas três índices se destacaram (Tabela 4:3). Esse fato está relacionado com a sensibilidade espectral de cada índice bem como com a variância dos valores derivados. Assim, esses índices foram apontados pela menor variância dos dados e maior representatividade com as classes de ataque.

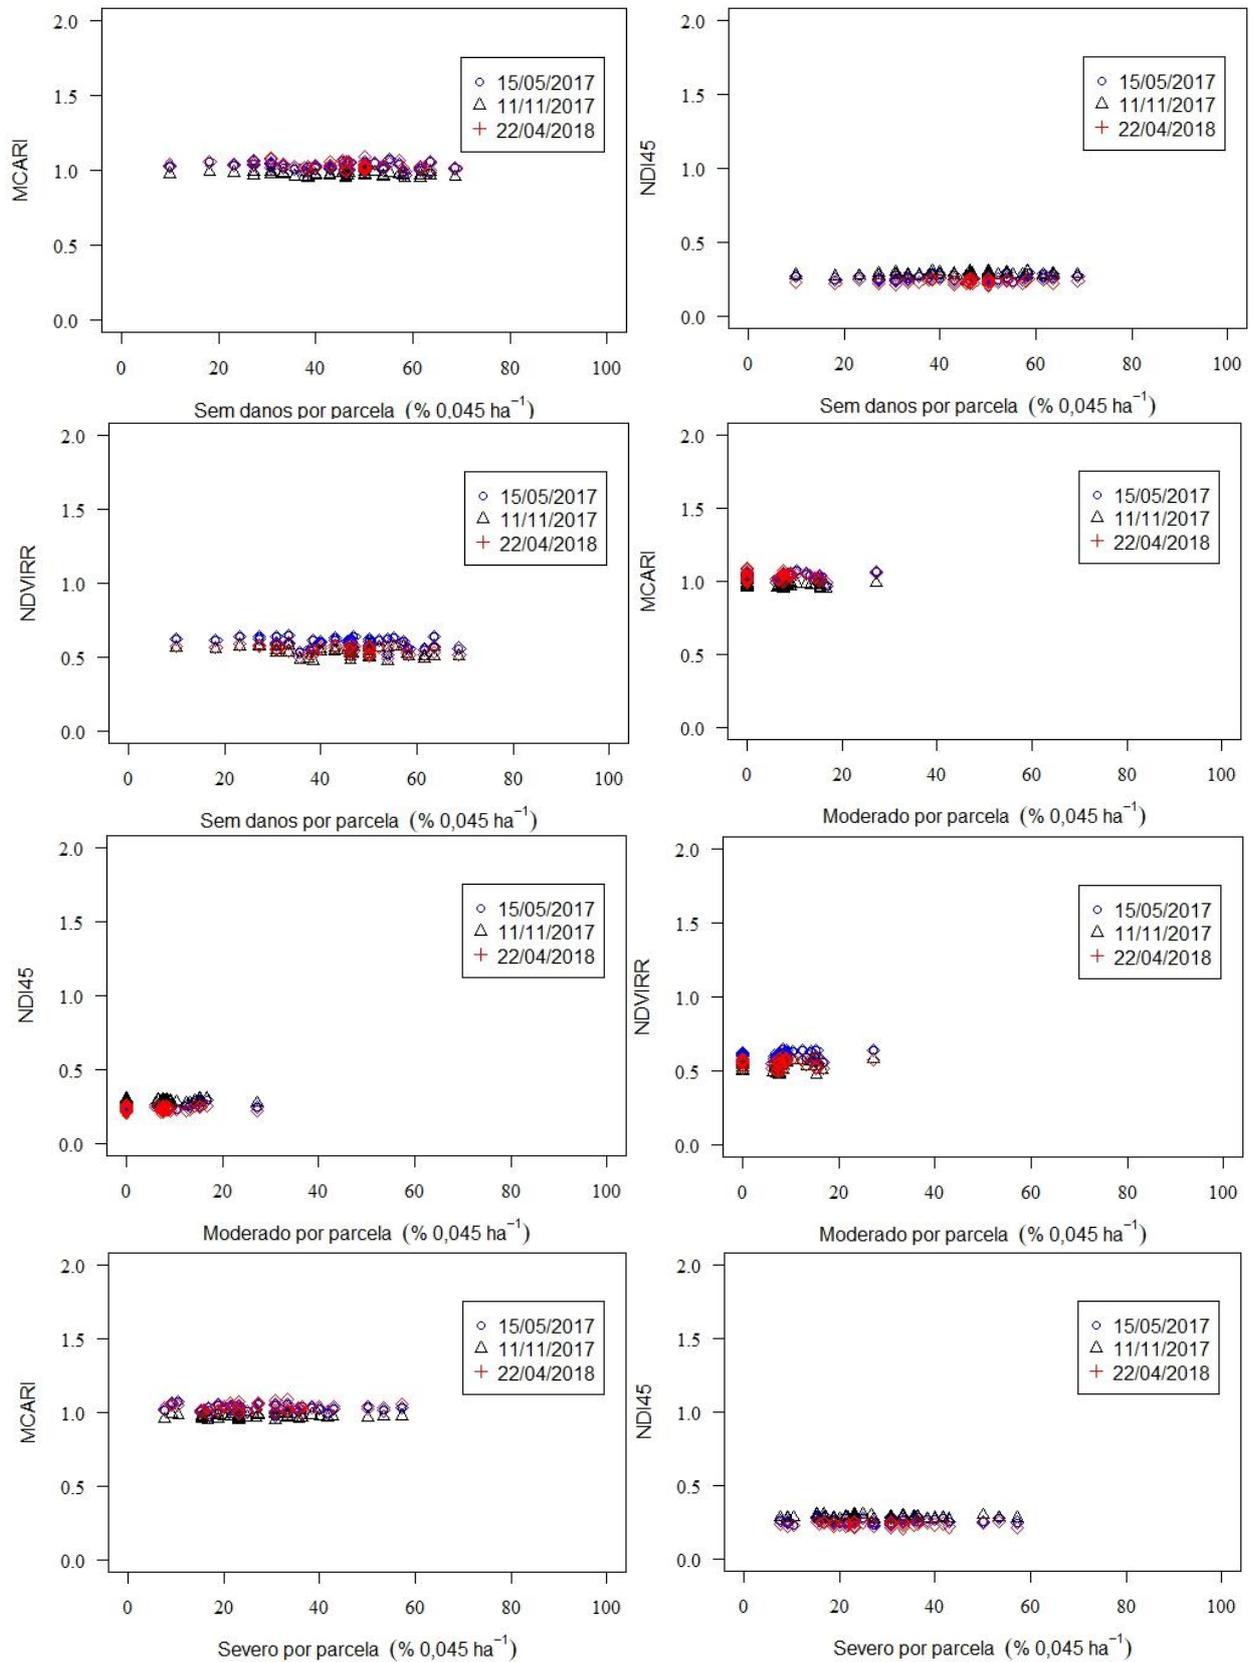
Tabela 4: 3 - Seleção das variáveis regressoras utilizando PCA para um povoamento de *Pinus taeda* L. atacado por *S. nigritus* em Bocaina do Sul – SC.

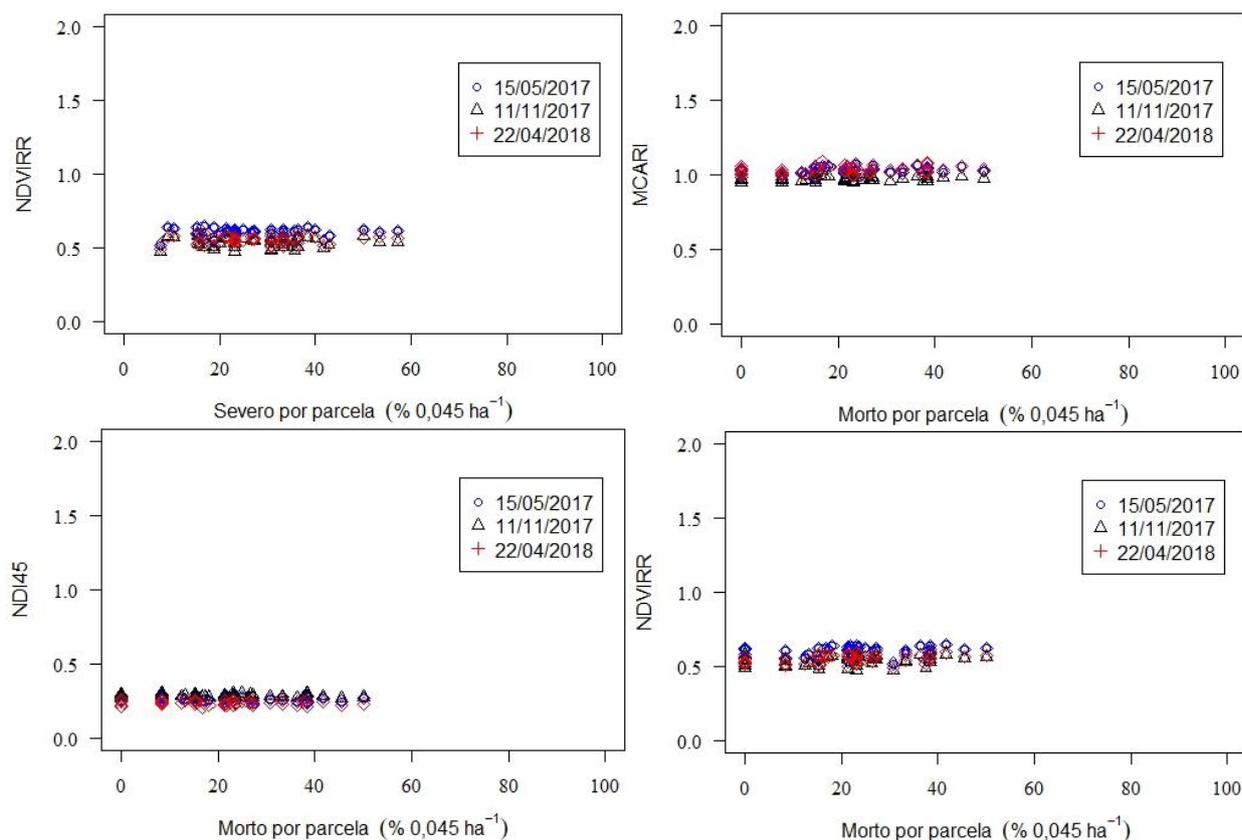
Classe	IV	Porcentagem de importância
Sem danos	NDVIRR e NDI45	0,8722
Moderado	NDVIRR e NDI45	0,8667
Severo	NDVIRR e NDI45	0,8664
Morto	NDVIRR e MCARI	0,8667

Em que: IV: Índice de Vegetação; MCARI: Modified Chlorophyll Absorption in Reflectance Index; NDI45: Normalized Difference Index 45 e NDVIRR: Red and Red-edge Normalized Difference Vegetation Index.

A relação dos IV selecionados pela PCA com o percentual de ataque de cada classe por parcela (% 0,045 ha⁻¹) expressou um comportamento diferente para cada classe de dano, índice e imagem analisada (Figura 4:3). A variação do comportamento dos índices está diretamente relacionada com as bandas espectrais abordadas no cálculo dos mesmos e sua relação com o ataque do *S. nigritus*.

Figura 4: 3 - Comportamento dos IV indicados pela PCA relacionados com as classes de ataque por parcela (% 0,045 ha⁻¹) para as três imagens do Sentinel-2/MSI.





Todos os modelos de regressão ajustados estimaram o percentual de classe de ataque por parcela com métricas de ajuste moderadas (Tabela 4:4). A variação do R^2 ajustado foi de 0,4274 a 0,9766, enquanto que os percentuais de erro variaram de 0,32 a 13,08 (% 0,045 ha⁻¹).

Tabela 4: 4 - Estatísticas do ajuste dos modelos de regressão testados para o sensor Sentinel-2 visando estimar o percentual de classe de ataque de macaco-prego por parcela (% 0,045 ha⁻¹) para um povoamento de *Pinus taeda* L. em Bocaina do Sul.

Sem danos									
Modelo	Método	IV	R ² aj	Syx	Syx (%)	F	AIC	BIC	RMSE
1	Stepwise	NDVIRR e NDI45	0,8042	5,85	13,49	5,63	216,31	268,57	1,95
2	SVM	NDVIRR e NDI45	0,9000	13,19	30,38	-	-	-	13,08
3	RF	NDVIRR e NDI45	0,8697	12,89	29,92	-	-	-	8,87
Moderado									
Modelo	Método	IV	R ² aj	Syx	Syx (%)	F	AIC	BIC	RMSE
1	Stepwise	NDVIRR e NDI45	0,4603	0,95	62,56	1,96	197,53	249,78	1,49
2	SVM	NDVIRR e NDI45	0,4274	4,43	61,42	-	-	-	4,89
3	RF	NDVIRR e NDI45	0,4508	5,91	81,87	-	-	-	6,51
Severo									
Modelo	Método	IV	R ² aj	Syx	Syx (%)	F	AIC	BIC	RMSE

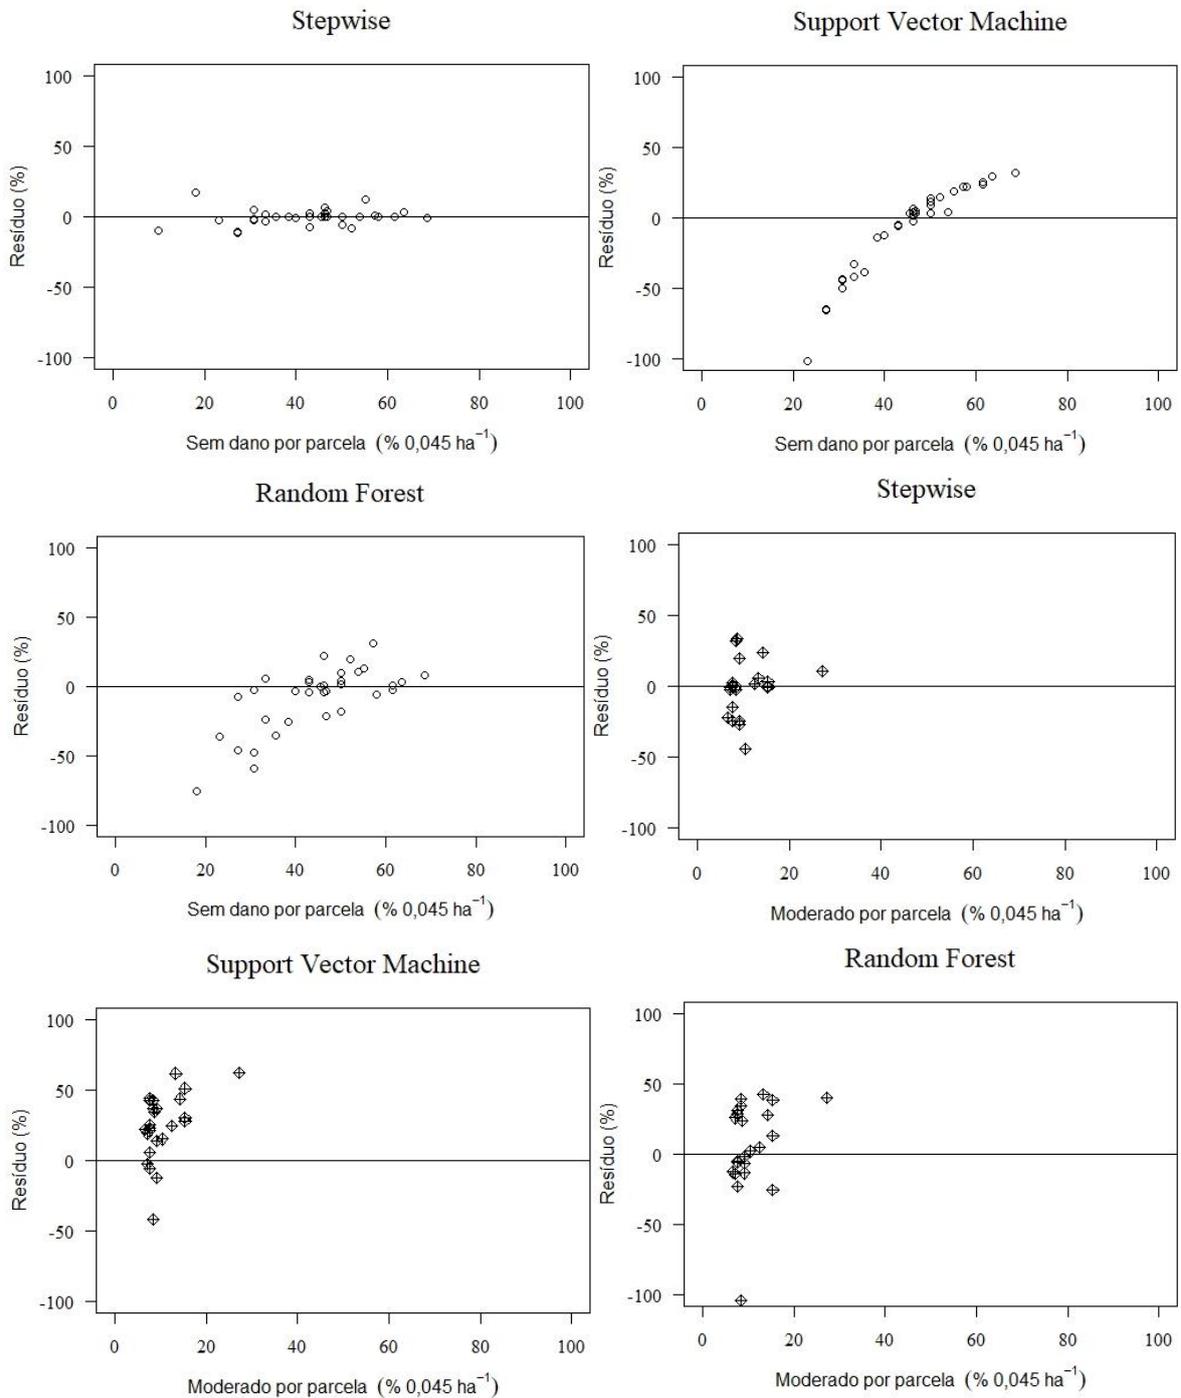
1	Stepwise	NDVIRR e NDI45	0,8815	4,15	15,11	8,89	170,63	226,05	2,11
2	SVM	NDVIRR e NDI45	0,9047	12,07	43,95	-	-	-	10,72
3	RF	NDVIRR e NDI45	0,8548	11,75	42,78	-	-	-	6,49
Morto									
Modelo	Método	IV	R² aj	Syx	Syx (%)	F	AIC	BIC	RMSE
1	Stepwise	NDVIRR e MCARI	0,9766	1,96	8,69	43,95	93,86	150,87	0,32
2	SVM	NDVIRR e MCARI	0,6900	11,38	50,27	-	-	-	11,67
3	RF	NDVIRR e MCARI	0,9629	13,21	58,37	-	-	-	12,98

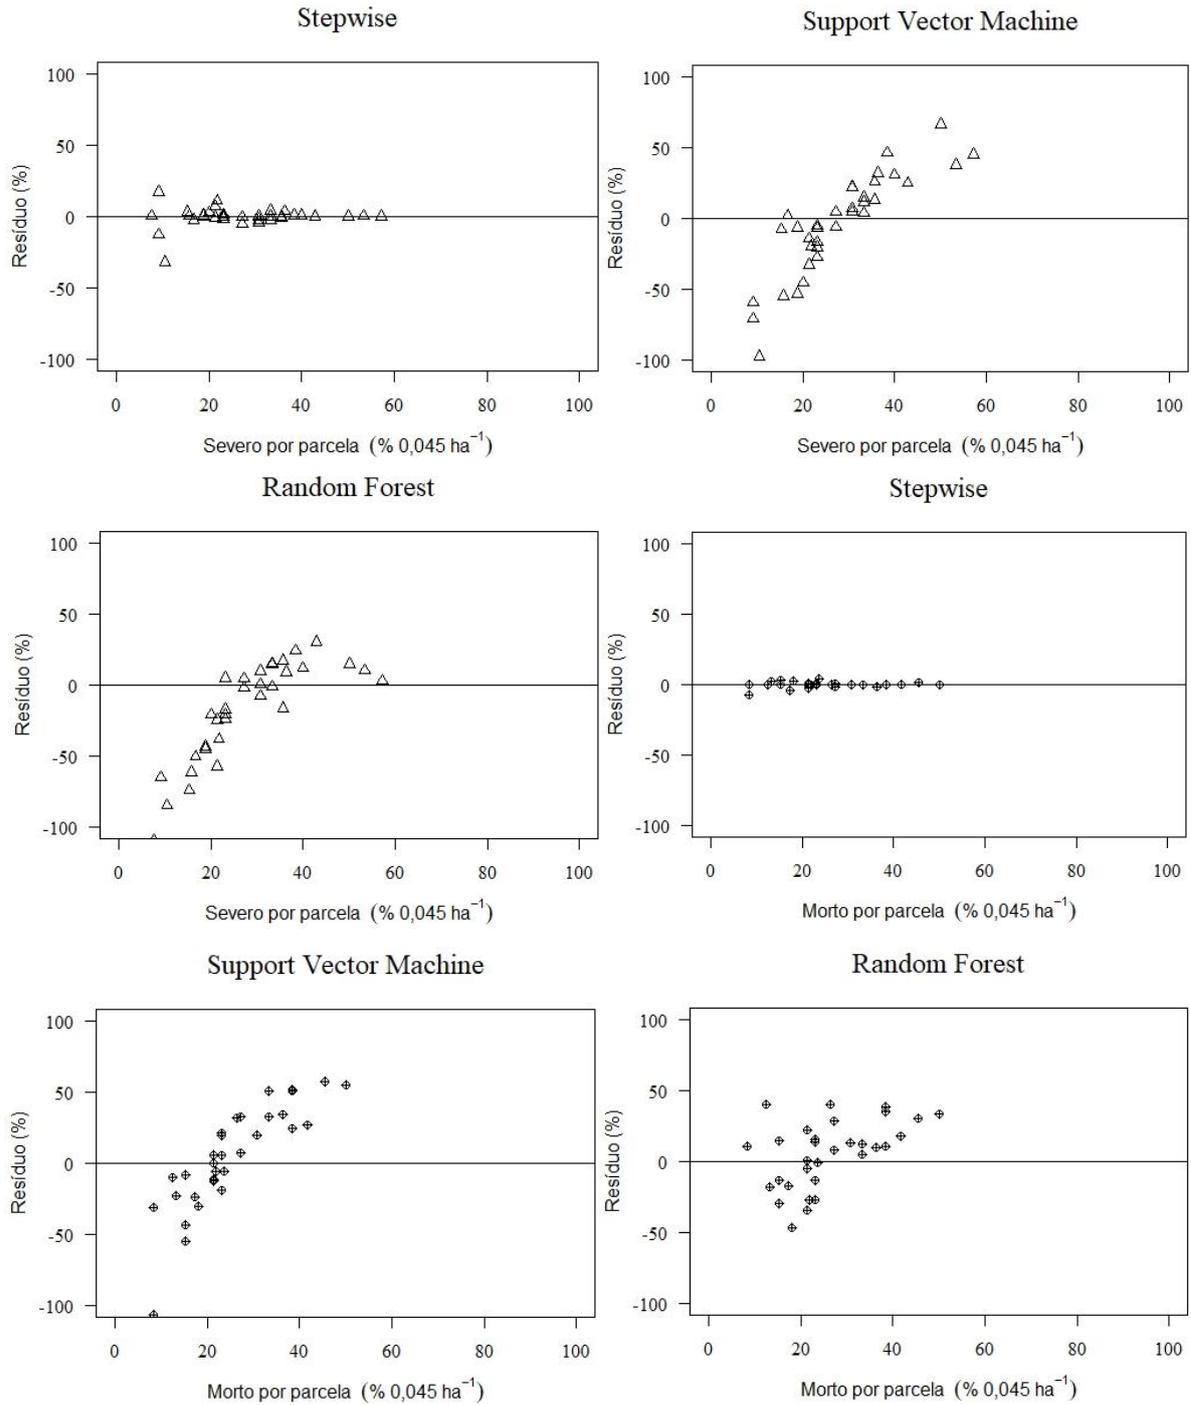
Em que: MCARI: Modified Chlorophyll Absorption in Reflectance Index; NDI45: Normalized Difference Index 45; NDVIRR: Red and Red-edge Normalized Difference Vegetation Index; R² aj: coeficiente de determinação ajustado; Syx: erro padrão da estimativa (% 0,045 ha⁻¹); Syx (%): erro padrão da estimativa (% 0,045 ha⁻¹); F: teste F com o nível de significância de 5% de probabilidade; AIC: Critério de Informação de Akaike; BIC: Critério de Informação Bayesiano; RMSE: Raiz do Erro Quadrático Médio (% 0,045 ha⁻¹).

Os métodos de regressão testados indicaram que, a modelagem *Stepwise* foi superior as demais, fato atribuído ao critério de adição ou remoção de variáveis ao modelo. Já os modelos desenvolvidos por aprendizado de máquina revelaram instabilidade na construção dos modelos, pelo critério de separação das amostras de treinamento no caso do SVM e nas florestas de decisão do RF.

Na análise gráfica dos resíduos dos modelos de regressão para predição do percentual de ataque por parcela por classe (% 0,045ha⁻¹) (Figura 4:4) foi possível notar que, nos modelos derivados da técnica *Stepwise*, houve distribuição dos resíduos mais concentrada em torno da linha de regressão. Nos modelos desenvolvidos pelas modelagens SVM e RF, os resíduos apresentaram comportamento semelhante, contudo, houve a presença de *outliers*, subestimativas e super estimativas. Entretanto, para a classe moderado, os resíduos foram altos para todas as técnicas testadas, em função da grande variabilidade dos dados e do menor número de árvores pertencentes a essa classe. Para as demais classes, ficou evidente a superioridade do método *Stepwise*, seguido por SVM e RF.

Figura 4: 4 - Dispersão gráfica dos resíduos dos modelos ajustados para as classes de dano pelas técnicas Stepwise, SVM e RF com os índices do Sentinel-2/MSI na estimativa do percentual de ataque de *S. nigritus* por parcela (% 0,045 ha⁻¹) em um povoamento de *Pinus taeda* L. em Bocaina do Sul.





A partir dos critérios estatísticos desenvolvidos, nota-se a superioridade dos modelos construídos pela técnica *Stepwise* em relação aos modelos de aprendizado de máquina. Em função dos maiores valores de R^2 ajustado, menores percentuais de erro e distribuição gráfica dos resíduos concentrada em torno da linha de regressão, os modelos mais indicados para estimar o percentual de ataque por classe foram os ajustados por *Stepwise*. Entretanto, a validação do melhor modelo por classe de dano indicou que não existem diferenças entre os valores de ataque estimados pelo referido modelo e os dados de ataque para cada classe observados a campo (Tabela 4:5).

Tabela 4: 5 - Teste do Qui-Quadrado para os modelos desenvolvidos pela técnica *Stepwise* para cada classe de ataque causado pelo *S. nigritus* em um povoamento de *Pinus taeda* L.

Classe	χ^2 tabelado	χ^2 calculado	Hipótese
Sem dano	16,91	0,076	Aceita H_0
Moderado	16,91	0,041	Aceita H_0
Severo	16,91	0,036	Aceita H_0
Morto	16,91	0,021	Aceita H_0

As análises estatísticas corroboram com tais resultados, revelando que não houve diferença significativa entre o percentual de ataque observado pelo inventário e pelos dados remotamente situados para cada classe de ataque.

4.4 DISCUSSÃO

Os IV selecionados pela PCA (MCARI, NDI45 e NDVIRR) para cada imagem analisada tiveram comportamentos distintos. O índice MCARI apresentou os maiores valores em todas as imagens, enquanto que o NDI45 foi o índice com os menores valores. Para o NDVIRR, os maiores valores foram representados na imagem que representa a antecedência do ataque. Para as demais imagens, os valores de reflectância desse índice também foram baixos.

Esse fato está relacionado com o comportamento espectral da vegetação nas faixas espectrais de cada índice. Os agentes causadores de estresse as plantas como ataques, doenças, temperaturas e nutrição induzem a perda de clorofila, interferindo drasticamente na absorção da radiação fotossinteticamente ativa. O resultado desse processo é o aumento da refletância na faixa do visível, com destaque para as bandas na região do vermelho (665 nm) e azul (560 nm) (CARTER; KNAPP, 2001). Com isso, essa faixa espectral não apresenta uma sensibilidade significativa às perdas de clorofila nos estágios iniciais do ataque (CARTER; KNAPP, 2001), como no caso do *S. nigritus*.

Contudo, as bandas *red-edge* possuem maior sensibilidade as variações do teor de clorofila as bandas do visível para detectar as mudanças nos valores de clorofila induzidos pelo estresse (EITEL et al., 2010) ou ataque de *S. nigritus*. A sensibilidade das bandas *red-edge* às variações no teor de clorofila foliar foi relatada primeiro por Rabinowitch e Govindjee (1969), que apontaram a existência de um pico de absorção de clorofila em 695 nm. Gitelson et al. (1996) indicaram fatores para fortalecer esse pressuposto, como a redução da área da folha em decorrência do ataque ou estresse, refletindo na redução da absorção da clorofila e no aumento da reflectância. Isso também causa diminuição de reflectância na faixa do infravermelho, que interage com a estrutura

foliar saudável e é espalhada pelas interfaces da célula aérea do mesofilo esponjoso (JENSEN, 2000).

Fatores como idade, densidade, tipo de vegetação de sub-bosque, tipo de solo e práticas de manejo florestal também podem contribuir para fortalecer a relação dos índices de vegetação com o ataque de *S. nigritus*, além de consolidar o conhecimento do padrão de ataque desse primata em povoamentos florestais. O monitoramento da sanidade florestal também pode estar associado ao clima, grau de perturbação, fenologia do tipo da floresta e agente causador do estresse (STONE; COOPS, 2004).

A utilização de IV permite a remoção da variabilidade causada pela geometria do dossel, fundo do solo, ângulos de visão solar e condições atmosféricas (GILABERT et al., 2002). Contudo, o emprego desses dados espectrais derivados de imagens multiespectrais, como o Sentinel-2/MSI implica em limitações, como o “problema de pixel misto”. Em um povoamento florestal, um *pixel* frequentemente representa a copa das árvores, o solo e outros materiais. Isso proporciona a obtenção de estimativas a nível de floresta e não a nível de árvore (MAITI et al., 2015).

Além disso, outro fator que interferiu na relação dos índices com o dano por parcela foi a quantidade de cobertura vegetal dentro dos pixels do Sentinel-2 (resolução espacial de 10 m) e do grau de homogeneidade dentro do pixel encontrado no povoamento florestal em estudo, como apontam Zarco-Tejada et al. (2018). A identificação das parcelas com o posicionamento receptores de sinais GNSS influenciaram na relação dos IV com as categorias de dano. Os erros associados ao uso de GPS em florestas envolvem atrasos na ionosfera e troposfera (ocorre diminuição de intensidade do sinal de GPS ao atravessar a atmosfera), multicaminhamento (reflexão do GPS por objetos ou estruturas antes de alcançar o receptor), relógio do receptor (precisão do relógio receptor ser inferior aos relógios atômicos dos satélites GPS) e erros de órbitas (informações incorretas acerca da posição dos satélites) (MONICO et al., 2014).

Segundo Wang et al. (2010), os índices de vegetação são utilizados como variáveis regressoras ou para outras análises de dados no SR aplicado a sanidade florestal. Isso permite uma aproximação entre o que foi observado pelos sensores e com as variáveis físicas florestais. Contudo, os autores ressaltam que nessas análises de regressão, os coeficientes de determinação podem ser baixos quando utilizam índices para a predição das respostas das plantas às mudanças no ambiente. Mesmo assim, a regressão de IV com variáveis florestais correspondem a informações valiosas.

O índice NDVI se destacou como um dos mais indicados para avaliar o nível de desfolhação de uma floresta na pesquisa de Rullan-Silva et al. (2013). Entretanto, os índices mais robustos encontrados para esse estudo foram o NDVIRR, seguido do NDI45. Isso está relacionado

com a variação das bandas mais adequadas para a detecção de áreas atacadas em decorrência da fase ou nível de ataque.

O NDVIRR foi o índice mais robusto para o diagnóstico da resposta óptica ao ataque de *S. nigritus*. Isso indica que a associação de bandas nas faixas do vermelho, *red-edge* e NIR fornecem melhores estimativas de áreas atacadas por macaco-prego, pois essas faixas espectrais estão diretamente relacionadas com a reflectância de radiação, que depende da sanidade do tecido vegetal.

Tal resultado corrobora com a pesquisa de Zarco-Tejada et al. (2018), no qual os autores monitoraram a condição de copa de florestas de coníferas em uma dimensão temporal na região espectral *red-edge*, avaliando as trajetórias temporais dos índices sensíveis à clorofila, utilizando um modelo de transferência radiativa em 3D, três voos hiperespectrais de alta resolução espacial conduzidos dentro de um período de dois anos, juntamente com avaliações de campo de 400 árvores para desfolha e clorose associadas a imagens do Sentinel-2A. Essa metodologia demonstrou que, houve diferença no teor de clorofila na região espectral *red-edge* da floresta ao longo do período analisado, em função da desfolha. Os autores também destacaram o potencial de usar este método de tendência temporal baseado na taxa de mudança da borda vermelha para detectar e monitorar processos de declínio em árvores e florestas.

Os modelos de regressão para cada classe de ataque desenvolvidos pela modelagem tradicional (*Stepwise*) e pelas máquinas de aprendizado (SVM e RF) demonstraram o desempenho moderado de todas as técnicas para todas as imagens. A adição de variáveis regressoras pela técnica *Stepwise* (*Forward* e *Backward*) resultou em modelos lineares com R^2 ajustado e percentuais de erro inferiores. Os modelos não lineares calibrados por SVM tiveram métricas de ajuste superiores às da técnica *Stepwise* com um menor número de variáveis regressoras. E a modelagem RF resultou em modelos não lineares e menos estáveis que as demais.

Para a classe sem danos, todos os modelos desenvolvidos revelaram métricas de ajuste satisfatórias. A modelagem SVM gerou R^2 ajustado superiores aos demais, seguida por RF e *Stepwise*. Contudo, o modelo desenvolvido por *Stepwise* teve os menores percentuais de erro, AIC, BIC, RMSE e melhor distribuição de resíduos. A classe de ataque moderado obteve as estatísticas de ajuste com os maiores percentuais de erro para todas as técnicas testadas. Esse fato pode ser explicado pelo reconhecimento desse tipo de dano nas imagens e posteriormente nos índices utilizados nos modelos. Os modelos ajustados para estimar o percentual de ataque severo por parcela revelaram um bom desempenho de todas as técnicas de modelagem. Contudo, os modelos desenvolvidos por *Stepwise* foram superiores aos demais. E as estimativas da última classe de

ataque, referente as árvores mortas, foram significativas, com destaque para a técnica *Stepwise*, RF e SVM.

Também é importante ressaltar que, é recomendado testar a confiabilidade do modelo com dados oriundos de outros sensores que possuem as faixas espectrais do vermelho, NIR, *red-edge* e SWIR, como recomendam Eitel et al. (2011). Além disso, a importância de uma plataforma de satélite com informações de banda *red-edge* para o desenvolvimento do sistema de detecção e monitoramento de desfolhação de insetos e outras pragas foi ressaltada por Adelabu et al. (2014), bem como a classificação do nível de saúde para o manejo florestal.

Os erros das predições feitas pelos modelos ajustados podem estar relacionados com a identificação das parcelas no campo, como já mencionado anteriormente. O posicionamento das parcelas com receptores de sinais GNSS do tipo *Garmin Etrex Legend®*, pode apresentar erro de multicaminhamento dependendo das características do dossel do povoamento. Canavesi et al. (2010) também apontam a geometria de iluminação do terreno como um elemento decisivo nesse estudo.

Os IV obtidos e os modelos de regressão ajustados demonstraram que as imagens multiespectrais oriundas do Sentinel-2 possuem sensibilidade para a detecção de áreas atacadas por *S. nigritus* no povoamento de *Pinus taeda* L. Os resultados aqui encontrados podem ser utilizados para o desenvolvimento de modelos que visam relacionar a reflectância espectral com as variáveis biofísicas de áreas de vegetação atacadas por algum tipo de praga florestal ou populações problema, como é o caso do *S. nigritus*.

O desenvolvimento de modelos de regressão utilizando IV oriundos de imagens de Sentinel-2 como variáveis regressoras por meio de técnicas de *Random Forest* (RF), *Support Vector Machines* (SVM) e *K-Nearest Neighbors* (KNN) para a estimativa da desfolhação em *Pinus sylvestris* foi testado por Hawyrlo et al. (2018). Os índices mais robustos foram o MTCI e o GNDVI, os quais foram utilizados na construção de modelos de regressão. As duas primeiras técnicas desenvolveram modelos com R^2 de 0,57 e nRMSE de 11,6 e 11,9, respectivamente. Utilizando KNN, os modelos tiveram R^2 de 0,53 e nRMSE de 12,2. O SVM foi considerado o método mais estável para esse conjunto de dados, contudo, os autores recomendam utilizar diversos índices de vegetação como variáveis preditoras desses modelos e indicam o Sentinel-2 como uma fonte de dados promissora para o desenvolvimento de métodos de avaliação de desfolhação florestal.

A combinação de IV com parâmetros fisiológicos por um modelo de SVM foi avaliada por Rumpf et al. (2010), para a detecção precoce e classificação de doenças de plantas com acurácia de classificação de 97%. A discriminação de plantas saudáveis e estressadas também foi realizada

por Behmann et al. (2014), a partir de uma combinação otimizada de IV com alto poder discriminativo em um modelo SVM.

A associação de IV com níveis de infestação causados por doenças, pragas ou causadores de estresse em plantas já foi investigada utilizando técnicas de SR em diversas pesquisas. O teste de IV para a detecção de infestações por *Sirex noctilio* em *Pinus patula* foi realizado por Ismail et al. (2007). Os índices NDVI, RVI, DVI e GNDVI foram derivados a partir de imagens multiespectrais do sensor LrEye e correlacionados com os dados de infestação obtidos a campo. Os índices NDVI e GNDVI tiveram a maior força relativa pela análise canônica variável e foram utilizados para classificar os níveis de infestação em saudável, vermelho e cinzento. Contudo, o NDVI foi superior, demonstrando o potencial para detectar e monitorar danos nas copas de árvores de *Pinus patula* causados por *S. noctilio*.

O acréscimo de informações da reflectância da banda *red-edge* melhorou as estimativas das variações no teor de clorofila em *Pinus sylvestris* no estudo de Eitel et al. (2010). O modelo com esses dados estimou o teor de clorofila com RMSE de 1,69 e R^2 ajustado de 0,73. Sem a referida faixa espectral, o RMSE foi 2,11 e o R^2 ajustado de 0,57. Essa banda espectral também se destacou no estudo de Carter et al. (1996), no qual detectou o estresse induzido por herbicida em *Pinus taeda* L. e *Pinus elliottii* Engelm. 16 dias antes de sinais visuais de estresse.

Estudos com Sentinel-2 ainda são recentes nesse contexto de sanidade florestal, contudo, outros sensores ópticos de média a alta resolução espacial foram utilizados em pesquisas com essa abordagem, como pode-se citar os estudos de Townsend et al. (2012), Olsson et al. (2016), Foster et al. (2017), Marx e Kleinschmit (2017), e Abdullah et al. (2018).

A influência no tempo de aquisição de imagens Landsat-5 no mapeamento da intensidade da desfolha em áreas florestais nos Estados Unidos foi examinada por Townsend et al. (2012), entre os anos de 2000-2008. O melhor índice foi o NDI11, com forte relação entre a vegetação avaliada e o índice de alteração detectada nas imagens pré e pós deposição. Com erro quadrático médio de 14,9% e coeficiente de determinação ajustado de 0,802, foi possível mapear a desfolha utilizando o índice NDI11 em cinco anos diferentes.

A relação entre dados oriundos do sensor MODIS (*Moderate Resolution Imaging Spectroradiometer*) e a perturbação causada por insetos utilizando um método de detecção de dano foi investigado por Olsson et al. (2016). O método foi baseado no z-scores dos máximos sazonais do *Enhanced Vegetation Index 2* (EVI2) de 2 bandas e aplicado em florestas fragmentadas e fortemente manejadas de pinheiro-silvestre (*Pinus sylvestris* L.) e com desfolha de serapilheira (*Neodiprion sertifer* Geoffr.). Os resultados demonstraram que o sensor MODIS não foi eficiente na detecção de danos em florestas fragmentadas, particularmente quando o histórico de danos é

longo e estudos regionais baseados nesses dados podem subestimar a desfolhação. No entanto, o método produziu resultados precisos em ecossistemas florestais homogêneos. Além disso, esse método poderia ser utilizado em imagens de média resolução espacial, como do sensor Sentinel-2.

A combinação estatística entre a desfolha em florestas de pinheiros infestadas por traças (*Lymantria monacha*) e as bandas espectrais do sensor *RapidEye*, juntamente com os índices NDVI e NDVIR foi avaliada por Marx e Kleinschmit (2017). Os dois índices foram bem correlacionados com a desfolha, contudo, o NDVI foi mais indicado para diagnosticar áreas com danos graves, ao passo que o NDVIR foi mais eficiente na detecção de áreas com desfolha precoce.

Os melhores comprimentos de onda para a detecção da infestação de *Dendroctonus rufipennis* em *Picea engelmannii* nas florestas subalpinas do oeste dos Estados Unidos foram determinados por Foster et al. (2017). A região do SWIR do espectro eletromagnético foi o melhor comprimento de onda para a detecção de fases precoces da infestação de besouros, evidenciando o potencial dessa faixa espectral na detecção da infestação de besouros no primeiro estágio em áreas maiores usando imagens de satélite multiespectral. Os autores também descobriram que a série temporal de reflectância na banda 7 do Landsat-TM (SWIR) estava fortemente correlacionada com a progressão no tempo de um surto de besouro no sul do Wyoming. Isso pode facilitar o entendimento da dinâmica espaço-temporal dos surtos de besouros e mitigar potencialmente alguma mortalidade dessa espécie de *Pinus* spp.

O impacto do ataque de besouro da casca (*Ips typographus* L.) em *Picea abies* (L.) Karst bem como a precisão da estimativa de propriedades bioquímicas das folhas utilizando medidas hiperespectrais foi investigado por Abdullah et al. (2018). Tal infestação afetou a precisão da estimativa das concentrações de clorofila e nitrogênio, examinadas por meio de dados de reflectância hiperespectral e modelo de regressão parcial dos mínimos quadrados. Os autores destacam o potencial desse estudo e sugerem que novas pesquisas sejam desenvolvidas para avaliar se os resultados apresentados podem ser obtidos no nível do dossel usando dados de SR diferentes, como imagens multiespectrais.

Por fim, algumas limitações dessa pesquisa devem ser apontadas, como por exemplo, o tamanho e o georreferenciamento das parcelas a campo, os receptores GPS utilizados, a resolução espacial das imagens (10 metros), características da área como tipo de solo, idade das árvores e condições topográficas. Por isso, recomenda-se para futuros trabalhos que tal metodologia seja testada em sensores de alta a ultra alta resolução espacial, em outras áreas florestais acometidas por *S. nigritus* em diferentes épocas e com diferentes índices de vegetação.

4.5 CONCLUSÃO

Para o conjunto de dados utilizados nessa pesquisa, os índices mais robustos para a identificação de áreas atacadas por *S. nigritus* por parcela em um povoamento de *Pinus taeda* L. foram o MCARI (*Modified Chlorophyll Absorption in Reflectance Index*), NDVIRR (*Red and Red-Edge Modified Chlorophyll Index*) e NDI45 (*Normalized Difference Index 45*).

Os modelos de regressão utilizados para a estimativa das classes de ataque por parcela (% 0,045 ha⁻¹) tiveram métricas de ajuste significativas. A modelagem desenvolvida pela técnica *Stepwise* foi superior aos modelos desenvolvidos pelos métodos de máquina de aprendizado (SVM e RF).

Foi possível estimar/identificar áreas atacadas por esse primata no povoamento avaliado, contudo, recomenda-se testar imagens obtidas por imagens digitais de alta e ultra alta resolução espacial, para fortalecer a metodologia aqui apresentada.

REFERÊNCIAS

- ABBAD, G.; TORRES, C.V. Regressão múltipla stepwise e hierárquica em Psicologia Organizacional: aplicações, problemas e soluções. **Estudos de Psicologia**, v. 7, p. 19-29, 2002.
- ADELABU, S.; MUTANGA, O.; ADAM, E. Evaluating the impact of red-edge band from Rapideye image for classifying insect defoliation levels. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 95, p. 34-41, 2014.
- ALVARES, C. A.; STAPE, J. L.; SENTELHAS, P.C.; GONÇALVES, J. L. M.; SPAROVEK, G. Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, Stuttgart, v. 22, n. 6, p.711-728, 2013.
- ANDRADE, E. M.; ARAÚJO, L. F. P.; ROSA, M. F.; GOMES, R. B.; LOBATO, F. A. O. Fatores determinantes da qualidade das águas superficiais na bacia do Alto Acaraú, Ceará, Brasil. **Ciência Rural**, v.37, p.1791-1797, 2007.
- BEHMANN, J.; STERINRUCKEN, J.; PLUMER, L. Detection of early plant stress responses in hyperspectral images. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 93, p. 98-111, 2014.
- BELGIU, M.; DRAGUT, L. Random forest in remote sensing: A review of applications and future directions. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 114, p. 24-31, 2016.
- BERNARDI, J.V.E.; FOWLER, H.G.; LANDIM, P.M.B. Um estudo de impacto ambiental utilizando análises estatísticas espacial e multivariada. **Holos Environmental**, v. 1, p. 162-172, 2001.
- BERNARDI, J.V.E.; LACERDA, L.D.; DÓREA, J.G.; LANDIM, P.M.B.; GOMES, J.P.O.; ALMEIDA, R.; MANZATTO, A.G.; BASTOS, W.R. Aplicação da análise das componentes principais na ordenação dos parâmetros físico-químicos no alto rio madeira e afluentes, Amazônia Ocidental. **Geochimica Brasiliensis**, v. 23, n. 1, p. 079-090, 2009.
- BLACKBURN, G. A. Spectral indices for estimating photosynthetic pigment concentrations: A test using senescent tree leaves. **International Journal of Remote Sensing**, v. 19, n. 4, p. 657-675, 1998.
- BREIMAN, L. Random Forests. **Machine Learning**, v. 45, p. 5-32, 2001.
doi:10.1023/A:1010933404324.

CARTER, G.; CIBULA, W.; MILLER, R. L. Narrow-band reflectance imagery compared with thermal imagery for early detection of plant stress. **Journal of Plant Physiology**, v. 148, p. 515–522, 1996.

CARTER, G. A.; KNAPP, A. K. Leaf optical properties in higher plants: linking spectral characteristics to stress and chlorophyll concentration. **American Journal of Botany**, v. 88, p. 677–684, 2001.

CAMPOS, J.C.C.; LEITE, H.G. **Mensuração Florestal: Perguntas e Respostas**. Viçosa: Editora UFV, 3ed. 2009, 542 p.

CANAVESI, V.; PONZONI, F. J.; VALERIANO, M. M. Estimativa de volume de madeira em plantios de Eucalyptus spp. utilizando dados hiperespectrais e dados topográficos. **Revista Árvore**, v. 34, n. 3, p. 539-549, 2010.

CLEVERS, J. G. P. W.; JONG, S. M. DE; EPEMA, G. F.; ADDINK, E. A.; BOX, P. O. Meris and the Red-Edge Index. In 2nd EARSeL workshop, Enschede, 2000 (pp. 1–16), 2000.

DASH, J.; CURRAN, P.J. Evaluation of the MERIS terrestrial chlorophyll index (MTCI). **Advances in Space Research**, v. 39, n. 1, p. 100–104, 2007.

DAUGHTRY, C. Estimating Corn Leaf Chlorophyll Concentration from Leaf and Canopy Reflectance. **Remote Sensing of Environment**, v. 74, n. 2, p. 229–239, 2000.

EITEL, J. U. H.; KEEFE, R. F.; LONG, D. S.; DAVIS, A. S.; VIERLING, L. A. Active ground optical remote sensing for improved monitoring of seedling stress in nurseries. **Sensors**, v. 10, p. 2843–2850, 2010.

EITEL, J. U. H.; VIERLING, L. A.; LITVAK, M. E.; LONG, D. S.; SCHULTHESS, U.; AGER, A. A.; KROFCHECK, D. J.; STOSCHECK, L. Broadband, red-edge information from satellites improves early stress detection in a New Mexico conifer woodland. **Remote Sensing of Environment**. v. 115, i. 12, 15, p. 3640–3646, 2011.

ESA. European Space Agency. **SNAP and Sentinel Toolboxes**. Disponível em: <http://step.esa.int/main/download/>. Acesso em: 06 ago 2018.

ESRI. Environmental Systems Research Institute. **ArcGIS Professional GIS for the desktop, version 10.4.1**. Disponível em: <https://support.esri.com/en/Products/Desktop/arcgis-desktop/arcmap/10-4-1>. Acesso em: 20 mai. 2018.

EXELIS. **Visual Information Solutions**. Disponível em:

< <https://www.harrisgeospatial.com/SoftwareTechnology/ENVI.aspx> > . Acesso em: 24 mai. 2018.

FERNÁNDEZ-MANSO, A.; FERNÁNDEZ-MANSO, O.; QUINTANO, C. SENTINEL-2A red-edge spectral indices suitability for discriminating burn severity. **International Journal of Applied Earth Observation and Geoinformation**, v. 50, p. 170–175, 2016.

FOSTER, A.C.; WALTER, J.A.; SHUGART, H.H. SIBOLD, A.; NEGRON, J. Spectral evidence of early-stage spruce beetle infestation in Engelmann spruce. **Forest Ecology and Management**, v. 384, p. 347-357, 2017.

FRAMPTON, W.F.; DASH, J.; WATMOUGH, G.; MILTON, E.J. Evaluating the capabilities of Sentinel-2 for quantitative estimation of biophysical variables in vegetation. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 82, p. 83–92, 2013.

GILABERT, M.A.; GONZALEZ-PIQUERAS, J.; GARCIA-HARO, F.J.; MELIA, J. A generalized soil-adjusted vegetation index. **Remote Sensing of the Environment**, v. 82, p. 303–310, 2002.

GITELSON, A.A.; KAUFMAN, Y.J.; MERZLYAK, M.N. Use of a green channel in remote sensing of global vegetation from EOS-MODIS. **Remote Sensing of Environment**, v. 58, n. 3, 289–298, 1996.

GITELSON, A.A.; MERZLYAK, M.N.; CHIVKUNOVA, O.B.; GITELSON, A.A.; MERZLYAK, M.N.; CHIVKUNOVA, O.B. Optical properties and nondestructive estimation of anthocyanin content in plant leaves. **Photochemistry and Photobiology**, v. 74, n. 1, p. 38–45, 2001.

GITELSON, A.A.; ZUR, Y.; CHIVKUNOVA, O.B.; MERZLYAK, M. N. Assessing carotenoid content in plant leaves with reflectance spectroscopy. **Photochemistry and Photobiology**, v. 75, n. 3, p.272–281, 2002.

GITELSON, A. A.; VIÑA, A.; ARKEBAUER, T. J.; RUNDQUIST, D. C.; KEYDAN, G.; LEAVITT, B. (2003). Remote estimation of leaf area index and green leaf biomass in maize canopies. **Geophysical Research Letters**, v. 30, n. 5, n/a-n/a, 2003a.

GITELSON, A.A.; GRITZ, Y.; MERZYLAK, M.N. Relationships between leaf chlorophyll content and spectral reflectance and algorithms for non destructive chlorophyll assessment in higher plant leaves. **Journal of Plant Physiology**, v. 160, p. 271-282, 2003b. doi: 10.1078/0176-1617-00887.

GUYOT, G.; BARET, F. Utilisation de la Haute Resolution Spectrale pour Suivre L'état des Couverts Vegetaux. In 4th International Colloquium "Spectral Signatures of Objects in Remote Sensing", Aussois, 18– 22 January 1988, Paris: ESA, Publication SP-287 (pp. 279–286), 1988.

HARDISKY, M.; KLEMAS, V.; SMART, R. The Influences of Soil Salinity, Growth Form, and Leaf Moisture on the Spectral Reflectance of *Spartina Alterniflora* Canopies. **Photogrammetric Engineering and Remote Sensing**, v. 49, p. 77–83, 1983.

HAWRYLO, P.; BEDNARZ, B.; WEŻYK, P.; SZOSTAK, M. Estimating defoliation of Scots pine stands using machine learning methods and vegetation indices of Sentinel-2. **European Journal of Remote Sensing**, v. 51, n. 1, p. 194-205, 2018.

HENDGES, C. D.; MELO, G. L.; GONÇALVES, A. S.; CEREZER, F. O.; CÁ CERES, N. C. Landscape attributes as drivers of the geographical variation in density of *Sapajus nigritus* Kerr, 1792, a primate endemic on the Atlantic Forest. **Acta Oecologica**, n. 84, p. 57-63, 2017.

HUETE, A. A soil-adjusted vegetation index (SAVI). **Remote Sensing of Environment**, v. 25, n. 3, p. 295–309, 1988.

ISMAIL, R.; MUTANGA, O.; BOB, U. Forest health and vitality: the detection and monitoring of *Pinus patula* trees infected by *Sirex noctilio* using digital multispectral imagery. **Southern Hemisphere Forestry Journal**, v. 69, n. 1, p. 39-47, 2007.

JENSEN, J.R. **Remote sensing of the environment - an earth resource perspective**. Pearson Prentice Hall, MN, USA, pp. 544. 2000.

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

KANTOLA, T.; VASTARANTA, M.; YU, X.; LYYTIKÄINEN-SAARENMAA, P.; HOLOPAINEN, M.; TALVITIE, M.; KAASALAINEN, S. L.; SOLBERG, S.; HYYPPA, J. Classification of defoliated trees using tree-level airborne laser scanning data combined with aerial images. **Remote Sensing**, v. 2, n.12, p. 2665–2679, 2010.

KEY, C. H., ZHU, Z., OHLEN, D., HOWARD, S., MCKINLEY, R., & BENSON, N. The normalized burn ratio and relationships to burn severity: ecology, remote sensing and implementation. In J. D. Greer (Ed.), *Rapid Delivery of Remote Sensing Products*. Proceedings of the Ninth Forest Service Remote Sensing Applications Conference, San Diego, CA 8–12 April, 2002. Bethesda: American Society for Photogrammetry and Remote Sensing. 2002.

KOEHLER, A.; FIRKOWSKI, C. Descascamento de pinus por macaco-prego (*Cebus apella*). **Floresta**, Curitiba, v. 24, n. 1/2, p. 61-75, 1996.

KUHN, M.; JOHNSON, K. **Applied predictive modeling**. Springer, 2013. doi:10.1007/978-1-4614-6849-3.

LAUSCH, A.; ERASMI, S.; KING, D.J.; MAGDON, P.; HEURICH, M. Understanding forest health with remote sensing-Part I-A review of spectral traits, processes and remote-sensing characteristics. **Remote Sensing**, v. 8, n. 12, p. 1029–1043, 2016.

LAUSCH, A.; ERASMI, S.; KING, D.J.; MAGDON, P.; HEURICH, M. Understanding forest health with remote sensing-Part II-A review of approaches and data models. **Remote Sensing**, v. 9, n. 2, p. 129–133, 2017.

LIEBSCH, D.; MARQUES, M. C. M.; GOLDENBEG, R. How long does the Atlantic Rain Forest take to recover after a disturbance? Changes in species composition and ecological features during secondary succession. **Biological Conservation**, v. 141, n. 6, p. 1717-1725, 2008. ISSN 0006-3207.

LIAW, A.; WIENER, M. Classification and Regression by Random Forest. **RNews**, v. 2/3, p. 18–22, 2002.

LYNCH ALFARO, J. W.; DE SOUSA E SILVA, J., JR.; RYLANDS, A. B. How Different Are Robust and Gracile Capuchin Monkeys? An Argument for the Use of *Sapajus* and *Cebus*. **American Journal of Primatology**, v. 74, n. 4, p. 273-286, 2012.

MAITI, S.; SATPATHY, R.; BANDYOPADHYAY, J.; JEYASEELAN, A.T. Vegetation parameter derivation for forest health measurement and stress detection in a time series. **Research & Reviews: Journal of Ecology**, v. 4, n.3, p. 19-26, 2015.

MARX, A.; KLEINSCHMIT, B. Sensitivity analysis of RapidEye spectral bands and derived vegetation indices for insect defoliation detection in pure scots pine stands. **IForest**, v. 10, n. 4, p. 659–668, 2017.

MIKICH, S. B.; LIEBSCH, D. **O Macaco-prego e os Plantios de *Pinus* spp.** Comunicado Técnico, n 234. Embrapa Florestas. Colombo, PR, p.1-5. 2009.

MIKICH, S. B.; LIEBSCH, D. Damage to forest plantations by tufted capuchins (*Sapajus nigritus*): too many monkeys or not enough fruits? **Forest Ecology and Management**, v. 314, p. 9-16, 2014.

MERZLYAK, M. N.; GITELSON, A. A.; CHIVKUNOVA, O. B.; RAKITIN, V. Y. Non-destructive optical detection of pigment changes during leaf senescence and fruit ripening. **Physiologia Plantarum**, v. 106, n. 1, p. 135–141, 1999.

MONICO, J.F.G.; ROFATTO, V.F.; MENDONÇA, M.A.M.D. Introdução e aplicação da diluição da precisão das ambiguidades GNSS - ADOP. **Boletim de Ciências Geodésicas**, Curitiba, v. 20, n.2, p. 279-299, 2014.

MOSER, P.; OLIVEIRA, L.Z. **Regressão linear aplicada à dendrometria**: uma introdução e iniciação à linguagem R. Blumenau: Edifurb, 2017. 152p.

MOZGERIS, G.; AUGUSTAITIS, A. Estimating crown defoliation of Scots pine (*Pinus sylvestris* L.) trees using small format digital aerial images. **iForest - Biogeosciences and Forestry**, v. 6, n. 1, p. 15–22, 2013.

NETO, B.D.B.; SCARMINIO, I.S.; BRUNS, R.E. **Como fazer experimentos**: pesquisa e desenvolvimento na ciência e na indústria. SP: Editora Unicamp, 2 ed. 2002. 405p.

NICOLETTI, M. F.; SOUZA, K.; SILVESTRE, R.; FRANÇA, M. C.; ROLIM, F. A. Relação Hipsométrica para *Pinus taeda* L. em Diferentes Fases do Ciclo de Corte. **Floresta e Ambiente**, Seropédica, v. 23, n. 1, p. 80-89, 2016.

OLSSON, P.O.; KANTOLA, T.; LYYTIKÄINEN-SAARENMAA, P.; JÖNSSON, A. M.; EKLUNDH L. Development of a method for monitoring of insect induced forest defoliation – limitation of MODIS data in Fennoscandian forest landscapes. **Silva Fennica**, v. 50, n. 2, p. 1-22. 2016.

PAUSE, M.; SCHWEITZER, C.; ROSENTHAL, M.; KEUCK, V.; BUMBERGER, J.; DIETRICH, P. HEURICH, M.; JUNG, A.; LAUSCH, A. In situ/Remote sensing integration to assess forest health– A review. **Remote Sensing**, v. 8, n. 6, p- 471, 2016.

PEARSON, K. On the criterion that a given system of deviations from the probable in the case of a correlated system of variables is such that it can be reasonably supposed to have arisen from random sampling. **Philosophical Magazine**, v. 5, n. 50, p. 157-175, 1900.

QI, J.; CHEHBOUNI, A.; HUETE, A. R.; KERR, Y. H.; SOROOSHIAN, S. A modified soil adjusted vegetation index. **Remote Sensing of Environment**, v. 48, n. 2, p. 119– 126, 1994.

R CORE TEAM. R: **A language and environment for statistical computing**. R Foundation for Statistical Computing, Vienna, Austria. Disponível em: <<https://www.Rproject.org/>> Acesso em: 22 abr 2018.

RABINOWITCH, E.; GOVINDJEE, X. Photosynthesis. Wiley and Sons Inc., New York, USA, pp.273. 1969. Disponível em: <<http://www.cabdirect.org/cabdirect/abstract/19700703082>>. Acesso em: 05 set 2018.

ROCHA, V. J. Macaco-Prego, como controlar essa nova praga florestal? **Floresta**, Curitiba, v. 30, n. 1/2, p. 95-99, 2000.

ROUSE, J.W.; HAAS, R.H.; SCHELL, J.A. Monitoring the Vernal Advancement of Retrogradation (Green Wave Effect) of Natural Vegetation, Remote Sensing Center, Texas A&M University College Station, USA, 1974.

RULLAN-SILVA, C.D.; OLTHOFF, A.E.; DELGADO DE LA MATA, J.A.; PAJARES-ALONSO, J.A. Remote monitoring of forest insect defoliation. A review. **Forest Systems**, v. 22, n. 3, p. 377, 2013.

RUMPF, T.; MAHLEIN, A-K.; STEINER, U.; OERKE, E-C.; DEHNE, H-W.; PLUMER, L. Early detection and classification of plant diseases with Support Vector Machines based on hyperspectral reflectance. **Computers and Electronics in Agriculture**, v. 74, p. 91-99, 2010.
SANGÜESA-BARREDA, G.; CAMARERO, J.J.; GARCÍA-MARTÍN, A.; HERNÁNDEZ, R.; DE LA RIVA, J. Remote-sensing and tree-ring based characterization of forest defoliation and growth loss due to the Mediterranean pine processionary moth. **Forest Ecology and Management**, v. 320, p. 171–181, 2014.

SCHNEIDER, P. R.; SCHNEIDER, P. S. P.; SOUZA, C. A. M. **Análise de regressão aplicada à Engenharia Florestal**. 2. ed. Santa Maria: Facos, 2009.

STONE, C.; COOPS, N.C. Assessment and monitoring of damage from insects in Australian eucalypt forests and commercial plantations. **Australian Journal of Entomology**, v. 43, p. 283–292, 2004.

TEMESGEN, H.; ZHANG, C.; ZHAO, X. Modelling tree height-diameter relationships in multi-species and multi-layered forests: A large observational study from Northeast China. **Forest Ecology and Management**, v. 316, p. 76-89, 2014.

TOWNSEND, P.A., SINGH, A., FOSTER, J.R., REHBERG, N.J., KINGDON, C.C., ESHLEMAN, K.N., SEAGLE, S.W. A general Landsat model to predict canopy defoliation in broadleaf deciduous forests. **Remote Sensing of Environment**, v. 119, p. 255–265, 2012.

TRUMBORE, S.; BRANDO, P.; HARTMANN, H. Forest health and global change. **Science**, v. 349, n. 6250, p. 814-818, 2015.

XIE, Q.; DASH, J.; HUANG, W.; PENG, D.; QIN, Q.; MORTIMER, H.; CASA, R.; PIGNATTI, S.; LANEVE, G.; PASCUCCI, S.; DONG, Y.; HUICHUN, Y. Vegetation indices combining the red and red-edge spectral information for leaf area index retrieval. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 5, n. 11, p. 1482-1493, 2018.

WALTER, J.A.; PLATT, R.V. 2013. Multi-temporal analysis reveals that predictors of mountain pine beetle infestation change during outbreak cycles. **Forest Ecology and Management**, v. 302, p. 308–318, 2013. doi.org/10.1016/j.foreco.2013.03.038

WANG, J.; SAMMIS, T.W.; GUTSCHICK, V.P.; GEBREMICHAEL, M.; DENNIS, S.O.; HARRISON, R.E. Review of Satellite Remote Sensing Use in Forest Health Studies. *The Open Geography Journal*, v. 3, p. 28-42, 2010.

ZARCO-TEJADA, P.L.; HORNERO, A.; HERNÁNDEZ-CLEMENTE, R.; BECK, P.S.A. Understanding the temporal dimension of the red-edge spectral region for forest decline detection using high-resolution hyperspectral and Sentinel-2A imagery. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 137, p. 134-148, 2018.

5 CAPÍTULO II:

USO DE VEÍCULOS AÉREOS NÃO TRIPULADOS (VANT) NA CLASSIFICAÇÃO DE ÁRVORES ATACADAS POR *Sapajus nigritus* Kerr (1972) EM UM POVOAMENTO DE *Pinus taeda* L.

RESUMO

Esse estudo objetivou avaliar o potencial das imagens digitais obtidas de um VANT para a classificação de árvores atacadas por macaco-prego em um plantio de *Pinus taeda* L. localizado em Santa Catarina – SC. As imagens aéreas foram adquiridas em 03/2018, utilizando um VANT modelo DJI *Phanton* Pro 4, totalizando 17,73 hectares sobrevoados. De posse das imagens, o processamento foi realizado no aplicativo computacional *Agisof PhotoScan Professional*, gerando os ortomosaicos, nos quais foram derivados índices de vegetação e composições de bandas. Utilizando-se de fotointerpretação com base na coloração da copa, foi realizada a contagem manual das árvores classificando-as em não atacadas, mortas e atacadas. As amostras foram coletadas e divididas em 75% de treinamento e 25% validação, considerando três diâmetros de copa: 0,5 m, 1 m e 1,5 m. Foram testados três algoritmos de classificação orientada a região, sendo eles: *Maximum Likelihood Classification*, *Random Tree* e *Support Vector Machine* (SVM). A precisão da classificação foi avaliada por exatidão global e índice kappa. Foram detectadas manualmente 3773 árvores, sendo 1478 atacadas, 197 mortas e 2098 não atacadas. Os resultados também indicaram que para a classificação da sanidade, o melhor diâmetro de copa foi o de 0,5 metros, melhor algoritmo classificador o SVM e maior acurácia na composição do índice ExG associado ao ortomosaico original, com exatidão global de 0,8859 e 0,8347 e índice kappa de 0,8306 e 0,9105. Dessa forma, pode-se concluir que a metodologia testada se mostrou viável na detecção e classificação de árvores acometidas por *S. nigritus* em um povoamento de *Pinus taeda* L.

Palavras-chave: Imagens aéreas, fotogrametria, sanidade florestal.

ABSTRACT

The objective of this study was to evaluate the potential of digital images obtained from a UAV for the classification of trees attacked by capuchin monkeys in a plantation of *Pinus taeda* L. located in Santa Catarina - SC. The aerial images were acquired on 03/2018, using a UAV Model DJI *Phanton* Pro 4, totaling 17.73 hectares overhead. The images were processed using the *Agisof Photo Scan Professional* computer software, generating the orthomosaic species, in which vegetation indices and band compositions were derived. Using a photointerpretation based on the color of the crown, the manual counting of the trees was classified as non-attacked, killed and attacked. The samples were collected and divided into 75% training and 25% validation, considering three crown diameters: 0.5 m, 1 m and 1.5 m. Three region-oriented classification algorithms were tested: *Maximum Likelihood Classification*, *Random Tree*, and *Support Vector Machine* (SVM). The accuracy of the classification was assessed by global accuracy and kappa index. Manually detected 3773 trees, of which 1478 were attacked, 197 died and 2098 were not attacked. The results also indicated that for the classification of sanity, the best diameter was 0.5 meters and the best classifier algorithm was the SVM, and the highest accuracy was represented by the composition of the ExG index associated to the original orthomosaic, with global accuracy of 0.8859 and 0.8347 and kappa index of 0.8306 and 0.9105. Thus, it can be concluded that the

methodology tested proved to be feasible in the detection and classification of trees attacked by *S. nigritus* in a stand of *Pinus taeda* L.

Keywords: Aerial imagery, photogrammetry, forest health.

5.1 INTRODUÇÃO

Os macacos-prego (*Sapajus nigritus* Kerr, 1972) são primatas florestais que ocupam desde o estado de Minas Gerais até o norte do Rio Grande do Sul (LYNCH ALFARO et al., 2012), com distribuição geográfica restrita à Mata Atlântica (VILANOVA et al., 2005). Essa espécie apresenta grande potencial de adaptação de diferentes lugares, como locais fragmentados e/ou alterados, podendo viver em áreas de vegetação nativa e povoamentos florestais dos gêneros *Pinus* spp. e *Eucalyptus* spp. (LIEBSCH; MIKICH, 2013).

Por ter alimentação onívora, durante períodos de escassez de alimentos em épocas de baixa frutificação devido a exploração da Mata Atlântica (LIEBSCH et al., 2008), um novo alimento foi incorporado a dieta do macaco-prego: a seiva de *Pinus* spp. (ROCHA, 2000). Para ter acesso a esse alimento, o macaco-prego retira a casca da árvore, resultando em dois tipos de danos: janelamento (descascamento parcial do tronco) e anelamento (descascamento total do tronco). Indiferente do tipo de dano, ocorre a interrupção da condução do floema, podendo resultar no secamento da parte superior da copa, no ataque de agentes patogênicos e na morte do indivíduo arbóreo (KOHLENER; FIRKOSKI, 1996; ROCHA, 2000; MIKICH, LIEBSCH, 2009; MIKICH; LIEBSCH, 2014; LIEBSCH et al., 2015)

Dessa maneira, é importante atuar na vigilância da sanidade desses povoamentos florestais atacados por macaco-prego. Para tanto, podem ser utilizadas tecnologias de Sensoriamento Remoto (SR) no mapeamento e monitoramento da sanidade florestal (BULMAN et al., 2016; TORRESAN et al., 2017), como comprovam as pesquisas desenvolvidas por Näsi et al. (2015) e Moriya et al. (2017). Com dados de reflectância espectral obtidos para locais com vegetação, é possível adquirir informações sobre presença ou ausência de certas espécies de árvores, estágios de crescimento de plantas e doenças de plantas (ISHIDA et al., 2018).

A utilização do SR e de imagens aéreas obtidas por *Unmanned Aerial Vehicle* (UAV), ou Veículos Aéreos Não Tripulados (VANT) vêm se destacando e evoluindo para aplicações de agricultura de precisão, incluindo a detecção da sanidade de árvores (ISHIDA et al., 2018). A plataforma de aquisição de dados VANT pode ser conceituada como um sistema composto por um segmento terrestre que realiza o controle remoto do voo e por um segmento aéreo formado pelo VANT com sensores remotos para a captura das fotos de alta resolução espacial do terreno

(BHARDWAJ et al., 2016), permitindo a coleta de dados em intervalos curtos e de forma econômica (DASH et al., 2017). Além disso, possuem resolução temporal superior as plataformas aéreas tripuladas e satélites artificiais e grande facilidade de uso (CANDIAGO et al., 2015), sendo uma tecnologia promissora, acessível e com grande praticidade (ZANETTI et al., 2017).

Pesquisas envolvendo VANT para monitoramento da sanidade florestal ainda são escassas na literatura (NASI et al., 2015). O primeiro estudo com essa abordagem foi realizado na Alemanha, utilizando imagens multiespectrais e análise de imagem baseada em objetos para detectar uma infestação em povoamentos de carvalho (*Quercus* sp.) causada pelo besouro esplendor de carvalho (*Agrilus biguttatus* Fab.). Já na área agrícola, o VANT já foi utilizado para avaliar a saúde de pomares de oliveiras (CALDERÓN et al., 2013) e árvores cítricas (GARCIA-RUIZ et al., 2013). Na área florestal, seu uso ainda é recente, contudo, pesquisas vem sendo desenvolvidas com essa plataforma para avaliar o nível de mato competição e presença e/ou ausência de doenças e pragas em plantios florestais.

Os classificadores por região agrupam “*pixels*” vizinhos com características similares e depois classificam estes agrupamentos (regiões) levando em consideração os atributos espectrais da região e os parâmetros espaciais que podem ser derivados da distribuição espacial dos “*pixels*” que formam a região. Estes classificadores procuram simular o comportamento de um fotointérprete, ao reconhecer áreas homogêneas de imagens, baseados nas propriedades espectrais e espaciais de imagens. A informação de borda é utilizada inicialmente para separar as regiões e as propriedades espaciais e espectrais que irão unir áreas com mesma textura (JENSEN, 2000). Dessa forma, utilizar classificação orientada a regiões nesse estudo envolveu a classificação de árvores não atacadas, atacadas e mortas por *Sapajus nigritus*.

Nesse sentido, o monitoramento de um povoamento florestal acometido por uma praga ou população-problema como o *S. nigritus* pode contribuir para as operações de manejo florestal. Dessa forma, um sistema de avaliação constante de árvores utilizando VANT atua na identificação dos sintomas (iniciais e tardios) bem como na fiscalização do progresso do ataque e da mortalidade das árvores atacadas.

Esse estudo objetivou gerar novas informações sobre a aplicabilidade de VANT para a classificação de árvores individuais não atacadas e atacadas por *S. nigritus* em um povoamento de *Pinus taeda* L. localizado em Bocaina do Sul, Estado de Santa Catarina, afim de apoiar a tomada de decisão em relação ao manejo florestal dessa área.

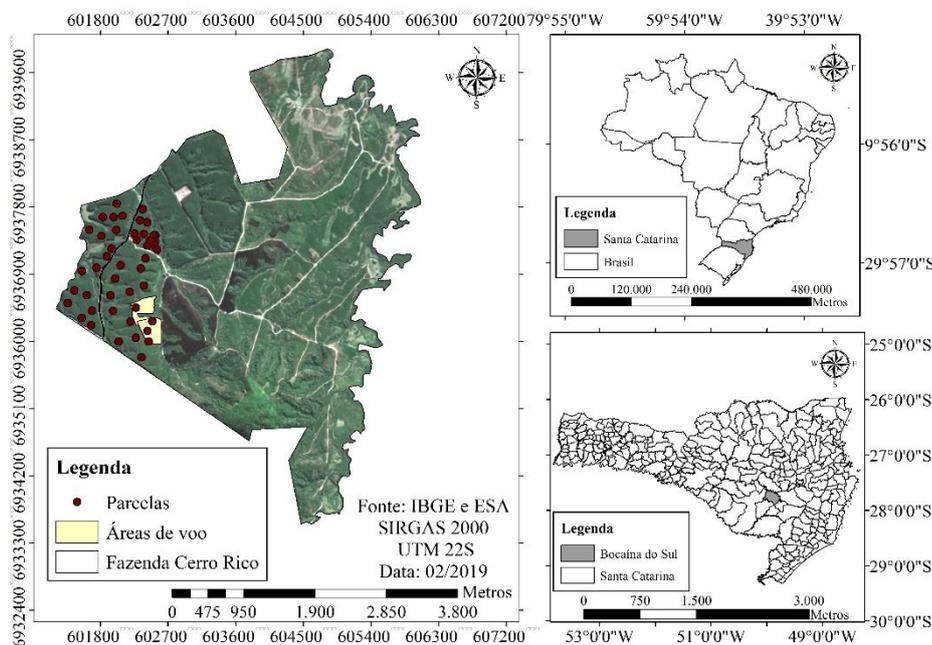
5.2 MATERIAL E MÉTODOS

5.2.1 Descrição da área

A pesquisa foi conduzida na fazenda Cerro Rico localizada no município de Bocaina do Sul (Figura 5:1), no estado de Santa Catarina, com coordenadas médias UTM, referidas ao SIRGAS 2000, E: 602272 m e N: 6936448 m. A área total da fazenda é de 1535,57 hectares e segundo Alvares et al. (2013), o clima do local é do tipo Cfb (clima mesotérmico subtropical úmido), pela classificação de Köppen. A temperatura média é de 16,5° C, umidade relativa do ar de 79,3% e precipitação bem distribuída ao longo do ano, com média anual de 1500 mm.

O povoamento florestal em estudo foi plantado nos anos de 2002 e 2003, com plantios de *Pinus taeda* L. Além das áreas plantadas, também existem áreas com floresta natural. A área efetiva de plantio de *Pinus taeda* L. compreende 236,210 hectares, com espaçamento de 3 metros x 2,5 metros. Não houve intervenção silvicultural com desbaste nos plantios. O sistema de colheita utilizado foi o *full tree*.

Figura 5: 1 - Localização da área florestal em Bocaina do Sul – SC.



Fonte: Elaborado pela Autora (2018).

5.2.2 Recobrimento aéreo

A aquisição das imagens aéreas foi realizada em março de 2018, utilizando um VANT do tipo quadricóptero, modelo DJI *Phantom Pro 4*, equipado com um sensor multiespectral do tipo 1 " CMOS (*Complementary Metal-Oxide Semiconductor*) com as características de 20 megapixels de resolução espacial (com pixel de 5 micrômetros) e distância focal de 8,8 mm. O VANT foi operado por controle remoto e pelo aplicativo *Drone Deploy*. O sistema de navegação foi do tipo GPS (*Global Positioning System*), favorecendo a coleta de imagens georreferenciadas. Além disso, as fotografias foram capturadas na faixa do visível: azul (0,40 – 0,58 nm), verde (0,50 – 0,65 nm) e vermelho (0,59 – 0,68 nm).

Em função do tamanho da fazenda (1535,57 hectares) o planejamento de voo foi elaborado para duas áreas: a primeira com 9,23 hectares e a segunda com 8,50 hectares, totalizando 17,73 hectares sobrevoados. Essas áreas foram definidas por uma avaliação prévia que revelou a existência de ataque.

O planejamento de voo foi idêntico para as duas áreas e considerou os seguintes parâmetros: altitude do voo, velocidade, tempo de voo, linhas de voo, percurso, captura das fotos e sobreposição lateral e frontal das imagens.

A altitude de voo foi determinada em função das condições topográficas da área e da resolução da câmera, pois esse parâmetro interfere na quantidade de imagens geradas e no tamanho do pixel sobre o terreno (JORGE; INAMASU, 2014). Como o local não apresentava muitas variações no relevo e para evitar possíveis obstáculos, a altitude foi de 120 metros.

Os voos foram realizados no período vespertino, entre 14 e 15h e cada voo teve duração aproximada de 10 minutos. A velocidade do voo foi determinada em função das condições climáticas (exposição à luminosidade e condições climáticas adversas) sendo de 7 metros/segundo. O voo seguiu uma rota retilínea, dependendo da conformação da superfície, de acordo com a orientação de Redweik (2007).

Para obter maior acurácia nas fotografias, o grau de sobreposição mínimo lateral foi de 80% e o grau de sobreposição mínimo frontal foi de 85%. Os parâmetros utilizados estão em concordância com a pesquisa de Mancini et al. (2013), a qual sugere 90% e o grau de sobreposição mínimo frontal foi de 60%.

5.2.3 Processamento fotogramétrico

De posse das imagens, o processamento foi realizado no aplicativo computacional *Agisoft PhotoScan Professional* (Agisoft LLC, St. Petersburg, Rússia), no qual realizou-se as correções relacionadas a orientação interior e exterior, obtenção das ortofotos e do ortomosaico.

Durante o processo de captura das imagens aéreas, alguns fatores resultam em distorções, ocasionadas por alterações espaciais (translação, escala e rotação) e por alterações radiométricas (brilho e cor), devido a variações de altitude e orientação do avião. Por tais motivos, as imagens devem ser retificadas e processadas, para assegurar maior acurácia nos produtos obtidos.

Foram realizadas cinco etapas no processamento das fotografias, em concordância com o estudo de Silva et al. (2015): calibração automática da câmera; alinhamento das fotos; geração da nuvem de pontos; filtragem e classificação da nuvem de pontos, geração das ortoimagens e do ortomosaico. No primeiro procedimento, a câmera foi calibrada de forma automática pelo aplicativo, estimando os parâmetros de orientação interior e exterior da câmera. Para isso, os dados necessários envolvem a resolução da imagem, distância focal e Centro Perspectivo (CP) da imagem (SILVA et al., 2014). A correta determinação da orientação interior e exterior possibilita a retificação dos erros sistemáticos das medidas no espaço imagem (CAMPOS et al., 2015). Segundo Marcato Junior (2011), define-se a orientação das fotografias de acordo com o sistema de coordenadas desejado no processo de orientação exterior.

O alinhamento das imagens baseou-se nas igualdades percebidas nas imagens sobrepostas. O posicionamento deve ser conciliado com pontos de apoio em solo (SILVA et al., 2015). A distribuição uniforme dos pontos de controle na região, utilizados no processamento das fotos, permite a geração de ortofotos com melhor qualidade posicional (ZANETTI et al., 2017). Entretanto, não foram utilizados pontos de apoio nesse estudo, apenas as coordenadas do GPS no sistema eletrônico acoplado no VANT. Isso ocorreu em função da condição da cobertura vegetal, que dificultava a sinalização dos pontos de controle. Em seguida, a nuvem de pontos foi processada, representando a área por coordenadas tridimensionais em um DSM (*Digital Surface Model*) - Modelo Digital de Superfície (MDS).

Com a união das imagens retificadas, o ortomosaico foi construído. Durante esse processo, as imagens foram ajustadas geometricamente gerando uma nova distorção, que deve ser corrigida (BROWN; LOWE, 2007). Por fim, obteve-se o GSD (*Ground Sample Distance*), também denominado elemento de resolução ou tamanho do pixel, sendo que para o ortomosaico da área 1 esse valor foi de 2,4 cm e para a área 2 de 2,76 cm.

5.2.4 Índices de vegetação (IV)

De posse dos ortomosaicos das áreas, foram calculados índices de vegetação (Tabela 5:1) com base no espectro visível. Além disso, foram utilizados níveis de cinza e não valores de reflectância. Esse processo foi realizado para minimizar as influências de elementos como topografia, ângulo de visada, ângulo solar e a consistência radiométrica entre as rotas de voo (JENSEN, 2007).

Tabela 5: 1 - Índices de Vegetação derivados para um povoamento de *Pinus taeda* L. atacado por *S. nigritus* localizado em Bocaina do Sul – Santa Catarina.

IV	Abreviatura	Equação	Referência
Blue-Green Pigment Index	BGI	$B3/B2$	Zarco-Tejada et al. (2005)
Excess green	Ex G	$2 * B2 - B1 - B3$	Woebbecke et al. (1995)
Green Leaf Index	GLI	$(2 * B3 - B1 - B2) -$ $(2 * B3 + B1 + B2)$	Louhaichi et al. (2001)
Red-green index	RGI	$B1/B2$	Coops et al. (2006)
Triangular Greenness Index	TGI	$- 0,5 * [(B1 - B3)*(B1 - B2) - (B1 - B3) * (B1 - B2)]$	Hunt et al. (2011)

Em que: IV: índice de vegetação; B1: vermelho (0,59 – 0,68 nm), B2: verde (0,50 – 0,65 nm) e B3: azul (0,40 – 0,58 nm).

Para realçar o comportamento espectral das árvores atacadas, selecionaram-se composições de bandas para as três áreas utilizando as bandas vermelha e azul do ortomosaico e os índices de vegetação, que substituíram a banda verde. Assim, as composições foram as seguintes: 1: R-BGI-B; 2: R-ExG-B; 3: R-RGI-B; 4: R-RGI-B e 5: R-TGI-B. Além das composições, também foram utilizados os ortomosaicos no seu formato original.

5.2.5 Detecção manual das árvores individuais

A identificação das árvores não atacadas e das atacadas por *Sapajus nigritus* foi baseada na fotointerpretação da coloração da copa das árvores, estabelecendo-se três classes qualitativas de dano por árvore, sendo elas: copa verde (árvore sem presença de danos); copa amarelada/avermelhada (árvore com ataque recente ou tardio); copa cinza (árvore morta). Com isso, realizou-se a contagem manual das árvores atacadas, não atacadas e mortas para as duas áreas

sobrevoadas. Para essa etapa, também foram consideradas informações de campo, obtidas no capítulo anterior.

5.2.6 Classificação orientada a objeto das árvores

Para a classificação realizada (orientada a regiões), o primeiro procedimento envolveu o agrupamento dos pixels em áreas significativas. A etapa da segmentação e a geração da topologia foram definidas de acordo com a resolução e a escala dos objetos esperados, favorecendo a extração dos *pixels* únicos e homogêneos.

A segmentação foi executada na ferramenta *Segment Mean Shift* em ambiente GIS (ESRI, 2018). Os parâmetros considerados foram os atributos espectrais, espaciais e o tamanho mínimo do segmento em pixels. O primeiro refere-se ao nível de importância dado as características espectrais diversas dos alvos na imagem. Os valores variam de 1 a 20. Contudo, valores altos são utilizados quando os objetos têm propriedades espectrais similares, mas devem ser classificados separadamente. Já valores menores indicam que os objetos não necessitam de uma classificação tão robusta. O valor utilizado foi de 15,5.

O segundo parâmetro indica o nível de importância atribuído à proximidade entre os objetos. Os valores são expressos de 1 a 20, sendo que valores altos são recomendados em imagens nos quais os objetos são pequenos e agrupados. Valores menores são utilizados para obter objetos da mesma classe, que exijam um nível de detalhe espacial menor. O valor utilizado foi de 15. Já o último parâmetro é o método que atua na junção de segmentos menores que o tamanho definido com o segmento vizinho de melhor ajuste. Foi considerado um tamanho mínimo do segmento de 20. O produto final da segmentação foram imagens segmentadas em RGB com resolução espectral 8 bits.

5.2.7 Geração das amostras

Para a determinação das amostras de treinamento e validação, utilizou-se a contagem manual das árvores para cada área analisada. Em função do espaçamento do povoamento e da proximidade das copas das árvores, foram gerados três tamanhos de *buffers* de 0,5 m, 1 m e 1,5 m para as árvores atacadas, não atacadas e mortas. Esses valores foram considerados para obter diferentes níveis de abrangência das copas das árvores e para verificar se essa variação no tamanho dos *buffers* poderia contribuir para a separabilidade das árvores de acordo com sua condição fitossanitária.

De posse desses dados, as amostras foram divididas em 75% para treinamento e 25% para validação (JENSEN, 2007; PEREIRA; CENTENO, 2017). Para essa separação, utilizou-se as ferramentas *Select by Feature* e *Erase*, ambas presentes em ambiente GIS (ESRI, 2018).

5.2.8 Métodos testados

O treinamento dos algoritmos de classificação envolveu a especificação dos indicadores a serem acrescentados na tabela de atributos da imagem segmentada, sendo eles: cor (cor da cromaticidade média por segmento); média (número digital médio por segmento); desvio padrão (desvio padrão por segmento); contagem (número de pixels que compõem o segmento) e formato (grau em que o segmento é compacto ou circular, variando de 0 a 1, em que 1 é um círculo);

Após o algoritmo ser treinado e o arquivo em formato ECD (*Esri Classifier Definition*) gerado, as imagens foram classificadas pelos métodos descritos a seguir.

5.2.8.1 *Maximum Likelihood Classification* – Maxver

Esse método de classificação paramétrica é muito conhecido e utilizado. Seu funcionamento baseia-se no princípio de que a classificação errônea de um pixel não influencia na classificação errônea de outro pixel na imagem (RICHARDS, 1993). Esse método leva em consideração a ponderação das distâncias médias por meio de parâmetros estatísticos de distribuição dos pixels em uma classe. O resultado adequado diz respeito ao número razoavelmente elevado de regiões para cada amostra de treinamento além da distribuição estatística próxima da distribuição normal dos mesmos. A quantidade de regiões incluídas nas amostras de treinamento também influencia na eficácia do produto gerado em função da precisão razoável da estimativa do vetor médio e da matriz de covariância de toda a classe espectral (CRÓSTA, 1993).

5.2.8.2 *Random Tree* - RT

O algoritmo conhecido como árvores aleatórias é um classificador de árvore de decisão não paramétrico que não requer nenhuma suposição estatística a priori sobre a distribuição de dados (OUTKEI; BLASCHKE, 2010). Quinlan (1993) demonstra o processo de construção de uma árvore de decisão. Entretanto, a estrutura básica é formada por um nó raiz, um número de nós internos e um conjunto de nós terminais. A divisão dos dados ocorre de forma recursiva pela árvore de decisão e pela estrutura de classificação definida. Dessa maneira, em cada nó existe uma regra

de decisão, implantando pelo teste de divisão com frequência do formulário para árvores de decisão univariadas (OUTKEI; BLASCHKE, 2010). Alguns fatores são decisivos para assegurar o desempenho desse método, como métodos de incentivo utilizados e limiares de decisão, de acordo com Mahesh e Mather (2003).

5.2.8.3 *Support Vector Machine - SVM*

A teoria do classificador SVM não paramétrico foi apresentada por Vapnik e Chervonenkis (1971) e posteriormente estudada por Vapnik (1999). O sucesso desse método depende do treinamento adequado do processo. Para isso, classes linearmente separáveis são indicadas. Assim, dados de treinamento com um número de amostras e um rótulo de classe são linearmente separáveis se existir um hiperplano, o qual determina a direção do plano discriminante e um vetor escalar que relaciona o deslocamento do hiperplano discriminador da origem (OSUNA et al., 1997).

Dessa forma, os dois hiperplanos são considerados e além de maximizar a distância entre as classes, também acrescenta pontos entre elas. De maneira geral, o SVM irá avaliar em que classe tais pontos novos de dados serão incluídos. O desempenho superior do SVM em relação aos outros classificadores já foi apontado, contudo, o resultado adequado está diretamente relacionado com o kernel usado, escolha de parâmetros para o kernel escolhido e o método usado para obter o SVM (HUANG et al., 2002).

5.2.9 **Acurácia da classificação**

A assertividade da classificação pelos algoritmos testados foi verificada pela matriz de confusão e pelos valores dos indicadores exatidão global e índice kappa. A exatidão global refere-se ao número total de amostras classificadas corretamente (ou seja, soma de positivos verdadeiros para todas as classes) dividido pelo número total de amostras. Já o índice Kappa avalia o acordo de previsão com a classe verdadeira. É uma métrica que compara uma precisão observada com uma precisão esperada (ou seja, leva em conta a chance aleatória de classificar corretamente) (NEVALAINEN et al., 2017).

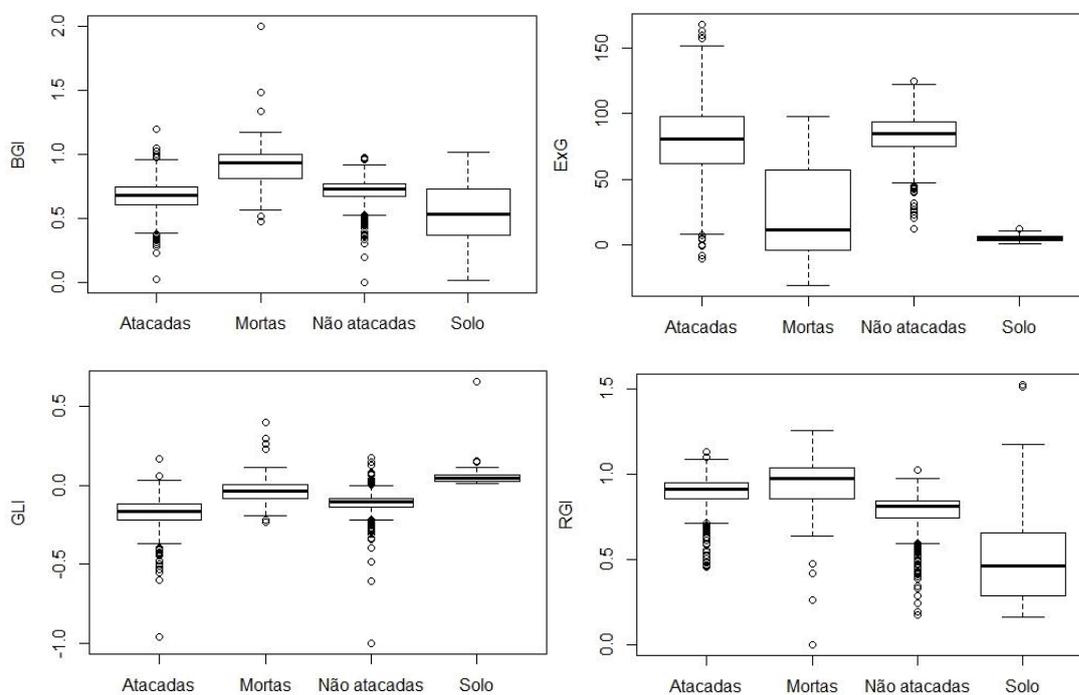
É importante ressaltar que para a geração da matriz de confusão, foram coletados 300 pontos aleatoriamente dentro de cada classe a partir do pressuposto de que cada classe continha um número de pontos proporcional à sua área relativa. A matriz de confusão foi computada em

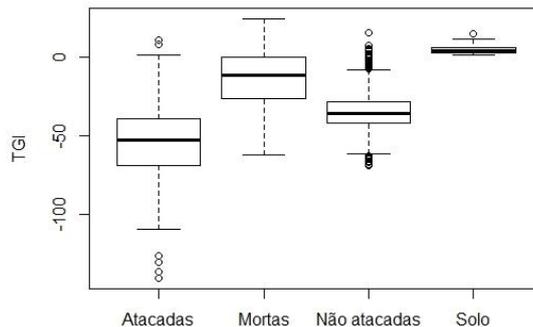
ambiente GIS, a partir das ferramentas *Create Accuracy Assessment Points* e *Update Accuracy Assessment Points* (ESRI, 2018).

5.3 RESULTADOS

A partir dos IV calculados, notou-se que houve diferenças nos níveis de cinza para as árvores atacadas, não atacadas e mortas em cada área analisada. De maneira geral, para a primeira área (Figura 5:2), a escala de valores de cada índice variou, sendo que o ExG apresentou os maiores valores para todas as classes e os menores valores foram representados pelo TGI. Assim, para a primeira área, o índice que separou melhor as classes foi o ExG. Ao comparar as árvores atacadas e não atacadas, percebe-se que o ataque causou diminuição na reflectância, diminuindo os valores dos IV. Para as árvores mortas, houve uma dispersão em função dos valores altos, assim como as não atacadas. Isso pode estar associado a confusão espectral entre classes, causando classificação incorreta de árvores nessa condição. O solo foi caracterizado por valores baixos em todos os IV.

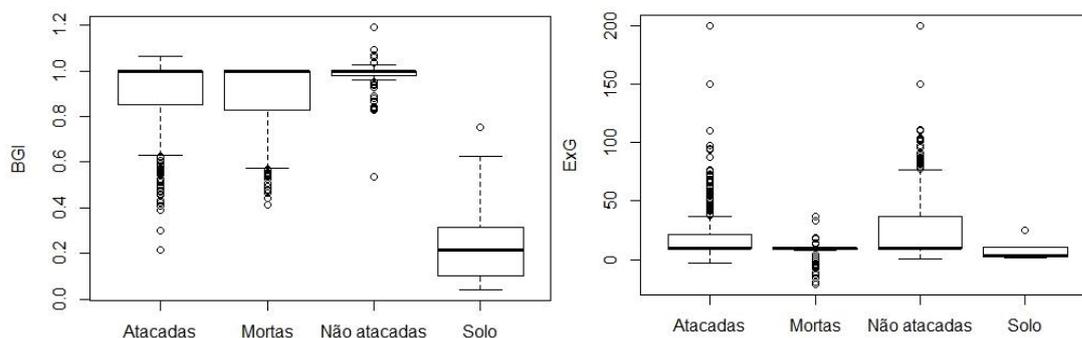
Figura 5: 2 - Comportamento dos IV calculados com as classes de treinamento com o ortomosaico da Área 1.

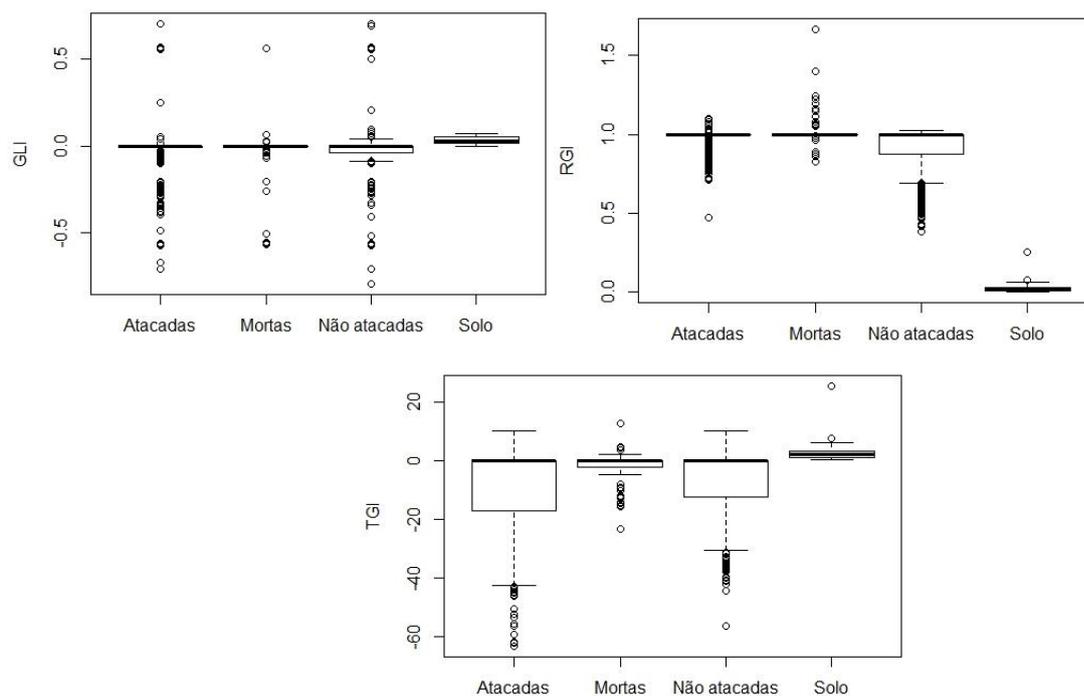




Para a segunda área analisada (Figura 5:3), os IV revelaram comportamentos diferentes de acordo com as classes de treinamento. Para o BGI, as árvores mortas e que não apresentaram nenhum tipo de ataque foram ligeiramente superiores as atacadas, ao passo que o solo foi caracterizado pelos menores valores. Para o ExG, as árvores não atacadas foram representadas pelos valores superiores as demais. Esse índice apresentou a melhor diferenciação entre as classes. No GLI, todas as classes apresentaram valores semelhantes, sendo que os maiores valores foram observados na classe solo. O índice RGI destacou o desempenho semelhante de árvores atacadas e mortas e a discrepância entre os altos valores das árvores sem ataque e os baixos valores de solo. Por fim, no TGI as árvores com algum tipo de ataque foram menores que as demais classes. Árvores mortas e solo apresentaram valores semelhantes enquanto que as árvores não atacadas expressaram os maiores valores.

Figura 5: 3 - Comportamento dos IV calculados com as classes de treinamento com o ortomosaico da Área 2.



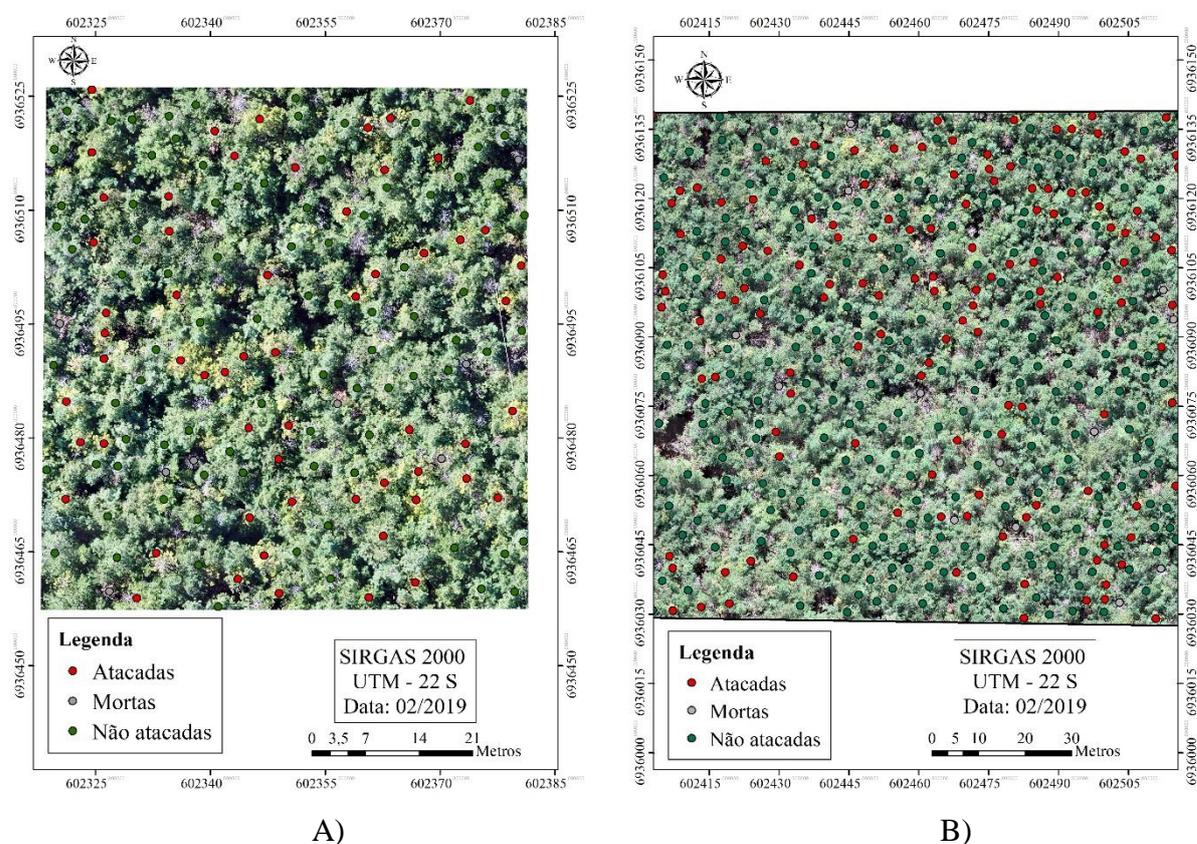


A detecção manual das árvores (Tabela 5:2 e Figura 5:4) diferiu para cada área analisada, revelando que o maior percentual de árvores atacadas foi identificado na primeira área avaliada ao passo que o maior número de árvores não atacadas foi encontrado segunda área. A diferença no número de árvores atacadas e não atacadas para as duas áreas analisadas contribuiu para os diferentes comportamentos dos IV testados para esses locais.

Tabela 5: 2 - Contagem manual das árvores atacadas, não atacadas e mortas de *Pinus taeda* L. em Bocaina do Sul – SC.

Área	Atacadas	%	Mortas	%	Não atacadas	%	Total
1	783	41,50	126	6,67	978	51,83	1887
2	695	36,85	71	3,76	1120	59,39	1886
Total	1478	-	197	-	2098		3773

Figura 5: 4 – Detecção manual das árvores em função de sua sanidade para as áreas analisadas (Área 1 (A) e Área 2 (B)) de um povoamento de *Pinus taeda* L. localizado em Bocaina do Sul – SC.



A partir dos algoritmos de classificação testados, foi possível notar a acurácia de classificação de cada método bem como a superioridade da classificação para as amostras de 0,5 metros e do método SVM para a área 1. As Tabelas 2:3 e 2:4 representam a assertividade da classificação para as áreas 1, 2, respectivamente. A matriz de confusão de cada classificação está ilustrada no Anexo B.

Tabela 5: 3 - Acurácia dos métodos de classificação orientada a região testados para a Área 1, localizada em um povoamento de *Pinus taeda* L. em Bocaina do Sul – SC.

Imagem	Buffer – 0,5m					
	Maxver		Random Tree		SVM	
	Ex. Global	Kappa	Ex. Global	Kappa	Ex. Global	Kappa
Ortomosaico	0,6589	0,5254	0,8763	0,8193	0,8792	0,8215
Composição 1	0,6488	0,5125	0,8328	0,7530	0,8523	0,7817
Composição 2	0,7993	0,7115	0,8328	0,7529	0,8859	0,8306
Composição 3	0,6756	0,5415	0,7559	0,6418	0,8691	0,8070
Composição 4	0,6388	0,4935	0,8161	0,7299	0,8380	0,7630
Composição 5	0,7692	0,6709	0,7559	0,6462	0,8154	0,7288

Buffer – 1m

Imagem	Maxver		Random Tree		SVM	
	Ex. Global	Kappa	Ex. Global	Kappa	Ex. Global	Kappa
Ortomosaico	0,6367	0,4601	0,7793	0,6459	0,7733	0,6291
Composição 1	0,6000	0,4111	0,7467	0,5880	0,7500	0,5990
Composição 2	0,7167	0,5497	0,7633	0,6164	0,7333	0,5678
Composição 3	0,6823	0,5116	0,6600	0,4688	0,7993	0,6744
Composição 4	0,5733	0,3866	0,7867	0,6529	0,7333	0,5733
Composição 5	0,6733	0,5008	0,7167	0,5610	0,7433	0,5929

Buffer – 1,5m						
Imagem	Maxver		Random Tree		SVM	
	Ex. Global	Kappa	Ex. Global	Kappa	Ex. Global	Kappa
Ortomosaico	0,6722	0,5471	0,8762	0,8193	0,8791	0,8214
Composição 1	0,6321	0,4874	0,8127	0,7238	0,8624	0,7962
Composição 2	0,7592	0,6752	0,8461	0,7738	0,8859	0,8306
Composição 3	0,6555	0,6145	0,7625	0,6516	0,6291	0,4113
Composição 4	0,5629	0,3189	0,5993	0,3487	0,6490	0,4332
Composição 5	0,6291	0,4158	0,5960	0,3771	0,5960	0,3848

Em que: Maxver: Máxima verossimilhança; SVM: Support Vector Machine; Ex. Global: exatidão global; Kappa: Índice Kappa.

De acordo com a Tabela 5:4, a classificação obtida com as amostras de 0,5 m apresentou estatísticas superiores (exatidão global e índice kappa) a 80%, sendo que a composição 2 apresentou os maiores valores, com exatidão global de 88% e um índice kappa de 83%. Para as amostras de 1m, os valores foram inferiores e os métodos *Random Tree* e SVM foram superiores ao Maxver. Já para as amostras de 1,5m, as composições 1, 2 e 3 obtiveram dados acima de 80% ao passo que as demais imagens tiveram resultados inferiores a 70%.

Tabela 5: 4 - Acurácia dos métodos de classificação orientada a objeto testados para a Área 2, localizada em um povoamento de *Pinus taeda* L. em Bocaina do Sul – SC.

Imagem	Maxver		Random Tree		SVM	
	Ex. Global	Kappa	Ex. Global	Kappa	Ex. Global	Kappa
Ortomosaico	0,5709	0,3673	0,8811	0,7763	0,9105	0,8347
Composição 1	0,7284	0,5126	0,8529	0,7292	0,8072	0,6545
Composição 2	0,7293	0,5551	0,8613	0,7529	0,7287	0,5668
Composição 3	0,7105	0,5437	0,8721	0,7722	0,8585	0,7426
Composição 4	0,7566	0,5534	0,8178	0,6557	0,8157	0,6715
Composição 5	0,6523	0,4444	0,8548	0,7349	0,7828	0,6347

Buffer – 1m						
Imagem	Maxver		Random Tree		SVM	
	Ex. Global	Kappa	Ex. Global	Kappa	Ex. Global	Kappa
Ortomosaico	0,5709	0,3673	0,8443	0,7148	0,8745	0,7714
Composição 1	0,7284	0,5126	0,7516	0,5759	0,7368	0,5468
Composição 2	0,7293	0,5550	0,8157	0,6622	0,8305	0,6997
Composição 3	0,7105	0,5437	0,8443	0,7158	0,8283	0,6933
Composição 4	0,7566	0,5534	0,7715	0,5933	0,5746	0,3106
Composição 5	0,6523	0,4443	0,7614	0,5942	0,7582	0,5863

Buffer – 1,5m						
Imagem	Maxver		Random Tree		SVM	
	Ex. Global	Kappa	Ex. Global	Kappa	Ex. Global	Kappa
Ortomosaico	0,6862	0,4669	0,7346	0,5016	0,7467	0,5183
Composição 1	0,5825	0,2919	0,6426	0,4038	0,5903	0,3411
Composição 2	0,6375	0,4033	0,7377	0,5326	0,7557	0,5662
Composição 3	0,5501	0,3194	0,6828	0,4628	0,7003	0,4793
Composição 4	0,5552	0,2715	0,6483	0,4093	0,7013	0,4752
Composição 5	0,5260	0,3010	0,6984	0,4715	0,7166	0,5182

Em que: Maxver: Máxima verossimilhança; Ex. Global: exatidão global; Kappa: Índice Kappa.

A análise da Tabela 5:4 permite inferir que a classificação das amostras de 0,5m exibiram estatísticas entre 67 a 91%, sendo que, a classificação para o ortomosaico teve maior acurácia do que a classificação testada com os índices, considerando o método SVM. Para as amostras com *buffer* de 1m, é possível notar a inferioridade do método Maxver e destacar o desempenho do método *Random Tree*, o qual foi significativo nas composições 1, 3, 4 e 5. O método SVM proporcionou a melhor classificação para o ortomosaico e a composição 2. Já as amostras com raio maior (1,5m) tiveram estatísticas abaixo de 75%.

De maneira geral, os resultados das Tabelas 2:3 e 2:4 indicam que para todas as composições testadas, os dados das amostras geradas com os *buffers* de 0,5m forneceram as melhores classificações. Além disso, a classificação de imagens baseada em objetos utilizando o método SVM produziram as maiores precisões gerais no presente estudo, com exatidão global variando de 0,7287 a 0,9105 e 0,5668 a 0,8306 para o índice kappa.

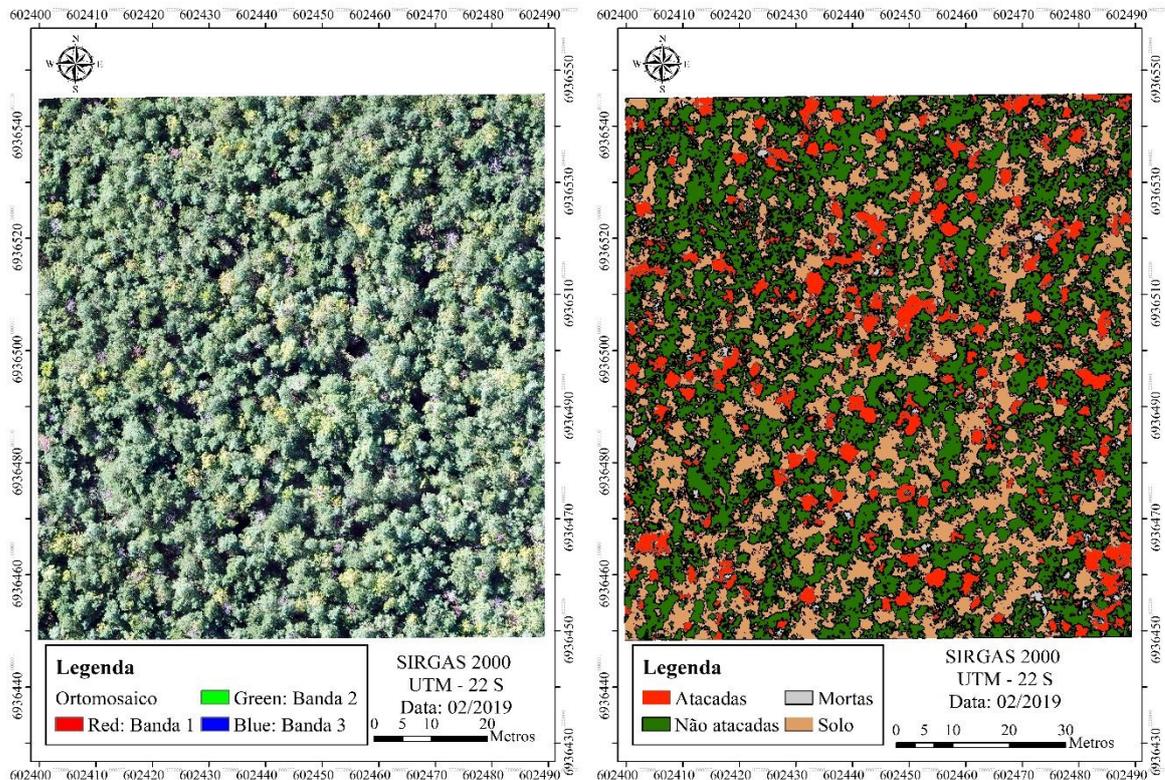
Além disso, a análise dos coeficientes de concordância da matriz de confusão também deve ser entendida. O uso do coeficiente Kappa (K) é satisfatório na avaliação da precisão de uma classificação temática, pelo fato de levar em consideração toda a matriz de confusão no seu cálculo, inclusive os elementos de fora da diagonal principal, os quais representam as discordâncias na

classificação, diferentemente da exatidão global, por exemplo, que utiliza somente os elementos diagonais (concordância real) (CONGALTON, 1991). Assim, pode-se concluir que o índice kappa expressa a assertividade da classificação em concordância geral e a exatidão global para as classes individuais.

O contraste entre as classificações obtidas por Maxver e SVM consiste nas particularidades de cada método, pois no Maxver admite-se uma distribuição normal para cada uma das classes e um vetor de atributos é extraído para o cálculo das probabilidades do *pixel* pertencer a classe de treinamento. Já o SVM consiste em uma técnica de classificação não estatística para o reconhecimento dos padrões das amostras das classes pré-definidas. Com base na montagem de um hiperplano ideal de separação entre classes, diminui-se a distância entre elas. Assim, o algoritmo classificador utiliza uma função para minimizar a expectativa de erro.

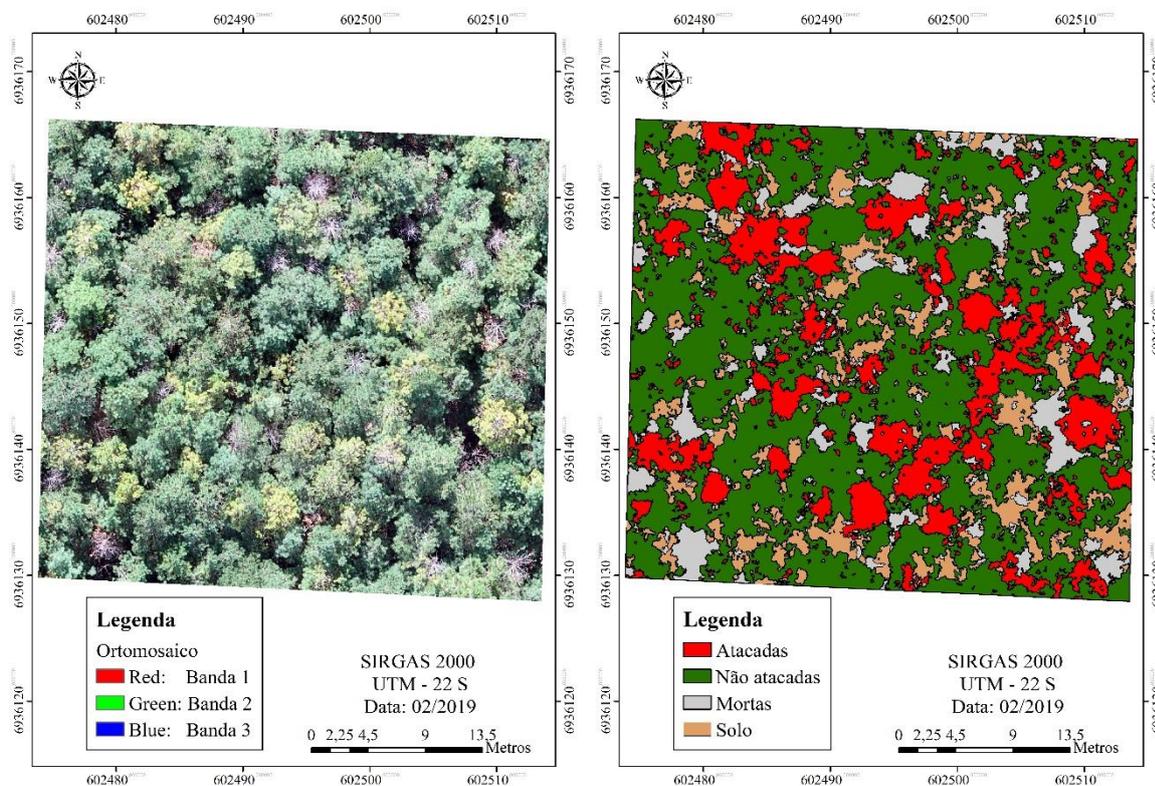
A classificação pelo método SVM para a primeira área revelou que, a melhor distinção das árvores atacadas ocorreu na classificação obtida com a composição com o índice ExG. A composição derivada com o índice GLI proporcionou a identificação das árvores não atacadas enquanto que as árvores mortas foram representadas pela composição com o RGI. Em todas as combinações, houve confusão entre as amostras das árvores não atacadas com as amostras de solo. A melhor representatividade da classe de árvores atacadas, os menores erros de omissão e comissão entre as classes e os valores superiores de acurácia (exatidão global de 0,8859 e kappa de 0,8306) elegeram a composição com o ExG como o melhor método de classificação para primeira área (Figura 5:5).

Figura 5: 5 - Algoritmo SVM para a classificação das árvores não atacadas, mortas e atacadas por macaco prego na área 1 de um povoamento de *Pinus taeda* L. localizado em Bocaina do Sul – SC.



Para a área 2, a classificação derivada do ortomosaico resultou na diferenciação de árvores atacadas e não atacadas com os menores erros de omissão ou comissão, ou seja, a maior parte das árvores foi classificada corretamente nessas duas classes. Já na composição com o BGI, árvores mortas foram identificadas como atacadas e na composição com ExG estas foram confundidas com árvores não atacadas. Nas demais composições, as árvores atacadas foram classificadas erroneamente como não atacadas e a classe solo foi confundida com as demais classes. Em função da precisão da classificação e da melhor representação da condição das árvores atacadas, não atacadas e mortas, a classificação obtida com o ortomosaico foi indicada como a mais adequada (Figura 5:6) para essa área.

Figura 5: 6 - Algoritmo SVM para a classificação das árvores não atacadas, mortas e atacadas por macaco prego na área 2 de um povoamento de *Pinus taeda* L. Localizado em Bocaina do Sul – SC.



Pode-se perceber que, os dados utilizados ofereceram diversas possibilidades de seleção de recursos para a detecção das árvores. A abordagem utilizada compreendeu o uso de OBIA, obtendo os recursos para cada árvore, porém, poderiam ter sido utilizados todos os pixels de cada árvore ou classificação orientada a pixel.

5.4 DISCUSSÃO

A partir dos resultados demonstrados, pode-se dizer que o ataque causado por *Sapajus nigrurus* as árvores de *Pinus taeda* L. interferiu na sanidade das árvores à medida que os sinais de ataque evoluíram. Após o ataque, a alteração na resposta na copa da árvore demora aproximadamente seis meses. Esse tempo correspondeu ao período em que a área foi analisada.

Na fase inicial do ataque, não são identificados sinais visuais de infestação, pois a copa das árvores permanece verde. Contudo, com o passar do tempo, as copas das árvores tornam-se amareladas e/ou avermelhadas. Com a morte dos indivíduos arbóreos atacados, a copa torna-se cinza. Esse comportamento também ocorre em árvores atacadas por besouros, como descrevem

Wulder et al. (2006). A desfolhação de árvores coníferas foi descrita como um processo gradual por Vogelmann et al. (2009).

Em relação aos índices de vegetação derivados para cada área e sua respectiva relação com as classes de treinamento pode ser explicada pela faixa utilizada do espectro eletromagnético, faixa do visível. Sabe-se que as propriedades espectrais da vegetação variam de acordo com o comprimento de onda analisado (MAITI et al., 2015). O comportamento observado nessa faixa é explicado pela absorção da radiação incidente no vermelho e azul e reflexão no verde, sendo que a estrutura interna das folhas saudáveis age como refletor difuso dos comprimentos de onda do vermelho (ASRAR et al., 1985). Dessa forma, a sensibilidade espectral dos índices utilizados ficou restrita a essa faixa espectral, não registrando a reflexão característica na faixa do infravermelho, que por sua vez, tende a variar em árvores atacadas e não atacadas, pela variação nos teores de clorofila ocasionados pelo ataque do patógeno em questão.

O índice RGI contribuiu para a diferenciação das árvores mortas nas composições de bandas utilizando os ortomosaicos. Esse resultado corrobora com a pesquisa de Hart e Veblen (2015), na qual também ocorreu redução na concentração de clorofila com a morte do indivíduo arbóreo, ocorre interrupção na absorção do vermelho e com isso, os valores altos de RGI identificam as árvores mortas. Outro índice com destaque foi o ExG, o qual gerou as composições de bandas com a melhor classificação das árvores na área 1.

A contagem manual das árvores nas condições de mortas, com ataque e sem ataque forneceram informações extremamente relevantes para a área analisada, pois além de fornecer dados em todo o cenário estudado, atuam na tomada de decisão acerca da condição da área, podendo reduzir potencialmente a taxa de crescimento da população problema, limitando a severidade e a extensão dos ataques removendo as árvores atacadas como sugerem Hansen et al. (2010). Dessa forma, nota-se a importância do monitoramento das árvores atacadas, principalmente no estágio inicial, pois tais dados podem atuar no gerenciamento e no estudo do povoamento acometido por *S. nigritus*, afim de adotar estratégias para diminuir o impacto do ataque desse primata.

A análise dos espectros de reflectância para as classes avaliadas relevou que as reflectâncias diferiram de acordo com a faixa espectral analisada, conforme esperado. A causa de tal variação refere-se às propriedades bioquímicas foliares, principalmente aos teores de clorofila afetada pelo estresse ocasionado pelo ataque. Esse comportamento também ocorreu na avaliação do impacto do ataque de *Ips topographus* L. nas características espectrais de reflectância de *Picea abies* L. desenvolvida por Abdullah et al. (2018). A inclusão da faixa do infravermelho nessa

pesquisa destes autores contribuiu para os resultados obtidos, sendo que houve aumento de reflectância na faixa do visível e redução no infravermelho próximo.

Os resultados dos algoritmos de classificação testados indicam que o método adequado para identificar árvores sem ataque, mortas e com ataque de macaco prego nas áreas analisadas foi o SVM e o melhor diâmetro considerado foi de 0,5 metros. Entretanto, recomenda-se testar outros métodos de classificação em imagens de alta resolução espacial, como *Random Forest*, *K-Nearest Neighbor* (KNN).

O método SVM também foi eficiente na combinação de nove IV associados a parâmetros fisiológicos e utilização de SVM para detectar precocemente e classificar doenças de plantas em culturas agrícolas por Rumpf et al. (2010). A detecção da influência do estresse hídrico em plantas de cevada utilizando IV e SVM foi estudada por Behmann et al. (2014), os quais selecionaram uma combinação otimizada de IV com alto poder discriminativo e os usaram como características em seu modelo SVM para distinguir entre plantas saudáveis e estressadas.

A utilização de dados com maior resolução espacial como os derivados por VANT podem fornecer maior acurácia na classificação, como foi investigado por Lausch et al. (2013). Os autores pesquisaram os efeitos da resolução espacial sobre a precisão na classificação de danos causados por besouros da casca com GSDs maiores (4 cm e 7 cm). O menor GSD (4 cm) forneceu melhor precisão de classificação, pois os melhores resultados com resoluções mais altas provavelmente se devem ao menor nível de mistura de espectros de objetos adjacentes.

O desempenho dos algoritmos testados está relacionado com algumas características específicas, como explica-se a seguir. Um fator que pode influenciar nesse processo refere-se ao isolamento de árvores individuais e a distinção de brilho entre as copas das árvores e o solo. Isso depende da resolução espacial da imagem utilizado e do tamanho da copa das árvores. Imagens com altíssima resolução espacial, ou seja, com GSD entre 5 a 15 cm, exigem muitos detalhes das copas, como ramificações e variações existentes, permitindo a divisão das copas. Contudo, quanto menor a resolução espacial, a capacidade de diferenciar a área da copa e o solo também diminui, principalmente para árvores com copas pequenas. Além disso, nessas imagens, a variação do brilho nas copas das árvores maiores ocasiona maiores erros de comissão na classificação e maior tempo de análise e processamento computacional (KE et al., 2011).

Nesse sentido, destaca-se a pesquisa desenvolvida por Pouliot et al. (2002). Os autores identificaram a melhor relação entre a resolução espacial da imagem e o tamanho da copa da árvore de coníferas entre 6 a 10 anos. A proporção indicada entre o diâmetro da coroa e o tamanho do pixel do solo para sua aplicação foi de 15: 1.

A distinção de brilho também foi examinada nas pesquisas de Korpela et al. (2011) e Puttonen et al. (2010). Na primeira pesquisa, os autores usaram quatro diferentes classes de iluminação e usaram mais pixels na classificação para cada árvore ao investigar a classificação de espécies de árvores. No segundo trabalho, a divisão em pixels iluminados pelo sol e sombreados foi utilizada para melhorar a classificação de espécies de árvores com imagens que não foram corrigidas radiometricamente. Esse método melhorou a classificação em comparação com seu método de referência.

Em algumas classificações geradas nesta pesquisa, foi possível perceber a ocorrência de problemas relacionados ao tamanho das copas e tamanho do GSD. Árvores com copas pequenas não foram classificadas e copas de árvores grandes foram classificadas como várias árvores. Tal fato pode ser explicado pela variação no tamanho das copas avaliadas, pelo grau de suavização da imagem utilizada e pelo tamanho do *pixel*.

Os dados das classificações testadas indicam que essa abordagem individual baseada em árvores pode ser treinada em áreas maiores, a partir dos resultados de uma área menor e representativa, como recomendam Nasi et al. (2018). Os referidos autores também recomendam utilizar variações fenológicas das árvores e conferir a calibração dos dados remotamente situados.

A geração de informações individuais de árvores favorece a utilização de dados com maior nível de precisão e eficiência para o monitoramento da sanidade da floresta (HOLOPAINEN et al., 2014). Contudo, se dados de alta resolução espacial ao nível de árvore não estiverem disponíveis, recomenda-se utilizar metodologias para a detecção de áreas atacadas (NASI et al., 2018) bem como o monitoramento multitemporal de uma floresta, pois esses métodos podem indicar novas infestações (SENF et al., 2017). Outras faixas espectrais, como infravermelho próximo e infravermelho de ondas curtas (SWIR) (FOSTER et al., 2016; ABDULLAH et al., 2018) ou térmicas (JUNTTILA et al., 2016), podem fornecer informações adicionais sobre o estado sanitário de um povoamento florestal.

Michez e Lejeune (2016) recomendam selecionar e testar com cuidado as variáveis a serem analisadas na classificação de árvores individuais em imagens digitais, como características espectrais e de textura. Essas propriedades já demonstraram sua importância para garantir a alta precisão na classificação de espécies arbóreas.

Outra limitação observada refere-se as árvores mortas, caracterizadas pela copa cinza. Diversos fatores podem causar a morte de um indivíduo arbóreo e dessa forma, árvores que foram mortas por outras causas, além do ataque de macaco prego, foram incluídas na classificação e incorretamente associadas ao ataque desse primata. Tal fato também ocorreu na pesquisa de Hart e Veblen (2015), ao classificar árvores de *Pinus* spp. atacadas por besouros. Uma alternativa para

solucionar esse impasse envolve a utilização de abordagens de séries temporais, as quais atuam na geração de informações necessárias para a separação de diferentes distúrbios e patógenos em uma área, como sugerem Meigs et al. (2011).

Como já descrito anteriormente, a confusão entre classes pode ser explicada pela utilização de *pixels* homogêneos, pela dificuldade em separar as copas das árvores e pela ocorrência de *pixels* com baixos valores na classe de árvores atacadas. Esse fato também ocorreu na pesquisa de Negron-Juarez et al. (2011), que relataram a subestimação da detecção de mortalidade de árvores em nível de *subpixel* (pequenas lacunas florestais) na Amazônia usando dados do Landsat, com *pixel* de 30 metros. Em níveis mais altos de mortalidade de árvores, a precisão da classificação de data única foi maior. Por outro lado, em níveis mais baixos de mortalidade de árvores, a classificação multi-data detectou mortalidade com maior precisão.

A utilização de imagens derivadas de VANT na classificação digital de espécies florestais arbóreas envolve a compreensão da tecnologia de Sensoriamento Remoto, as propriedades espectrais das características de interesse em relação às características básicas da imagem e a área a ser coberta (planejamento e execução da missão) (FRANKLIN et al., 2018). Além disso, fatores relacionados a plataforma/sensor (por exemplo, capacidade de piloto automático e elevação, questões regulatórias), projeto de missão (geometria e radiometria do sensor) e processamento de dados (ferramentas de armazenamento, sobreposição, transferência/gerenciamento e extração de informações) (WHITEHEAD et al., 2014) também devem ser considerados.

Outras pesquisas foram desenvolvidas visando testar a abordagem individual de árvores em imagens de alta resolução espacial, como pode-se citar Hart e Veblen (2015), Nasi et al. (2015), Nevalainen et al. (2017) e Franklin et al. (2017).

O trabalho desenvolvido por Franklin et al. (2017) classificou uma área de floresta utilizando OBIA e aprendizado de máquina em imagens multiespectrais de VANT. O processo de segmentação OBIA foi usado para gerar objetos de imagem apropriados que correspondiam a coroas de árvores individuais. O classificador de aprendizado de máquina foi eficaz na separação de coroas individuais com variáveis de resposta espectral, textura e formato de coroa. A acurácia da classificação geral foi de aproximadamente 78% com base em uma amostra de treinamento de 86 e uma amostra de validação de 23 coroas de árvores individuais de quatro espécies decíduas maduras. Os padrões de precisão de classificação, erro de comissão e IV foram interpretados como consistentes com a experiência anterior com seleção de fotointerpretação aérea e chaves de eliminação. Estes resultados confirmam similaridades de classificação multiespectral de espécies arbóreas baseadas em VANT relatadas em outros lugares (GINI 2014; LISEIN et al. 2015; AHMED et al. 2017).

Nos demais trabalhos desenvolvidos visando classificar árvores a partir de dados derivados de VANT, como os de Ahmed et al. (2017), Franklin e Ahmed (2017) e Franklin et al. (2018), as maiores precisões globais de classificação foram obtidas usando combinações de variáveis espectrais (incluindo dados na faixa do infravermelho próximo), texturas e variáveis de forma e coroa baseadas em nuvem de pontos. Essas características foram especificamente selecionadas para capturar digitalmente diferenças esperadas entre espécies individuais de interesse (ST. ONGE et al. 2015).

Diante do cenário demonstrado e dos resultados obtidos, nota-se que devem ser estudadas e implementadas metodologias para aumentar as precisões de classificação digital com dados de SR multiespectral baseados em VANT, envolvendo características radiométricas, espaciais e temporais, extração de variável específica da espécie, como formato e estrutura da copa e delineamento de árvore automatizado, utilizando algoritmos de extração automática de árvores.

5.5 CONCLUSÃO

A classificação orientada a regiões revelou que, para as áreas sobrevoadas o melhor método foi o *Support Vector Machine*. Para as áreas analisadas, a maior acurácia na classificação foi representada pela composição de bandas com o índice ExG e com as bandas R e B do ortomosaico original, resultando em exatidão global de 0,8859 e 0,8347 e índice kappa de 0,8306 e 0,9105, respectivamente.

Recomenda-se testar algoritmos de detecção automática de árvores individuais, bem como outros métodos de classificação, outros parâmetros de segmentação de imagens e classificação automatizada de copas individuais.

REFERÊNCIAS

ABDULLAH, H.; DARVISHZADEH, R.; SKIDMORE, A.K.; GROEN, T.A.; HEURICH, M. European spruce bark beetle (*Ips typographus*, L.) green attack affects foliar reflectance and biochemical properties. **International Journal Applied Earth Observation and Geoinformation**, v. 64, p. 199–209, 2018.

AHMED, O. S.; A. SHEMROCK, D.; CHABOT, C. ;DILLON, G.; WILLIAMS, R.; WASSON, S. E. FRANKLIN. Hierarchical Land Cover and Vegetation Classification Using Multispectral Data Acquired from an Unmanned Aerial Vehicle. **International Journal of Remote Sensing**, v. 38, n. 8–10, p. 2037–2052, 2017.

ALVARES, C. A.; STAPE, J. L.; SENTELHAS, P.C.; GONÇALVES, J. L. M.; SPAROVEK, G. Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, Stuttgart, v. 22, n. 6, p.711-728, 2013.

ASRAR, G.; KANEMASU, E. T.; JACKSON, R. D.; PINTER, P. J., Estimation of total aboveground phytomass production using remotely sensed data. **Remote Sensing of Environment**, v.17, p. 211–220, 1985.

BEHMANN, J.; STEINRÜCKEN, J.; PLÜMER, L. Detection of early plant stress responses in hyperspectral images. **ISPRS Journal Photogrammetric Remote Sensing**, v. 93, p. 98–111, 2014.

BHARDWAJ, A.; SAM, L.; AKANSHA, MARTIN-TORRES, F.J.; KUMAR, R. UAVs as remote sensing platform in glaciology: Present applications and future prospects. **Remote Sensing of Environment**, v. 175, p. 196-204, 2016.

BROWN, M.; LOWE, D. G. Automatic Panoramic Image Stitching using Invariant Features. **International Journal of Computer Vision**, v. 74, n. 1, p. 59-73, 2007.

BULMAN, L.S.; BRADSHAW, R.E.; FRASER, S.; MARTN-GARCA, J.; BARNES, I.; MUSOLIN, D.L.; LA PORTA, N.; WOODS, A.J.; DIEZ, J.J.; KOLTAY, A.; DRENKHAN, R.; AHUMADA, R.; POLJAKOVICPAJNIK, L. et al. A worldwide perspective on the management and control of Dothistroma needle blight. **Forest Pathology**, v. 46, p. 472–488, 2016.

CALDERÓN, R.; NAVAS-CORTÉS, J.A.; LUCENA, C.; ZARCO-TEJADA, P.J. High-resolution airborne hyperspectral and thermal imagery for early detection of verticillium wilt of olive using fluoescense, temperature and narrow-band spectral indices. **Remote Sensing of Environment**, v.139, p. 231-245, 2013.

CAMPOS, M. B.; TOMMASELLI, A. M. G.; MORAES, M. V. A. D.; MARCATO, J. J. Análise Comparativa dos Resultados Obtidos pelos Métodos de Calibração de Campo Tridimensional e Bidimensional. **Boletim de Ciências Geodésicas**, v. 21, n. 2, p. 308-328, 2015.

CANDIAGO, S.; REMONDINO, F.; GIGLIO, M.de.; DUBBINI, M.; GATTELLI, M. Evaluating Multispectral Images and Vegetation Indices for Precision Farming Applications from UAV Images. **Remote Sensing**, v.7, p. 4026-4047, 2015.

COOPS, N. C.; JOHNSON, M.; WULDER, M. A.; WHITE, J. C. Assessment of QuickBird high spatial resolution imagery to detect red attack damage due to mountain pine beetle infestation. **Remote Sensing of Environment**, v. 103, n. 1, p. 67–80, 2006.

CRÓSTA, A. P. **Processamento Digital de Imagens de Sensoriamento Remoto**. Campinas, SP, UNICAMP, ed. rev., 1993.

DASH, J.P.; WATT, M.S.; PEARSE, G.D.; HEAPHY, M.; DUNGEY, H.S. 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.

ESRI. Environmental Systems Research Institute. **ArcGIS Professional GIS for the desktop, version 10.4.1**. Disponível em: <https://support.esri.com/en/Products/Desktop/arcgis-desktop/arcmap/10-4-1>. Acesso em: 20 mai. 2018.

FASSNACHT, F.E.; LATIFI, H.; GHOSH, A.; JOSHI, P.K.; KOCH, B. Assessing the potential of hyperspectral imagery to map bark beetle-induced tree mortality. **Remote Sensing of Environment**, v. 140, p. 533–548, 2014.

FRANKLIN, S.E.; AHMED, O. S. Deciduous tree species classification using object-based image analysis and machine learning with unmanned aerial vehicle multispectral data. **International Journal of Remote Sensing**, p. 1-10, 2017.

FOSTER, A.C.; WALTER, J.A.; SHUGART, H.H.; SIBOLD, J.; NEGRON, J. Spectral evidence of early-stage spruce beetle infestation in Engelmann spruce. **Forest Ecology and Management**, v. 384, p. 347-357, 2017.

GARCIA-RUIZ, F.; SANKARAN, S.; MAJA, J.M.; LEE, W.S.; RASMUSSEN, J.; EHSANI, R. Comparison of two aerial imaging platforms for identification of *Huanglongbing* infected citrus trees. **Computers and Electronics in Agriculture**, v. 91, p. 106–115, 2013.

GINI, R. Use of Unmanned Aerial Systems for Multispectral Survey and Tree Classification: A Test in a Park Area of Northern Italy. **European Journal of Remote Sensing**, p. 251–269. doi:10.5721/ EuJRS20144716.

HANSEN, E.M.; NEGRON, J.F.; MUNSON, A. S.; ANHOLD, J.A. A retrospective assessment of partial cutting to reduce spruce beetle-caused mortality in the southern Rocky Mountains. **Western Journal of Applied Forestry**, v. 25, p. 81–87, 2010.

HART, S.J.; VEBLER, T.T. Detection of spruce beetle-induced tree mortality using high-and medium-resolution remotely sensed imagery. **Remote Sensing of Environment**, v. 168, p. 134–145, 2015.

HOLOPAINEN, M.; VASTARANTA, M.; HYYPPÄ, J. Outlook for the next generation's precision forestry in Finland. **Forests**, v. 5, n. 7, p. 1682–1694, 2014.

HUANG, C.; DAVIS, L.S.; TOWNSHED, J.R.G. An assessment of support Vector Machines for Land cover classification. **International Journal of Remote Sensing**, v. 23, p. 725–749, 2002.

HUNT, E.R.; DAUGHTRY, C.S.T.; EITEL, J.U.H.; LONG, D.S. Remote sensing leaf chlorophyll content using a visible band index. **Agronomy Journal**, v. 103, p. 1090–1099, 2011.

ISHIDA, T.; KURIHARA, J.; VIRAY, F.A.; NAMUCO, S.B.; PARINGIT, E.C.; PEREZ, G.J.; TAKAHASHI, Y.; MARCIANO JR, J.J. A novel approach for vegetation classification using UAV-based hyperspectral imaging. **Computers and Electronics in Agriculture**, v. 144, p. 80–85, 2018.

JENSEN, J. R. **Introductory Digital Image Processing: A Remote Sensing Perspective**, Prentice Hall, New Jersey; Estados Unidos, 2000.

JENSEN, J. R. **Remote sensing of the environment: an earth resource perspective** (2 nd edition). Pearson Prentice Hall. 2007.

JORGE, L.A.D.C.; INAMASU, R.Y. Uso de Veículos Aéreos Não Tripulados (VANT) em agricultura de precisão. São Carlos: Embrapa, **Circular Técnica**, 2014.

JUNTTILA, S.; VASTARANTA, M.; HÄMÄLÄINEN, J.; LATVA-KÄYRÄ, P.; HOLOPAINEN, M.; HERNÁNDEZ CLEMENTE, R.; HYYPPÄ, H.; NAVARRO-CERRILLO, R.M. Effect of forest structure and health on the relative surface temperature captured by airborne thermal imagery—case study in Norway spruce-dominated stands in Southern Finland. **Scandinavian Journal Forest Research**, p. 1–12, 2016.

KE, Y.; QUACKENBUSH, L.L. A review of methods for automatic individual tree-crown detection and delineation from passive remote sensing. **International Journal of Remote Sensing**, v. 32, n. 17, p. 4725-4747, 2011.

KOEHLER, A.; FIRKOWSKI, C. Descascamento de pinus por macaco-prego (*Cebus apella*). **Floresta**, Curitiba, v. 24, n. 1/2, p. 61-75, 1996.

KORPELA, I.; HEIKKINEN, V.; HONKAVAARA, E.; ROHRBACH, F.; TOKOLA, T. Variation and directional anisotropy of reflectance at the crown scale—Implications for tree species classification in digital aerial images. **Remote Sensing of Environment**, v. 115, p. 2062–2074, 2011.

LAUSCH, A.; PAUSE, M.; DOKTOR, D.; PREIDL, S.; SCHULZ, K. Monitoring and assessing of landscape heterogeneity at different scales. **Environment Monitoring Assessment**, v. 185, n. 11, p. 9419–9434, 2013.

LEHMANN, J.R.K.; NIEBERDING, F.; PRINZ, T.; KNOTH, C. Analysis of Unmanned Aerial System-Based CIR Images in Forestry—A New Perspective to Monitor Pest Infestation Levels. **Forests**, v. 6, p.594-612, 2015.

LIEBSCH, D.; MARQUES, M. C. M.; GOLDENBEG, R. How long does the Atlantic Rain Forest take to recover after a disturbance? Changes in species composition and ecological features during secondary succession. **Biological Conservation**, v. 141, n. 6, p. 1717-1725, 2008.

LIEBSCH, D.; MIKICH, S.B. Descascamento e identificação de danos causados por macacos-prego (*Sapajus nigritus*) a plantios de eucaliptos. **Comunicado Técnico**, Embrapa Florestas, Colombo-PR, v. 328, p. 1-6, 2013.

LIEBSCH, D.; MIKICH, S. B.; OLIVEIRA, E. B. de; MOREIRA, J. M. M. Á. P. Descascamento de *Pinus taeda* por macacos-prego (*Sapajus nigritus*): tipos e intensidades de danos e seus impactos sobre o crescimento das árvores. **Scientia Forestalis**, Piracicaba, v. 43, n. 105, p. 37-49, 2015.

LISEIN, J.; MICHEZ, A.; CLAESSENS, H.; LEJEUNE, P. Discrimination of Deciduous Tree Species from Time Series of Unmanned Aerial System Imagery. **PLoS ONE**, v. 10, n. 11, p. e0141006, 2015. doi:10.1371/journal.pone.0141006.

LOUHAICHI, M.; BORMAN, M.M.; JOHNSON, D.E. Spatially located platform and aerial photography for documentation of grazing impacts on wheat. **Geocarto International**, v. 16, p. 65–70, 2001.

LYNCH ALFARO, J. W.; DE SOUSA E SILVA, J., JR.; RYLANDS, A. B. How Different Are Robust and Gracile Capuchin Monkeys? An Argument for the Use of *Sapajus* and *Cebus*. **American Journal of Primatology**, v. 74, n. 4, p. 273-286, 2012.

MAITI, S.; SATPATHY, R.; BANDYOPADHYAY, J.; et al. Vegetation parameter derivation for forest health measurement and stress detection in a time series. **Research & Reviews: Journal of Ecology**, v. 4, n.3, p. 19-26, 2015.

MAHESH, P., MATHER, P.M. An assessment of the effectiveness of the decision tree method for land cover classification. **Remote Sensing of the Environment**, v. 86, p. 554–565, 2003.

MARCATO JÚNIOR, J. **Fototriangulação em bloco de imagens orbitais com modelos rigorosos baseados em pontos e retas**. Dissertação, Universidade Estadual de São Paulo. 119p, 2011.

MANCINI, F.; DUBBINI, M.; GATTELLI, M.; STECCHI, F.; FABBRI, S.; GABBIANELLI, G. Unmanned Aerial Vehicles (UAV) for High Resolution Reconstruction of Topography: The Structure from Motion Approach on Coastal Environments. **Remote Sensing**, v. 5, p. 6880-6898, 2013.

MEIGS, G. W.; KENNEDY, R. E.; COHEN, W. B. A Landsat time series approach to characterize bark beetle and defoliator impacts on tree mortality and surface fuels in conifer forests. **Remote Sensing of Environment**, v. 115, n. 12, p. 3707–3718, 2011.

MICHEZ, A.; LEJEUNE, P. Classification of riparian forest species and health condition using multitemporal and hyperspatial imagery from unmanned aerial systems. **Environmental Monitoring and Assessment**, v.188, n. 146, p. 19-XX, 2016.

MIKICH, S. B.; LIEBSCH, D. O Macaco-prego e os Plantios de *Pinus* spp. **Comunicado Técnico**, Embrapa Florestas. Colombo, PR, n. 234, p.1-5. 2009.

MIKICH, S. B.; LIEBSCH, D. Damage to forest plantations by tufted capuchins (*Sapajus nigritus*): too many monkeys or not enough fruits? **Forest Ecology and Management**, v. 314, p. 9-16, 2014.

MORIYA, E. A. S.; IMAI, N. N.; TOMMASELLI, A. M. G.; MIYOSHI, G. T. Mapping Mosaic Virus in Sugarcane Based on Hyperspectral Images. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 10, n. 2, p. 740-748, 2017.

NASI, R.; HONKAVAARA, E.; LYYTIKÄINEN-SAARENMAA, P.; BLOMQVIST, M.; LITKEY, P.; HAKALA, T.; VILJANEN, N.; KANTOLA, T.; TANHUANPÄÄ, T.; HOLOPAINEN, M. Using UAV-Based Photogrammetry and Hyperspectral Imaging for Mapping Bark Beetle Damage at Tree-Level. **Remote Sensing**, v. 7, p.15467-15493, 2015.

NÄSI, R.; HONKAVAARA, E.; BLOMQVIST, M.; LYYTIKÄINEN-SAARENMAA, P.; HAKALA, T.; VILJANEN, N.; KANTOLA, T.; HOLOPAINEN, M. Remote sensing of bark beetle damage in urban forests at individual tree level using a novel hyperspectral camera from UAV and aircraft. **Urban Forest & Urban Greening**, v. 30, p. 72-83, 2018.

NEGRON-JUAREZ, R. I.; CHAMBERS, J. Q.; MARRA, D. M.; RIBEIRO, G. H. P. M.; RIFAI, S. W.; HIGUCHI, N. et al. Detection of subpixel treefall gaps with Landsat imagery in Central Amazon forests. **Remote Sensing of Environment**, v. 115, p. 3322–3328, 2011.

NEVALAINEN, O.; HONKAVAARA, E.; TUOMINEN, S.; VILJANEN, N.; HAKALA, T.; YU, X.; HYYPPÄ, J.; SAARI, H.; PÖLÖNEN, I.; IMAI, N.N.; TOMMASELLI, A.M.G. Individual tree detection and classification with UAV-Based Photogrammetric point clouds and hyperspectral imaging. **Remote Sensing**, v.9, n. 185, p. 1-34, 2017.

OSUNA, E.; FREUND, R.; GIROSI, F. An improved training algorithm for support vector machines. In Proceedings of the 1997 IEEE Workshop on Neural Networks for Signal Processing, Eds. J. Principe, L. Giles, N. Morgan, E. Wilson, pages 276 – 285, Amelia Island, FL, 1997.

OTUKEI, J.R.; BLASCCKE, T. Land cover change assessment using decision trees, support vector machines and maximum likelihood classification algorithms. **International Journal of Applied Earth Observation and Geoinformation**, v. 125, p. s27-s31, 2010.

PEREIRA, G.H.D.A.; CENTENO, J.A.S. Avaliação do tamanho de amostras de treinamento para redes neurais artificiais na classificação supervisionada de imagens utilizando dados espectrais e Laser Scanner. **Boletim de Ciências Geodésicas**, Curitiba, v. 23, n. 2, p. 268-283, 2017.

POULIOT, D.A.; KING, D.J.; BELL, F.W.; PITT, D.G. Automated tree crown detection and delineation in high-resolution digital camera imagery of coniferous forest regeneration. **Remote Sensing of Environment**, v. 82, p. 322–334, 2002.

PUTTONEN, E.; LITKEY, P.; HYYPPÄ, J. Individual tree species classification by illuminated-shaded area separation. **Remote Sensing**, v. 2, p. 19–35, 2010.

QUINLAN, R. Programs for Machine Learning. Morgan Kaufman, San Mateo. 1993.

R CORE TEAM. R: **A language and environment for statistical computing**. R Foundation for Statistical Computing, Vienna, Austria. Disponível em: <<https://www.Rproject.org/>> Acesso em: 22 abr 2018.

REDWEIK, P. **Fotogrametria Aérea**. Universidade de Lisboa, 2007. (Apostila).

RICHARDS, J.A. **Remote Sensing Digital Image Analysis**, Second Edition, New York: Wiley, 1993.

ROCHA, V. J. Macaco-Prego, como controlar essa nova praga florestal? **Floresta**, Curitiba, v. 30, n. 1/2, p. 95-99, 2000.

RUMPF, T., MAHLEIN, A.-K., STEINER, U., OERKE, E.-C., DEHNE, H.-W., PLÜMER, L., 2010. Early detection and classification of plant diseases with support vector machines based on hyperspectral reflectance. **Computers and Electronic Agriculture**, v. 74, n. 1, p. 91–99, 2010.

SENF, C.; SEIDL, R.; HOSTERT, P. Remote sensing of forest insect disturbances: Current state and future directions. **International Journal of Applied Earth Observation Geoinformation**, v. 60, p. 49-60, 2017.

SILVA, S. L. A.; TOMMASELLI, A. M. G.; ARTERO, A. Utilização de Alvos Codificados do tipo Aruco na Automatização do Processo de Calibração de Câmaras. **Boletim de Ciências Geodésicas**, v. 20, n. 3, p. 636-656, 2014.

SILVA, C. A.; SOUTO, M. V. S.; DUARTE, C. R.; BICHO, C. P.; SABADIA, J. A. B. (2015) Avaliação da acurácia dos ortomosaico e modelos digitais do terreno gerados pelo MVANT/DNPM. **Revista Brasileira de Cartografia**, v. 67, n. 7, p. 1479-1495, 2015.

ST-ONGE, B.; AUDET, F.-A.; BEGIN, J. Characterizing the height structure and composition of a boreal forest using an individual tree crown approach applied to photogrammetric point clouds. **Forests**, v. 6, p. 3899-3922, 2015.

TORRESAN, C.; BERTON, A.; CAROTENUTO, F.; DI GENARO, S.F.; GIOLI, B.; MATESE, A.; MIGLIETTA, F.; VAGNOLI, C.; ZALDEI, A.; WALLACE, L. Forestry applications of UAVs in Europe: a review. **International Journal of Remote Sensing**, v. 3, n. 8-10, p. 2427-2447, 2017.

VAPNIK, W.N.; CHERVONENKIS, A.Y. 1971. On the uniform convergence of the relative frequencies of events to their probabilities. *Theory of Probability and its Applications*, v. 17, p. 264–280, 1971.

VAPNIK, W.N. An overview of statistical learning theory. **IEEE Transactions of Neural Networks**, v. 10, p. 988–999, 1999.

VERRELST, J.; SCHAEPMAN, M.E.; KOETZ, B.; KNEUBÜHLER, M. Angular sensitivity analysis of vegetation indices derived from CHRIS/PROBA data. **Remote Sensing of Environment**, v. 112, n. 5, p. 2341–2353, 2008.

VILANOVA, R.; SOUSA, J.; JÚNIOR, S.; GRELLE, C. E. V.; MARROIG, G. & R. CERQUEIRA. Limites climáticos e vegetacionais das distribuições de *Cebus nigrinus* e *Cebus robustus* (Cebinae, Platyrrhini). **Neotropical Primates**, v. 1, n. 13, p. 14-19, 2005.

VOGELMANN, J.E.; TOLK, B.; ZHU, Z.L. 2009. Monitoring forest changes in the southwestern United States using multitemporal Landsat data. **Remote Sensing of Environment**, v. 113, p. 1739–1748, 2009.

ZANETTI, J.; JUNIOR, J.G; SANTOS, A.D.P.D. Influência do número e distribuição de pontos de controle em ortofotos geradas a partir de um levantamento por VANT. **Revista Brasileira de Cartografia**, v. 69, n.2, p. 263-277, 2017.

ZARCO-TEJADA, P.; BERJÓN, A.; LOPEZ-LOZANO, R.; MILLER, J.; MARTIN, P.; CACHORRO, V.; GONZALEZ, M. DEFRUTOS, A. Assessing vineyard condition with hyperspectral indices: Leaf and canopy reflectance simulation in a row-structured discontinuous canopy. **Remote Sensing of Environment**, v. 99, n. 3, p. 271–287, 2005.

WHITEHEAD, K.; HUGENHOLTZ, C. Remote sensing of the environment with small unmanned aircraft systems (UASs), Part 1: A review of progress and challenges. **Journal of Unmanned Vehicle Systems**, v. 2, n. 3, p. 69–85, 2014.

WOEBBECKE, D.M.; MEYER, G.E.; VON BARGEN, K.; MORTENSEN, D.A. Color indices for weed identification under various soil, residue, and lighting conditions. **Transactions of the ASAE**, v. 38, p. 259–269, 1995.

WULDER, M. A.; WHITE, J. C.; BENTZ, B.; ALVAREZ, M. F.; COOPS, N. C. Estimating the probability of mountain pine beetle red-attack damage. **Remote Sensing of Environment**, v. 101, n. 2, p. 150–166, 2006. doi.org/10.1016/j.rse.2005.12.010.

6 CAPÍTULO III:

EFEITO DO ATAQUE DE *Sapajus nigritus* Kerr (1972) NA PRODUÇÃO DE MADEIRA DE UM POVOAMENTO DE *Pinus taeda* L.

RESUMO

Essa pesquisa teve como objetivo avaliar o impacto do ataque de *S. nigritus* nas variáveis dendrométricas e no valor bruto da produção média de árvores de um povoamento de *Pinus taeda* L., localizado em Bocaina do Sul, estado de Santa Catarina. Para isso, foram instaladas 46 circulares de raio variável. Foram medidos a circunferência à altura do peito, altura total, altura inferior do dano e comprimento do dano de todos os indivíduos arbóreos contidos nas parcelas. O processamento dos dados foi realizado no *software* SisPinus com a planilha "Macaco-prego calc", o qual estimou o volume danificado e o volume total das árvores atacadas. Os resultados revelaram que ocorreram os dois tipos de danos causados pelo macaco-prego, anelamento e janelamento. Contudo, o primeiro foi o mais acentuado. Em relação ao número de danos, árvores com um único dano compreenderam 95,34% das árvores aneladas e 97,91% das árvores janeladas. A altura inferior dos danos aumentou com a idade das árvores aneladas e janeladas. As variáveis dendrométricas das árvores atacadas foram ligeiramente maiores do que às das árvores não atacadas. O volume apresentou a variação mais expressiva, sendo que as médias das árvores aneladas foram superiores as demais. Foram danificados 8,64 m³ ha⁻¹ pelo anelamento e 3,23 m³ ha⁻¹ pelo janelamento. A análise estatística revelou que não houve diferença significativa entre os tratamentos considerados para o diâmetro à altura do peito, altura total e volume total por parcela. Assim, pode-se concluir que esse povoamento teve seu crescimento afetado pelo ataque desse primata e que o anelamento foi o dano mais grave. Tais dados destacam a importância da caracterização e quantificação dos danos em um povoamento, para subsidiar a tomada de decisões do manejo florestal do povoamento acometido.

Palavras-chave: Danos florestais, primatas, manejo florestal.

ABSTRACT

The objective of this research was to evaluate the impact of *S. nigritus* attack on the dendrometric variables and the gross value of the average yield of trees from a *Pinus taeda* L. stand located in Bocaina do Sul, Santa Catarina State. For this purpose, 46 circulars with variable radius were installed. The circumference at breast height, total height, lower height of the damage and length of damage of all the arboreal individuals contained in the plots were measured. The data processing was performed in the SisPinus software with the "Macaco-prego calc" spreadsheet, which estimated the damaged volume and the total volume of the attacked trees. The results revealed that the two types of damages caused by monkey-nail, ringing and windowing occurred. However, the first was the most pronounced. In relation to the number of damages per tree, trees with single damage comprised 95.34% of the ringed trees and 97.91% of the trees felled. The lower height of the damages increased with the age of the ringed and windowed trees. The dendrometric variables of the attacked trees was slightly higher than those of the non - attacked trees. The volume was the variable with the most significant variation, and the mean of the ringed trees were higher than the others. 0.3888 m³ 0.0078 ha⁻¹ were damaged by girdling and 0.1453 m³ 0.0078 ha⁻¹ by windowing. Statistical analysis revealed that there was no statistical difference between the treatments considered for diameter at breast height, total height and total volume per plot. Thus, it can be concluded that this population had its growth affected by the attack of this primate and that the

ringing was the most serious damage. These data highlight the importance of the characterization and quantification of the damages in a stand, to subsidize the decision making of the forest management of the affected stand.

Keywords: Forest damages, primates, forest management.

6.1 INTRODUÇÃO

Sapajus nigritus (Kerr, 1972) conhecido popularmente como macaco-prego, é uma espécie endêmica com ocorrência desde o Sudeste ao sul do Brasil e nordeste da Argentina (LYNCH ALFARO et al., 2012). Com hábitos alimentares onívoros, esse primata possui dieta relacionada ao aprendizado, permitindo a inclusão de novos alimentos em sua dieta, como é o caso da seiva de *Pinus* spp (ROCHA, 2000). Formada por carboidratos, aminoácidos, ácidos orgânicos, proteínas e sais minerais (DINANT, 2008), esse alimento pode ser considerado como *fallback*, ou seja, baixa preferência de consumo e alta importância sazonal (MARSHALL; WRANGHAM, 2007).

A busca por alimentos alternativos por macaco-prego foi causada pela degradação e exploração da Mata Atlântica, que causa escassez de alimentos em determinados períodos (LIEBSCH et al., 2008). O consumo de recursos florestais, como a seiva do *Pinus* spp, causa danos e interfere no crescimento e produção desses plantios. Para obter esse alimento, o macaco-prego retira a casca da árvore, causando dois padrões de danos: janelamento (retirada parcial da casca em um ou mais entrenós) e o anelamento (retirada da casca em toda a circunferência do fuste). Além de comprometer o crescimento da árvore, esses danos favorecem a exposição da árvore a ação de pragas, como fungos (KOEHLER; FIRKOWSKI, 1996; ROCHA, 2000; MIKICH; LIEBSCH, 2014; LIEBSCH et al., 2015).

Diante disso, é possível perceber o impacto do ataque desse primata aos produtores e ao setor florestal como um todo, pois a perda de qualidade da madeira na área atacada acarreta em prejuízos financeiros significativos. O macaco-prego possui proteção legal como espécie nativa pela Lei de Crimes Ambientais (Lei nº 9.605/1998) (BRASIL, 1998), dificultando alternativas para seu controle populacional. Dessa forma, o planejamento apropriado das florestas atacadas torna-se de suma importância, para a avaliação quantitativa dos danos e para a tomada de decisões que visam a prevenção e o controle dos ataques desse primata.

As pesquisas com essa abordagem foram desenvolvidas por pesquisadores do projeto Macaco-prego dirigido pela EMBRAPA Florestas (Empresa Brasileira de Pesquisa Agropecuária) como os trabalhos de Liebsch et al. (2015) e Liebsch et al. (2018). Com a criação e desenvolvimento da ferramenta computacional Macaco-prego calc (EMBRAPA FLORESTAS, 2018), é possível realizar estimativas sobre as perdas de produção de madeira de povoamentos

florestais atacados por macaco-prego, além de realizar predições acerca da produção dessas áreas florestais de acordo com os níveis e idade de ocorrência dos ataques (OLIVEIRA et al., 2015).

Diante desse cenário, nota-se a importância de estudos relacionados ao planejamento adequado das florestas atacadas, considerando a finalidade da produção madeireira, envolvendo a aplicação de desbastes e antecipação e prolongamento da idade da colheita final nos povoamentos (OLIVEIRA et al., 2015). Assim, estudos visando avaliar o dano quantitativo ou econômico causado pelo ataque de *S. nigritus* a plantios florestais, podem fornecer informações relevantes das preferências desse animal e podem indicar estratégias de manejo florestal para prevenção e controle dos ataques (LIEBSCH et al., 2015).

Nesse contexto, essa pesquisa teve como objetivo avaliar o impacto do ataque de *Sapajus nigritus* nas variáveis dendrométricas e na produção das árvores de um povoamento de *Pinus taeda* L., localizado em Bocaina do Sul, estado de Santa Catarina.

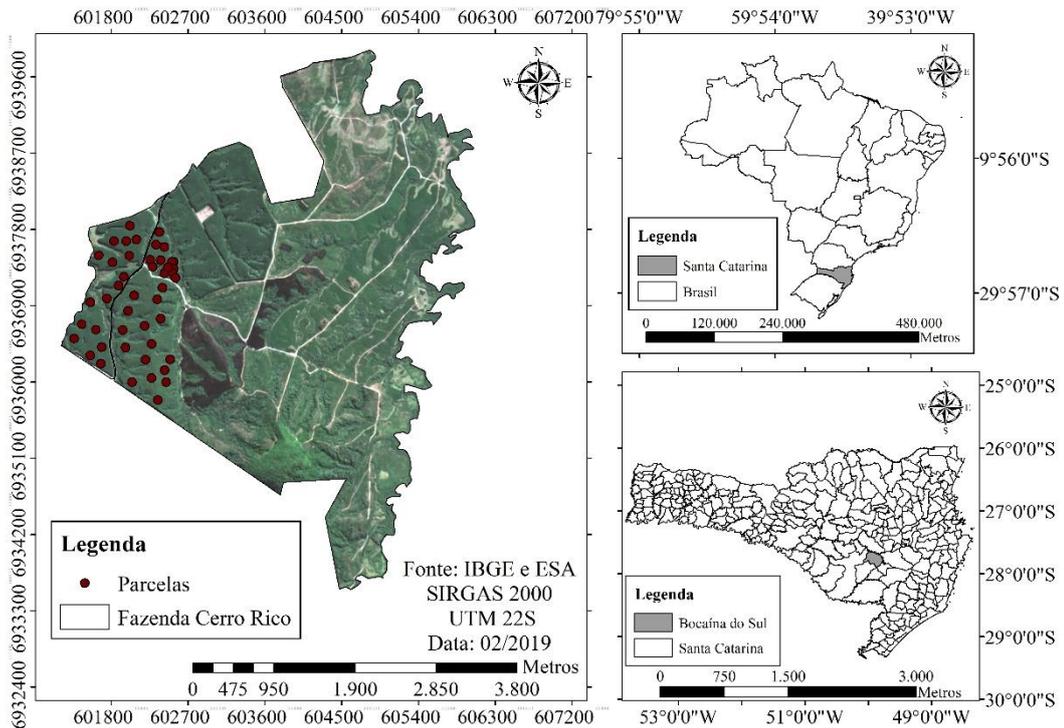
6.2 MATERIAL E MÉTODOS

6.2.1 Descrição da área

O estudo foi desenvolvido na fazenda Cerro Rico (Figura 6:1) localizada no município de Bocaina do Sul, no estado de Santa Catarina, com coordenadas UTM, referidas ao SIRGAS 2000, médias E: 602272 m e N: 6936448 m. A fazenda tem área de 1535,57 hectares, sendo o clima no local do tipo Cfb (clima mesotérmico subtropical úmido com verões frescos, sem estação seca e geadas severas), segundo a classificação de Köppen. Além disso, a temperatura média anual é de 16,5° C, umidade relativa do ar de 79,3% e precipitação bem distribuída ao longo do ano, com média anual de 1500 mm (ALVARES et al., 2013).

O plantio florestal foi realizado na área em 2002 e 2003, sendo de *Pinus taeda* L., do gênero *Eucalyptus* spp. Também existem áreas com floresta natural, com espécies nativas. O povoamento formado por *Pinus taeda* L. totaliza 236,10 hectares, com espaçamento de 3 metros x 2,5 metros. Não foram realizados desbastes e o sistema de colheita utilizado foi o *full tree*.

Figura 6: 1 - Localização do povoamento de *Pinus taeda* L. em Bocaina do Sul – SC.



Fonte: Elaborado pela Autora (2018).

6.2.2 Dados de campo

As avaliações foram realizadas durante os meses de março e abril de 2018. Para a execução do inventário florestal, foram alocadas 46 parcelas de tamanho e raio variável (5 a 10 m) para incluir árvores atacadas e não atacadas. Em cada parcela, todos os indivíduos arbóreos tiveram sua circunferência à altura do peito (CAP) mensurada com a fita métrica e a altura foi obtida com o Hipsômetro Vertex. A partir dos dados de CAP, obteve-se o diâmetro à altura do peito (DAP) em centímetros. O número de classes diamétricas foi calculado pela fórmula de Sturges (Equação 1), enquanto que o intervalo de classes foi determinado pela Equação 2:

$$NC = 1 + 3,3 \log n \quad (1)$$

$$IC = \frac{A}{NC} \quad (2)$$

Em que: NC: número de classes; n: número de árvores; A: amplitude (diferença entre o maior e menor valor da amostra) e IC: intervalo de classes.

Além disso, também foram medidos a altura inferior do dano (m) e o comprimento do dano (cm) e avaliados os tipos de danos (anelamento e janelamento) e a ocorrência de ponta seca nas

árvores, sendo que Liebsch et al. (2015), recomendam considerar árvores aneladas como aquelas que possuem os dois tipos de danos ou apenas anelamento.

Tais dados foram inseridos no aplicativo computacional SisPinus (Simulador de Crescimento e Produção de Pinus) com a planilha “Macaco-prego calc” (EMBRAPA, 2018). Esse aplicativo permite descrever o crescimento e produção de florestas do gênero *Pinus* spp. de acordo com os regimes de manejo, realizando prognoses de produções presentes e futuras, com Índice de sítio de 22. Além disso, análises econômicas também podem ser desenvolvidas, possibilitando a escolha da melhor alternativa de produção para o povoamento (OLIVEIRA, 2011).

O funcionamento da planilha “Macaco-prego calc” possibilita a elaboração de três planilhas: duas para o cálculo das perdas por danos físicos no fuste e uma para a estimativa das perdas de crescimento no povoamento atacado. Na primeira planilha, são calculados o fator de forma para a equação de volume considerando uma função de afilamento baseada em um valor de altura, correspondente a um determinado diâmetro e a altura total da árvore (OLIVEIRA et al., 2015).

Já a planilha seguinte estima as perdas de volume por árvore causados pelos danos do *S. nigritus*. Para isso, a variável independente compreende a expressão $(1 - \frac{h_i}{H})$. A partir de uma integral parcial do sólido de revolução gerado pela rotação da curva sobre o eixo referente a altura relativa, os volumes totais (m³) das árvores são obtidos (OLIVEIRA et al., 2015). Além do volume total, também são calculados: volume danificado (m³), volume acima do dano (m³) e volume abaixo do dano (m³). Para otimizar a utilização dessa ferramenta, a planilha dispõe os valores para um conjunto de árvores atacadas bem como os respectivos percentuais dos volumes obtidos (m³). E por fim, a última planilha possibilita a prognose do crescimento e produção dos povoamentos atacados por *S. nigritus*.

6.2.3 Avaliações econômicas

A estimativa da produção média das árvores atacadas e não atacadas foi baseada na metodologia descrita por Liebsch et al. (2018). Para isso, os preços dos sortimentos (Tabela 6:1) para árvores sem danos e com danos foram considerados. O volume total das árvores atacadas e não atacadas foram multiplicados pelos respectivos sortimentos, obtendo-se o preço por m³ em R\$ e conseqüentemente, a perda de produção para as árvores com e sem danos.

Tabela 6: 1 - Relação do preço dos sortimentos de árvores de *Pinus taeda* L. atacadas e não atacadas por *S. nigritus* no Sul do Brasil.

Sortimento (cm)	Preço por m ³ (R\$)		Perda de valor
	Sem danos	Danificado	
< 8	5,00	5,00	-
8 a 18	42,50	42,50	-
18 a 25	92,50	50,88	45%
25 a 35	135,00	54,00	60%
35 a 45	180,00	63,00	65%

Fonte: Adaptado de Liebsch et al. (2018).

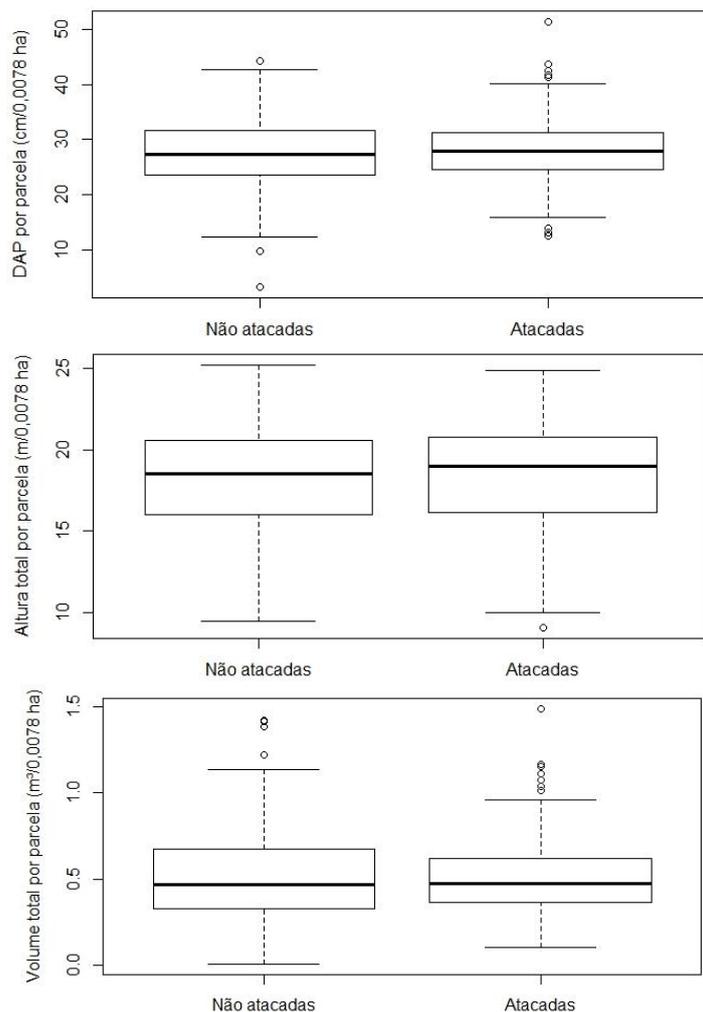
6.2.4 Análises estatísticas

O delineamento experimental foi o inteiramente casualizado com três tratamentos (árvores não atacadas, aneladas e janeladas) com 4 repetições (classes de idade), considerando as variáveis dendrométricas (diâmetro à altura do peito (cm), altura total (m) e volume total (m³)). Os dados foram submetidos ao teste de normalidade de Kolmogorov-Smirnov e de homogeneidade de variâncias de Bartlett, ambos com 5% de significância. Em seguida, aplicou-se a Análise de Variância (ANOVA) para verificar se existem diferenças significativas entre os tratamentos e o teste de Tukey para confrontar os tratamentos, com nível de 5% de significância. As análises foram realizadas no *software* R versão 3.4.1 (R CORE TEAM, 2018).

6.3 RESULTADOS

As variáveis dendrométricas DAP, altura e volume apresentaram comportamentos semelhantes para as árvores não atacadas e atacadas (Figura 6:2):

Figura 6: 2 - Estatística descritiva das variáveis dendrométricas das árvores não atacadas e atacadas por *S. nigritus* em um povoamento de *Pinus taeda* L. em Bocaina do Sul – SC.



Foram mensuradas 675 árvores e destas, 220 árvores apresentaram algum tipo de ataque, sendo que foram analisados 87,25 m³ anelados, 24,92 m³ janelados e 161,33 m³ sem nenhum dano, totalizando 273,5 m³, representando 17,81 m³ da área total. A tabulação das informações coletadas em campo permitiu ilustrar o percentual de ocorrência dos danos (anelamento e janelamento) por árvore (Tabela 6:2):

Tabela 6: 2 - Relação dos danos físicos causados por *S. nigritus* a um povoamento de *Pinus taeda* L. localizado em Santa Catarina – SC.

I	A	%	J	%	Total	%
15,3	44	25,5	8	16,6	52	23,6
15,5	33	19,2	15	31,2	48	21,8
15,6	29	16,8	13	27,2	42	19,1
16,2	66	38,5	12	25	78	35,5
Total	172	100	48	100	220	100

Em que: I: idade (anos); A: anelamento; J: janelamento; %: porcentagem em relação a soma das árvores aneladas e janeladas.

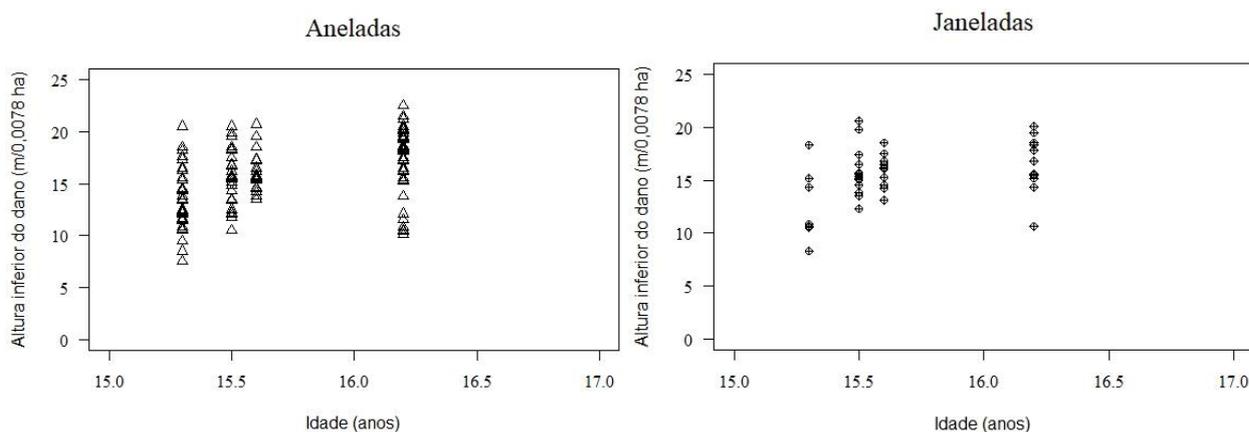
Na Tabela 6:3 é possível visualizar a quantidade de danos nas árvores avaliadas. A grande maioria das árvores teve um único tipo de dano, contudo, algumas árvores apresentaram anelamento e janelamento e apenas uma árvore avaliada foi anelada duas vezes e janelada uma vez.

Tabela 6: 3 - Número máximo de danos por árvore causados por *S. nigritus* em um povoamento de *Pinus taeda* L. localizado em Bocaina do Sul, Santa Catarina.

Idade	Número de danos por árvore					
	Anelamento			Janelamento		
	1	2	3	1	2	3
15,3	44	2	1	8	1	-
15,5	29	3	1	14	-	-
15,6	27	2	-	13	-	-
16,2	65	1	-	12	-	-
Total	164	6	1	47	1	-

O comportamento da altura inferior do dano está em concordância com o descrito na literatura, pois a altura aumentou com a idade das árvores (Figura 6:2). Além disso, 13,63% dos danos concentraram-se abaixo dos 10 metros de altura do tronco, enquanto que 59,54% ocorreram até os 20 metros.

Figura 6: 3 - Altura inferior do dano e idade das árvores aneladas e janeladas por *S. nigritus* em um povoamento de *Pinus taeda* L. localizado em Bocaina do Sul, Santa Catarina.



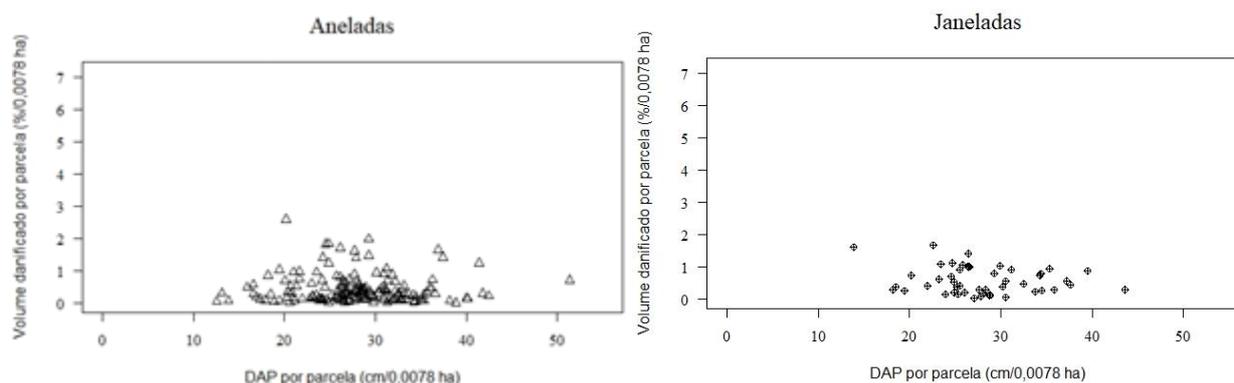
O ataque de *S. nigritus* por classe diamétrica revelou que ocorreram ataques diversificados por classes. Contudo, o ataque mais acentuado ocorreu na classe IV, com árvores de DAP entre 24,13 a 27,97 cm (Tabela 6:4). Esse fato está relacionado com o padrão de ataque, pois o macaco-prego atinge as árvores mais altas e velhas do povoamento, ou seja, árvores dominantes e co-dominantes. Isso ocorre, pois, essas árvores são encontradas em maior número do que as dominadas.

Tabela 6: 4 - Número de árvores de *Pinus taeda* L. aneladas ou janeladas por macaco-prego em função das classes de diâmetro à altura do peito (DAP).

Classe DAP (cm)	Total	Aneladas	Janeladas
I: 12,57 – 16,42	5	4	1
II: 16,43 – 20,27	18	14	4
III: 20,28 – 24,12	27	22	5
IV: 24,13 – 27,97	65	48	17
V: 27,98 – 31,82	54	44	10
VI: 31,82 – 35,67	32	26	6
VII: 35,68 – 39,52	17	13	4
VIII: 39,53 – 43,37	1	-	1
VIV: 43,38 – 47,22	-	-	-
V: 47,23 – 51,07	1	1	-
Total	220	172	48

A Figura 6:4 compara os volumes danificados (%) decorrentes dos danos causados por *S. nigritus* em um povoamento de *Pinus taeda* L.:

Figura 6: 4 - Volumes danificados pelo anelamento e janelamento em um povoamento de *Pinus taeda* L. localizado em Bocaina do Sul – SC.



De acordo com a Figura 6:4, nota-se que o volume danificado pelo anelamento foi superior ao danificado pelo janelamento. O dano anelamento comprometeu 172 árvores e $8,64 \text{ m}^3 \text{ ha}^{-1}$ enquanto que o janelamento comprometeu 48 árvores e $3,23 \text{ m}^3 \text{ ha}^{-1}$. Em relação ao volume total do povoamento ($273,5 \text{ m}^3$), o volume comprometido pelo anelamento representa 3,2% e pelo janelamento 1,2%. Também é possível perceber esse cenário na Tabela 6:5, a qual evidencia que os danos causados pelo macaco-prego ao povoamento avaliado interferiram na qualidade da madeira e consequentemente na sua produtividade.

Tabela 6: 5 - Perda do valor da produção de um povoamento de *Pinus taeda* L. atacado por *S. nigritus* em Bocaina do Sul.

Sortimento (cm)	R\$ por m ³		Prejuízos
	Sem danos	Danificado	
< 8	0,88	-	0,88
8 a 18	496	486,44	9,56
18 a 25	1075,33	577,11	498,22
25 a 35	1563,33	611,77	951,56
35 a 45	2120,44	724,89	1395,55
Total	5256	2400,44	2855,56

Em que: prejuízos: R\$/m³.

Segundo as análises estatísticas, não existem diferenças entre os tratamentos considerados para as variáveis dendrométricas referentes ao diâmetro à altura do peito (cm), altura total (m) e volume (m³) para as árvores não atacadas, aneladas e janeladas.

6.4 DISCUSSÃO

O dano mais acentuado foi o anelamento, sendo que as árvores aneladas exibiram o mesmo padrão observado por Liebsch et al. (2015): secamento e quebra da ponteira, ataque de microorganismos e áreas com apodrecimento. O janelamento revelou ser um ataque recente, devido a presença de lascas da casca das árvores encontradas próximas as árvores atacadas. Porém, prevê-se que resina da árvore atacada faça o isolamento do local danificado para recuperar o tecido exposto, também descrito por Liebsch et al. (2015).

A maior presença de ataques foi encontrada nas árvores mais velhas do povoamento, com 16,2 anos. Além disso, o percentual de danos por árvore revelou que árvores com um único dano compreenderam 95,34% das árvores aneladas e 97,91% das árvores janeladas. Em outras pesquisas, a quantidade de danos por árvore foi superior a esse número, como em Liebsch et al. (2015). Foram encontrados até oito danos (anelamento e janelamento) em árvores de *Pinus taeda* L. atacadas por *S. nigritus* e das 63,8% danificadas, 27% apresentaram um único dano.

A altura inferior do dano aumentou com a idade das árvores. Isso pode ser explicado pelo padrão de ataque desse primata, que danifica a porção superior das árvores, conforme Koehler e Firkowski (1996), Rocha (2000) e Mikich e Liebsch (2009). Em Liebsch et al. (2015), 23% dos danos foram encontrados abaixo de 7 metros de altura do tronco. Tais autores salientam que essa região do tronco é a de maior valor econômico e que, quanto mais demorar para esse dano acontecer, a perda econômica deverá ser menor.

As variáveis dendrométricas (Figura 3) expressaram valores semelhantes de estatística descritiva. Contudo, as médias de DAP das árvores aneladas e janeladas foram ligeiramente

maiores que às das árvores não atacadas. Já em relação à altura, as médias das árvores janeladas foram superiores às das árvores aneladas e não atacadas. O volume total das árvores aneladas foi ligeiramente superior às demais, seguido pelas árvores janeladas e não atacadas. Isso pode ser explicado pelo ataque estar concentrado nas árvores mais grossas e altas do povoamento.

O ataque de *S. nigritus* por classe diamétrica demonstrou que não ocorreram ataques em todas as classes. Contudo, a classe com o maior percentual de ataque (classe IV: 24,13 – 27,97 cm) coincidiu com a média das árvores não atacadas do povoamento. A referida classe representa árvores com diâmetro vigoroso, o que está diretamente relacionado com o valor comercial dessas árvores, causando certa preocupação.

Em relação ao volume danificado pelos dois tipos de danos, 8,64 m³ ha⁻¹ foram comprometidos pelo anelamento e 3,23 m³ ha⁻¹ pelo janelamento. Esses valores demonstram que ocorreu perda de madeira em volume e qualidade. Tal resultado corrobora com a pesquisa de Liebsch et al. (2018), na qual também ocorreu perdas de volume em árvores de *Pinus taeda* atacadas pelo macaco-prego. O anelamento foi o mais expressivo e no primeiro desbaste, as árvores aneladas não produziram madeira danificada. Já no segundo desbaste e corte raso, ocorreram perdas ocasionadas para uma árvore anelada que possuía locais afetados por janelamentos.

Em termos de produção, o valor bruto da produção média das árvores sem danos foi de 5256 R\$/m³ enquanto que as árvores atacadas representaram 2400,44 R\$/m³ dessa variável. Tais valores representam uma perda no valor bruto da produção de 2855,56 R\$/m³. A maior perda ocorreu no sortimento de 35 a 45 cm, em consequência do alto valor comercial dessas toras. Em Liebsch et al. (2018), o anelamento causou as maiores perdas em volume, qualidade e receita da produção, enquanto que os janelamentos causaram perdas de 45% de receita quando comparados com árvores sadias. Os sortimentos com as maiores perdas foram os de 18 a 25 cm e 25 a 35 cm.

Liebsch et al. (2015) afirmaram que o dano janelamento é o menos prejudicial em termos de incremento, contudo, prejudicam a qualidade da madeira. Já o anelamento causou o secamento parcial dos indivíduos, por interromper o transporte da seiva acima da lesão. Além disso, também podem ocorrer a quebra da ponteira, acarretando na paralisação do crescimento dessas árvores.

O impacto dos danos de *S. nigritus* na receita obtida nos desbastes e no corte raso de plantios de *Pinus taeda* L foi investigado por Liebsch et al. (2018). Os resultados demonstraram que o maior impacto dos danos ocorreu no segundo desbaste e que o anelamento causou perda de qualidade e redução no preço das toras.

6.5 CONCLUSÃO

O dano mais grave encontrado nesse povoamento de *Pinus taeda* L. atacado por *S. nigritus* foi o anelamento, que danificou $8,64 \text{ m}^3 \text{ ha}^{-1}$, comprometendo 3,2% do volume total do povoamento. Já o janelamento comprometeu $3,23 \text{ m}^3 \text{ ha}^{-1}$, representando 1,2% do volume total.

Tais resultados evidenciam o impacto do ataque desse primata em um povoamento florestal e a importância da quantificação e caracterização dos danos como uma estratégia valorosa para definir as ações relacionadas ao manejo florestal desse povoamento.

Recomenda-se testar a metodologia aqui apresentada com dados coletados em épocas coincidentes a fase pré-ataque (entre janeiro a julho), durante a ocorrência do ataque (junho a dezembro) e pós ataque (dezembro a julho) além de associar essas informações com características topográficas (declividade) da área, condições climáticas e idade do povoamento.

REFERÊNCIAS

- ALVARES, C. A.; STAPE, J. L.; SENTELHAS, P.C.; GONÇALVES, J. L. M.; SPAROVEK, G. Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, Stuttgart, v. 22, n. 6, p.711-728, 2013.
- 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. Publicado originalmente no **Diário Oficial da República Federativa do Brasil**, em 13 fev. 1998 e retificado em 17 fev. 1998. Disponível em: <http://www.planalto.gov.br/ccivil_03/leis/L9605.htm>. Acesso em: 8 jun. 2017.
- DINANT, S. Phloem, transport between organs and long-distance signalling. **Comptes Rendus Biologies**, v. 331, n. 5, p. 334-346, 2008.
- EMBRAPA FLORESTAS. **Aplicativo para cálculo de perdas por macaco-prego: Macaco-prego Calc**. Disponível em: <<https://www.embrapa.br/florestas/programa-macaco-prego>>. Acesso em: 14 mai. 2018.
- KOEHLER, A.; FIRKOWSKI, C. Descascamento de pinus por macaco-prego (*Cebus apella*). **Floresta**, Curitiba, v. 24, n. 1/2, p. 61-75, 1996.
- LIEBSCH, D.; MARQUES, M. C. M.; GOLDENBEG, R. How long does the Atlantic Rain Forest take to recover after a disturbance? Changes in species composition and ecological features during secondary succession. **Biological Conservation**, v. 141, n. 6, p. 1717-1725, 2008.
- LIEBSCH, D.; MIKICH, S. B.; OLIVEIRA, E. B. de; MOREIRA, J. M. M. Á. P. Descascamento de *Pinus taeda* por macacos-prego (*Sapajus nigritus*): tipos e intensidades de danos e seus impactos sobre o crescimento das árvores. **Scientia Forestalis**, Piracicaba, v. 43, n. 105, p. 37-49, 2015.
- LIEBSCH, D.; OLIVEIRA, E. B. de; MOREIRA, J. M. M. Á. P.; MIKICH, S. B. **Inventário e aplicativo computacional para avaliação de danos causados por macaco-prego em plantios de pinus**. Comunicado Técnico, n 384. Embrapa Florestas. Colombo, PR, p.1-8, 2016.
- LIEBSCH, D.; MOREIRA, J.M.M.A.P.; OLIVEIRA, E.B.; MIKICH, S.B. Impacto do descascamento de árvores de *Pinus taeda* L. por macacos-prego na produção e receita em plantios com desbastes. **BIOFIX Scientific Journal**, Curitiba, v.3, n.1, p. 48-55, 2018.

LYNCH ALFARO, J. W.; DE SOUSA E SILVA, J., JR.; RYLANDS, A. B. How Different Are Robust and Gracile Capuchin Monkeys? An Argument for the Use of *Sapajus* and *Cebus*. **American Journal of Primatology**, v. 74, n. 4, p. 273-286, 2012.

MARSHALL, A. J.; WRANGHAM, R. W. Evolutionary consequences of fallback foods. **International Journal of Primatology**, v. 28, n. 6, p. 1219-1235, 2007.

MIKICH, S. B.; LIEBSCH, D. **O Macaco-prego e os Plantios de *Pinus* spp.** Comunicado Técnico, n 234. Embrapa Florestas. Colombo, PR, p.1-5. 2009.

MIKICH, S. B.; LIEBSCH, D. Damage to forest plantations by tufted capuchins (*Sapajus nigritus*): too many monkeys or not enough fruits? **Forest Ecology and Management**, v. 314, p. 9-16, 2014.

OLIVEIRA, E. B. de; MOREIRA, J. M. M. A. P.; LIEBSCH, D.; MIKICH, S. B. Ferramenta computacional para estimar perdas na produção de madeira de *Pinus taeda*, atacadas por macaco-prego (*Sapajus nigritus*). In: CONGRESSO FLORESTAL PARANAENSE, 5. 2015, Curitiba. Novas tecnologias florestais: **Anais...** [Curitiba]: Associação Paranaense de Empresas de Base Florestal, 2015. 10 p.

OLIVEIRA, E.B. de. **Softwares para manejo e análise econômica de plantações florestais.** Documentos, 216. 2011. 70p.

R CORE TEAM. **R: A language and environment for statistical computing.** R Foundation for Statistical Computing, Vienna, Austria. Disponível em: <<https://www.Rproject.org/>> Acesso em: 22 abr 2018.

ROCHA, V. J. Macaco-Prego, como controlar essa nova praga florestal? **Floresta**, Curitiba, v. 30, n. 1/2, p. 95-99, 2000.

7 CAPÍTULO IV: RECOMENDAÇÕES E PERSPECTIVAS PARA PESQUISAS FUTURAS

Diante dos resultados encontrados nessa pesquisa, surgem algumas perspectivas para trabalhos futuros. Para análises envolvendo Sentinel-2, recomenda-se testar e utilizar outros índices de vegetação, utilizar parcelas maiores para diminuir o erro associado ao uso de receptores GNSS e também avaliar o comportamento espectral de pragas para testar o potencial desse sensor óptico, dispondo de dados em escala temporal e avaliações *in situ* (parcelas).

Pesquisas envolvendo imagens de alta resolução espacial obtidas por Veículos Aéreos Não Tripulados (VANT) podem explorar algoritmos de detecção automática de árvores, de delineamento individual de árvores e extração do número de árvores a partir de modelos digitais como o CHM (*Canopy Height Model*). Além disso, a aquisição de imagens na faixa do infravermelho poderá contribuir para a diferenciação das árvores com base na sua condição fitossanitária, a partir de índices de vegetação combinados com tais algoritmos.

Em relação ao manejo florestal do povoamento atacado por esse primata, inventários realizados na fase pré-ataque, durante e após o ataque podem melhorar o entendimento do padrão de ataque desse animal. Dessa forma, a integração desses dados com características da área como topografia, condições climáticas e idade do povoamento irá favorecer a tomada de decisão da melhor estratégia do ordenamento florestal desse povoamento.

ANEXO A

Tabela 7: 1 - Modelos ajustados pelas técnicas *Stepwise*, *Support Vector Machine* e *Random Forest* na estimativa de ataque de *S. nigritus* por parcela (% 0,045 ha⁻¹) em um povoamento de *Pinus taeda* L. localizado em Bocaina do Sul, Santa Catarina.

Modelo	Método	Classe	Equação
1	Stepwise	Sem danos	$A = \beta_0 + \beta_1 * IV + \beta_2 * \ln IV + \beta_3 * 1/IV2 + \beta_4 * 1/IV2^2 + \beta_5 * 1/IV^4$
2	SVM	Sem danos	$A = \beta_0 + \beta_1 * IV + \beta_2 * IV2 + \beta_3 * IV^2 + \beta_5 * IV2^3 + \beta_6 * IV2^4 + \beta_7 * IV^5$
3	RF	Sem danos	$A = \beta_0 + \beta_1 * IV + \beta_2 * IV2 + \beta_3 * IV2^2 + \beta_4 * 1/IV + \beta_5 * \text{EXP } IV2^4$
1	Stepwise	Moderado	$A = \beta_0 + \beta_1 * IV + \beta_2 * IV2 + \beta_3 * IV^2 + \beta_4 * IV^3 + \beta_5 * IV^4 + \beta_6 * IV^5 + \beta_7 * IV2^2 + \beta_8 * IV2^3 + \beta_9 * IV2^4 + \beta_{10} * IV2^5 + \beta_{11} * \ln IV2 + \beta_{12} * \text{EXP } IV + \beta_{13} * \text{EXP } IV2 + \beta_{17} * 1/IV^3$
2	SVM	Moderado	$A = \beta_0 + \beta_1 * IV + \beta_2 * 1/IV2 + \beta_3 * 1/IV^2 + \beta_4 * IV2^2 + \beta_5 * IV^4 + \beta_6 * \frac{1}{IV^5} + \beta_7 * \ln IV2 + \beta_8 * \text{EXP } IV2^3 +$
3	RF	Moderado	$A = \beta_0 + \beta_1 * IV + \beta_2 * IV2 + \beta_3 * IV2^4 + \beta_4 * IV2^5 + \beta_5 * \ln IV2^2 + \beta_6 * \text{EXP } IV + \beta_7 * \text{EXP } IV2 + \beta_8 * 1/IV^3$
1	Stepwise	Severo	$A = \beta_0 + \beta_1 * IV + \beta_2 * IV2 + \beta_3 * IV^2 + \beta_4 * \ln IV^2 + \beta_5 * IV^3 + \beta_6 * \text{EXP } IV^4 + \beta_7 * 1/IV^5 + \beta_8 * 1/IV2^2 + \beta_9 * \text{EXP } IV2^3 + \beta_{10} * \ln IV2^5$
2	SVM	Severo	$A = \beta_0 + \beta_1 * IV + \beta_2 * 1/IV2 + \beta_3 * 1/IV^2 + \beta_4 * 1/IV^3 + \beta_5 * 1/IV^4 + \beta_6 * 1/IV^5 + \beta_7 * 1/IV2^2 + \beta_8 * 1/IV2^3 + \beta_9 * \ln IV2 + \beta_{10} * \text{EXP } IV2$
3	RF	Severo	$A = \beta_0 + \beta_1 * IV + \beta_2 * IV * IV2 + \beta_3 * 1/IV * 1/IV^2 + \beta_4 * IV^3 + \beta_5 * IV^4 + \beta_6 * IV^5 + \beta_7 * \text{EXP } 1/IV2^2 + \beta_8 * \text{EXP } IV2^3 + \beta_9 * \ln 1/IV2 + \beta_{10} * \text{EXP } 1/IV2$
1	Stepwise	Morto	$A = \beta_0 + \beta_1 * IV + \beta_2 * IV^2 + \beta_3 * IV^3 + \beta_4 * IV^4 + \beta_5 * IV^5 + \beta_6 * IV2^2 + \beta_7 * IV2^3 + \beta_8 * IV2^4 + \beta_9 * IV2^5 + \beta_{10} * \ln IV + \beta_{11} * \ln IV2 + \beta_{12} * \text{EXP } IV^2 + \beta_{13} * \text{EXP } IV^3$
2	SVM	Morto	$A = \beta_0 + \beta_1 * IV + \beta_2 * IV^2 + \beta_3 * \text{EXP } IV^5 + \beta_4 * \sqrt{IV^5} + \beta_5 * \frac{1}{IV2} + \beta_6 * \frac{1}{IV^4} + \beta_7 * \frac{1}{IV2^3} + \beta_8 * \frac{1}{IV^3} * 1/IV2 + \beta_9 * \frac{1}{IV^4} * 1/IV$
3	RF	Morto	$A = \beta_0 + \beta_1 * IV + \beta_2 * \text{EXP } IV^3 + \beta_3 * \text{EXP } IV2^5 + \beta_4 * 1/IV2 + \beta_5 * 1/IV3^5 + \beta_6 * IV * IV2 + \beta_7 * IV * IV3 + \beta_8 * IV2 * IV3$

Em que: A: ataque por parcela (% 0,045 ha⁻¹); β_n : coeficientes do modelo; IV: índices de vegetação; ln: logaritmo natural com base na constante e (2,71828182845904); EXP: função exponencial natural.

Tabela 7: 38 - Matriz de confusão do ortomosaico classificado pelo método Maxver para a área 1, com amostras de 1,5m.

Classe	Atacadas	Não atacadas	Mortas	Solo	Total	Acurácia	Kappa
Atacadas	63	0	0	0	63	1,0000	
Não atacadas	9	75	3	0	87	0,8621	
Mortas	11	3	9	6	29	0,3103	
Solo	16	46	4	54	120	0,4500	
Total	99	124	16	60	299		
Acurácia	0,6364	0,6048	0,5625	0,90	598	0,6722	
Kappa							0,5472

Tabela 7: 39 - Matriz de confusão da composição 1 classificada pelo método Maxver para a área 1, com amostras de 1,5m.

Classe	Atacadas	Não atacadas	Mortas	Solo	Total	Acurácia	Kappa
Atacadas	60	8	2	0	70	0,8571	
Não atacadas	10	68	2	1	81	0,8395	
Mortas	6	2	4	2	14	0,2857	
Solo	23	46	8	57	134	0,4254	
Total	99	124	16	60	299		
Acurácia	0,6061	0,5484	0,2500	0,9500	598	0,6321	
Kappa							0,4874

Tabela 7: 40 - Matriz de confusão da composição 2 classificada pelo método Maxver para a área 1, com amostras de 1,5m.

Classe	Atacadas	Não atacadas	Mortas	Solo	Total	Acurácia	Kappa
Atacadas	68	3	0	0	71	0,9577	
Não atacadas	6	95	3	0	104	0,9135	
Mortas	14	3	12	5	34	0,3529	
Solo	11	23	1	55	90	0,6111	
Total	99	124	16	60	299		
Acurácia	0,6869	0,7661	0,7500	0,9167	598	0,7692	
Kappa							0,6753

Tabela 7: 41 - Matriz de confusão da composição 3 classificada pelo método Maxver para a área 1, com amostras de 1,5m.

Classe	Atacadas	Não atacadas	Mortas	Solo	Total	Acurácia	Kappa
Atacadas	61	12	3	1	77	0,7922	
Não atacadas	14	76	3	2	95	0,8000	
Mortas	4	6	8	6	24	0,3333	
Solo	20	30	2	51	103	0,4951	
Total	99	124	16	60	299		
Acurácia	0,6162	0,6129	0,5000	0,8500	598	0,6555	
Kappa							0,5145

Tabela 7: 42 - Matriz de confusão da composição 4 classificada pelo método Maxver para a área 1, com amostras de 1,5m.

Classe	Atacadas	Não atacadas	Mortas	Solo	Total	Acurácia	Kappa
Atacadas	58	15	0	0	73	0,7945	

Não atacadas	44	96	11	0	151	0,6358	
Mortas	8	12	6	0	26	0,2308	
Solo	11	28	3	10	52	0,1923	
Total	121	151	20	10	302		
Acurácia	0,4793	0,6358	0,3000	1	598	0,5629	
Kappa							0,3189

Tabela 7: 43 - Matriz de confusão composição 5 classificada pelo método Maxver para a área 1, com amostras de 1,5m.

Classe	Atacadas	Não atacadas	Mortas	Solo	Total	Acurácia	Kappa
Atacadas	64	14	2	0	80	0,8000	
Não atacadas	38	107	5	0	150	0,7133	
Mortas	10	5	10	1	26	0,3846	
Solo	9	25	3	9	46	0,1957	
Total	121	151	20	10	302		
Acurácia	0,5289	0,7086	0,5000	0,9000	598	0,6291	
Kappa							0,4158

Tabela 7: 44 - Matriz de confusão do ortomosaico classificado pelo método *Random Tree* para a área 1, com amostras de 1,5m.

Classe	Atacadas	Não atacadas	Mortas	Solo	Total	Acurácia	Kappa
Atacadas	86	10	0	0	96	0,8958	
Não atacadas	8	103	2	0	113	0,9115	
Mortas	1	3	13	0	17	0,7647	
Solo	4	8	1	60	73	0,8219	
Total	99	124	16	60	299		
Acurácia	0,8687	0,8306	0,8125	1	598	0,8763	
Kappa							0,8193

Tabela 7: 45 - Matriz de confusão da composição 1 classificada pelo método *Random Tree* para a área 1, com amostras de 1,5m.

Classe	Atacadas	Não atacadas	Mortas	Solo	Total	Acurácia	Kappa
Atacadas	77	24	0	0	101	0,7624	
Não atacadas	18	96	4	0	118	0,8136	
Mortas	2	1	11	1	15	0,7333	
Solo	2	3	1	59	65	0,9077	
Total	99	124	16	60	299		
Acurácia	0,7778	0,7742	0,6875	0,9833	598	0,8127	
Kappa							0,7238

Tabela 7: 46 - Matriz de confusão da composição 2 classificada pelo método *Random Tree* para a área 1, com amostras de 1,5m.

Classe	Atacadas	Não atacadas	Mortas	Solo	Total	Acurácia	Kappa
Atacadas	76	9	0	0	85	0,8941	
Não atacadas	13	109	3	2	127	0,8583	
Mortas	3	3	11	1	18	0,6111	
Solo	7	3	2	57	69	0,8261	
Total	99	124	16	60	299		

Tabela 7: 67 - Matriz de confusão composição 5 classificado pelo método *Random Tree* para a área 2, com amostras de 0,5m.

Classe	Atacadas	Não atacadas	Mortas	Solo	Total	Acurácia	Kappa
Atacadas	93	14	1	0	108	0,8611	
Não atacadas	12	152	5	1	170	0,8941	
Mortas	3	6	5	0	14	0,3571	
Solo	0	2	0	9	11	0,8182	
Total	108	174	11	10	303		
Acurácia	0,8611	0,8736	0,4545	0,9000	604	0,8548	
Kappa							0,7350

Tabela 7: 68 - Matriz de confusão do ortomosaico classificado pelo método SVM para a área 2, com amostras de 0,5m.

Classe	Atacadas	Não atacadas	Mortas	Solo	Total	Acurácia	Kappa
Atacadas	87	4	0	0	91	0,9560	
Não atacadas	11	170	1	1	183	0,9290	
Mortas	9	0	9	0	18	0,5000	
Solo	0	0	1	9	10	0,9000	
Total	107	174	11	10	302		
Acurácia	0,8131	0,9770	0,8182	0,9000	604	0,9106	
Kappa							0,8347

Tabela 7: 69 - Matriz de confusão da composição 1 classificado pelo método SVM para a área 2, com amostras de 0,5m.

Classe	Atacadas	Não atacadas	Mortas	Solo	Total	Acurácia	Kappa
Atacadas	83	9	3	0	95	0,8737	
Não atacadas	14	153	5	2	174	0,8793	
Mortas	12	11	3	0	26	0,1154	
Solo	0	3	0	8	11	0,7273	
Total	109	176	11	10	306	0,0000	
Acurácia	0,7615	0,8693	0,2727	0,8	604	0,8072	
Kappa							0,6545

Tabela 7: 70 - Matriz de confusão da composição 2 classificado pelo método SVM para a área 2, com amostras de 0,5m.

Classe	Atacadas	Não atacadas	Mortas	Solo	Total	Acurácia	Kappa
Atacadas	81	9	1	0	91	0,8901	
Não atacadas	14	124	0	0	138	0,8986	
Mortas	9	4	8	0	21	0,3810	
Solo	5	39	2	10	56	0,1786	
Total	109	176	11	10	306		
Acurácia	0,7431	0,7045	0,7273	1	604	0,7288	
Kappa							0,5669

Tabela 7: 71 - Matriz de confusão da composição 3 classificado pelo método SVM para a área 2, com amostras de 0,5m.

Classe	Atacadas	Não atacadas	Mortas	Solo	Total	Acurácia	Kappa
Atacadas	87	9	3	0	99	0,8788	
Não atacadas	13	159	0	3	175	0,9086	

Tabela 7: 96 - Matriz de confusão da composição 4 classificada pelo método Maxver para a área 2, com amostras de 1,5m.

Classe	Atacadas	Não atacadas	Mortas	Solo	Total	Acurácia	Kappa
Atacadas	45	9	4	0	58	0,7759	
Não atacadas	46	116	4	2	168	0,6905	
Mortas	1	4	2	0	7	0,2857	
Solo	18	48	1	8	75	0,1067	
Total	110	177	11	10	308		
Acurácia	0,4091	0,6554	0,1818	0,8000	604	0,5552	
Kappa							0,2715

Tabela 7: 97 - Matriz de confusão da composição 5 classificada pelo método Maxver para a área 2, com amostras de 1,5m.

Classe	Atacadas	Não atacadas	Mortas	Solo	Total	Acurácia	Kappa
Atacadas	50	13	2	0	65	0,7692	
Não atacadas	23	98	0	4	125	0,7840	
Mortas	27	39	8	0	74	0,1081	
Solo	10	27	1	6	44	0,1364	
Total	110	177	11	10	308		
Acurácia	0,4545	0,5537	0,7273	0,6000	604	0,5260	
Kappa							0,3010

Tabela 7: 98 - Matriz de confusão do ortomosaico classificado pelo método *Random Tree* para a área 2, com amostras de 1,5m.

Classe	Atacadas	Não atacadas	Mortas	Solo	Total	Acurácia	Kappa
Atacadas	67	21	3	0	91	0,7363	
Não atacadas	30	153	3	7	193	0,7927	
Mortas	13	3	4	0	20	0,2000	
Solo	0	1	1	3	5	0,6000	
Total	110	178	11	10	309		
Acurácia	0,6091	0,8596	0,3636	0,3000	604	0,7346	
Kappa							0,5017

Tabela 7: 99 - Matriz de confusão da composição 1 classificada pelo método *Random Tree* para a área 2, com amostras de 1,5m.

Classe	Atacadas	Não atacadas	Mortas	Solo	Total	Acurácia	Kappa
Atacadas	63	21	0	1	85	0,7412	
Não atacadas	24	124	5	3	156	0,7949	
Mortas	19	28	5	2	54	0,0926	
Solo	3	2	1	4	10	0,4000	
Total	109	175	11	10	305		
Acurácia	0,5780	0,7086	0,4545	0,4000	604	0,6426	
Kappa							0,4038

Tabela 7: 100 - Matriz de confusão da composição 2 classificada pelo método *Random Tree* para a área 2, com amostras de 1,5m.

Classe	Atacadas	Não atacadas	Mortas	Solo	Total	Acurácia	Kappa
--------	----------	--------------	--------	------	-------	----------	-------

Atacadas	72	18	3	1	94	0,7660	
Não atacadas	26	141	2	1	170	0,8294	
Mortas	10	9	6	1	26	0,2308	
Solo	3	8	0	7	18	0,3889	
Total	111	176	11	10	308		
Acurácia	0,6486	0,8011	0,5455	0,7000	604	0,7338	
Kappa							0,5327

Tabela 7: 101 - Matriz de confusão da composição 3 classificada pelo método *Random Tree* para a área 2, com amostras de 1,5m.

Classe	Atacadas	Não atacadas	Mortas	Solo	Total	Acurácia	Kappa
Atacadas	69	29	2	0	100	0,6900	
Não atacadas	21	129	3	2	155	0,8323	
Mortas	15	9	6	1	31	0,1935	
Solo	6	10	0	7	23	0,3043	
Total	111	177	11	10	309		
Acurácia	0,6216	0,7288	0,5455	0,7000	604	0,6828	
Kappa							0,4628

Tabela 7: 102 - Matriz de confusão da composição 4 classificada pelo método *Random Tree* para a área 2, com amostras de 1,5m.

Classe	Atacadas	Não atacadas	Mortas	Solo	Total	Acurácia	Kappa
Atacadas	65	22	3	1	91	0,7143	
Não atacadas	29	126	1	2	158	0,7975	
Mortas	16	29	6	3	54	0,1111	
Solo	1	1	1	4	7	0,5714	
Total	111	178	11	10	310		
Acurácia	0,5856	0,7079	0,5455	0,4000	604	0,6484	
Kappa							0,4094

Tabela 7: 103 - Matriz de confusão composição 5 classificada pelo método *Random Tree* para a área 2, com amostras de 1,5m.

Classe	Atacadas	Não atacadas	Mortas	Solo	Total	Acurácia	Kappa
Atacadas	69	22	2	0	93	0,7419	
Não atacadas	30	132	4	2	168	0,7857	
Mortas	11	9	5	1	26	0,1923	
Solo	0	11	0	7	18	0,3889	
Total	110	174	11	10	305		
Acurácia	0,6273	0,7586	0,4545	0,7000	604	0,6984	
Kappa							0,4715

Tabela 7: 104 - Matriz de confusão do ortomosaico classificado pelo método SVM para a área 2, com amostras de 1,5m.

Classe	Atacadas	Não atacadas	Mortas	Solo	Total	Acurácia	Kappa
Atacadas	62	7	1	0	70	0,8857	
Não atacadas	34	161	3	10	208	0,7740	
Mortas	13	10	7	0	30	0,2333	
Solo	0	0	0	0	0		
Total	109	178	11	10	308		

