



UNIVERSIDADE DE BRASÍLIA
FACULDADE DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA FLORESTAL
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIAS FLORESTAIS

**USO DE DRONE PARA IDENTIFICAR A DOMINÂNCIA DE GRAMÍNEAS INVASORAS
E VEGETAÇÃO NATIVA EM ÁREAS DE RESTAURAÇÃO DO CERRADO**

Marcos Vinicius Rezende de Ataíde

Orientador: Dr. Daniel Luis Mascia Vieira

Brasília Distrito Federal – Brasil
Janeiro de 2024

FACULDADE DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA FLORESTAL
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIAS FLORESTAIS

MARCOS VINICIUS REZENDE DE ATAÍDE

**USO DE DRONE PARA IDENTIFICAR A DOMINÂNCIA DE GRAMÍNEAS INVASORAS
E VEGETAÇÃO NATIVA EM ÁREAS DE RESTAURAÇÃO DO CERRADO**

Dissertação de mestrado submetida ao Programa de Pós-Graduação em Ciências Florestais do Departamento de Engenharia Florestal da Universidade de Brasília como parte dos requisitos necessários para a obtenção do grau de Mestre em Ciências Florestais.

ORIENTADOR: DANIEL LUÍS MASCIA VIEIRA

DISSERTAÇÃO DE MESTRADO EM CIÊNCIAS FLORESTAIS

BRASÍLIA/ DF, 14 DE janeiro DE 2024

AGRADECIMENTOS

Acredito que todos são capazes de construir excelentes trabalhos principalmente quando elaborado pela união e conhecimento de várias pessoas.

Acredito que todos merecem a oportunidade de mostrar que são capazes independente dos obstáculos e dificuldades que surgem no caminho. Neste trabalho obstáculos e dificuldades foram superadas e espero que sirvam de exemplo e esperança para todos.

Agradeço ao meu orientador, Dr. Daniel Vieira, que me deu suporte durante toda a minha trajetória acadêmica, seja repassando o seu conhecimento seja tendo paciência as condições adversas que foram aparecendo no caminho.

Agradeço a paciência e todo ensinamento de como construir um bom trabalho, mostrar os erros e acertos assim como as oportunidades de adquirir experiências começando no Mato Grosso e terminando em Alto Paraíso – GO.

Agradeço ao Dr. Aldicir pela confiança em ter me cedido a única bolsa do projeto, pelas conversas e aprendizados que vivenciamos em campo.

Agradeço ao Serginho pelo aprendizado e a carteirinha de habilitação para voo em drone

Agradeço ao Dudu pelas caronas e risadas todos os dias.

Agradeço as anjas Tâmilis Rocha e Silvia Rodrigues que me guiaram na estrada com empatia e confiança. Agradeço a elas todo ensinamento e aprendizado.

Agradeço a todos que na hora mais escura acenderam a luz e me receberam de mãos abertas em nossa salinha de bolsistas.

Por fim agradeço a Deus por chegar até aqui e aos Exus pelos caminhos abertos.

*“Não importe o que aconteça,
continue a nadar, continue a nadar”*

Doris, Nemo

SUMÁRIO

1. INTRODUÇÃO	3
2. OBJETIVOS	5
2. MATERIAL E MÉTODOS	6
2.1. Áreas de restauração e medidas	7
2.1.2. Levantamento de campo	7
2.2. Aquisição e processamento de imagens multiespectrais	8
2.3. Modelo de Altura (CHM)	9
2.4. Índices de Vegetação	11
2.5. Textura – GLCM	12
2.6. Construção do conjunto de dados	12
2.7. Definição dos grupos de espécies dominantes	13
2.8. Random Forest (Classificação)	14
2.9. Árvore de decisão	15
2.10. Regressão Random Forest	16
3. RESULTADOS	17
3.1. Classificação da acurácia e erro na distinção entre as dominâncias de gramíneas exóticas	17
3.2. Variáveis de importância na classificação Random Forest	19
3.3. Classificação e regressão CART (Árvore de decisão)	20
3.4. Análises exploratórias das variáveis preditoras	21
3.5. Cobertura vegetal de gramíneas exóticas invasoras	21
3.6. Desempenho das variáveis preditoras	22
4. DISCUSSÃO	23
4.1. Variáveis preditoras (Classificação RF)	24
4.2. Distinção a nível de espécies (Árvore de decisão)	26
4.3. Previsão da cobertura de gramíneas exóticas invasoras	27
5. CONCLUSÕES	28
6. REFERÊNCIAS BIBLIOGRÁFICAS	28

RESUMO

A restauração ecológica de ecossistemas campestres e savânicos em regiões tropicais tem como principal desafio a competição de gramíneas exóticas invasoras com espécies nativas. A identificação e mapeamento da cobertura de espécies invasoras é indispensável para dar suporte às ações de manutenção em áreas de restauração ecológica. Atualmente, os levantamentos de campo para monitorar a vegetação indesejável em áreas de restauração passam por uma mudança de paradigma com crescente uso de imagens adquiridas em câmeras a bordo de VANTs (Veículos Aéreo Não Tripulados), utilizadas como entrada em algoritmos de aprendizado de máquina (*machine learning*), mostrando eficazes na classificação de alvos na superfície terrestre, como gramíneas exóticas invasoras em ambientes campestres e savânicos. O presente estudo teve o objetivo de identificar manchas de gramíneas exóticas invasoras e nativas em áreas de restauração ecológica de savana no bioma Cerrado, a partir de imagens adquiridas por VANT e da aplicação de técnicas de aprendizagem de máquina. A área de estudo está localizada dentro do Parque Nacional da Chapada dos Veadeiros. Foram realizadas amostragens da cobertura vegetal por espécie em campo e os voos com um *drone DJI Phantom 4 Pro*, com uma câmera 1'' CMOS (*Complementary Metal Oxide Semiconductor*), para aquisição das imagens no espectro visível ao infravermelho próximo. Com os dados de cobertura coletados em campo, as áreas foram classificadas de acordo com a espécie que dominava pelo menos 40% da cobertura da parcela. As imagens foram analisadas para obter uma correta classificação das parcelas de acordo com a espécie dominante. Foi utilizado o algoritmo *Random Forest* (RF) seguido do método estatístico *stepwise* para diminuição da colineariedade das variáveis. A árvore de decisão foi construída com o modelo de classificação *Random Forest* e o *CART* para uma representação visual das características distintivas entre as espécies. Foram utilizadas para a construção do modelo as seguintes variáveis: modelo de altura de dossel (CHM), índices de vegetação e métricas de textura, as quais foram sobrepostas, gerando um raster uma única camada contendo todas variáveis. Em cada array foram plotados aleatoriamente 50 pontos para amostragem de valores que foram subdivididos em treinamento (80%) e validação (20%), utilizados nos algoritmos de classificação *Random* modelos de classificação para cada objetivo mostraram boas precisões globais de mapeamento, superiores a 0,6 (60%) para ambos os algoritmos. A análise das variáveis de importância de acordo com os resultados da classificação *Random Forest* revelou uma forte correlação entre a variação das respostas espectrais e as diferenças na estrutura celular das folhas e nos pigmentos fotossintéticos, como evidenciado pelos índices de vegetação, com maior desempenho na separação de parcelas com diferentes espécies dominantes: Índice de Vegetação de Clorofila Verde, Índice de Vegetação Atmosfericamente Resistente (GCI, ARVI, RED_EDGE). Enquanto para a cobertura as principais variáveis preditoras foram: NIR, BLUE e RED EDGE refletindo que as características morfológicas e fisiológicas das gramíneas exóticas invasoras são características essenciais para previsões da cobertura desta vegetação. O uso de variáveis derivadas de imagens multiespectrais adquiridas com câmeras em drones mostrou-se promissor para identificar áreas dominadas por espécies invasoras e nativas, prever a cobertura vegetal de gramíneas invasoras em ambientes em processo de restauração ecológica em campos e savanas no bioma Cerrado.

Palavras chave: Gramíneas exóticas invasoras, Aprendizado de máquina, Áreas degradadas, Sensoriamento remoto, Floresta aleatória, Monitoramento de restauração

ABSTRACT

The main challenge in the ecological restoration of grassland and savannah ecosystems in tropical regions is the competition between invasive exotic grasses and native species. Identifying and mapping the cover of invasive species is essential to support maintenance actions in ecological restoration areas. Currently, field surveys to monitor undesirable vegetation in restoration areas are undergoing a paradigm shift with the increasing use of images acquired from cameras on board UAVs (Unmanned Aerial Vehicles), used as input in machine learning algorithms, proving effective in classifying targets on the ground surface, such as invasive exotic grasses in grassland and savannah environments. The aim of this study was to identify patches of invasive exotic and native grasses in savannah ecological restoration areas in the Cerrado biome, based on images acquired by UAV and the application of machine learning techniques. The study area is located within the Chapada dos Veadeiros National Park. Vegetation cover was sampled by species in the field and flights were made with a DJI Phantom 4 Pro drone with a 1" CMOS (Complementary Metal Oxide Semiconductor) camera to acquire images in the visible to near infrared spectrum. With the cover data collected in the field, the areas were classified according to the species that dominated at least 40% of the plot's cover. The images were analyzed in order to correctly classify the plots according to the dominant species. The Random Forest (RF) algorithm was used, followed by the stepwise statistical method to reduce the collinearity of the variables. The decision tree was built using the Random Forest classification model and CART for a visual representation of the distinctive characteristics between the species. The following variables were used to build the model: canopy height model (CHM), vegetation indices and texture metrics, which were superimposed, generating a single layer raster containing all the variables. In each array, 50 points were randomly plotted to sample values that were subdivided into training (80%) and validation (20%), used in the classification algorithms. Random classification models for each objective showed good overall mapping accuracies, greater than 0.6 (60%) for both algorithms. Analysis of the variables of importance according to the results of the Random Forest classification revealed a strong correlation between the variation in spectral responses and differences in leaf cell structure and photosynthetic pigments, as evidenced by the vegetation indices with the best performance in separating plots with different dominant species: Green Chlorophyll Vegetation Index, Atmospherically Resistant Vegetation Index (GCI, ARVI, RED_EDGE). While for cover the main predictor variables were: NIR, BLUE and RED_EDGE reflecting that the morphological and physiological characteristics of invasive exotic grasses are essential characteristics for predicting the cover of this vegetation. The use of variables derived from multispectral images acquired with drone cameras proved promising for identifying areas dominated by invasive and native species, predicting the vegetation cover of invasive grasses in environments undergoing ecological restoration in grasslands and savannas in the Cerrado biome.

Keywords: Invasive exotic grasses, Machine learning, Degraded areas, Remote sensing, Random Forest, Restoration monitoring

1. INTRODUÇÃO

A restauração ecológica de ecossistemas savânicos e campestres, especialmente em regiões tropicais, representa um desafio prático e científico de grande magnitude (Pilon et al., 2023). Para tanto, métodos como a transferência de feno, a transposição da camada superficial de solo, a semeadura direta e a condução da regeneração natural (Le stradic et al., 2014., Ferreira et al., 2015., Le stradic et al., 2016., Pellizzaro et al., 2017., Pilon et al., 2018., Cava et al., 2018., Pilon et al., 2019., Assis et al., 2020) são promissores no reestabelecimento da vegetação nativa e vem se aprimorando à medida que o conhecimento da ecologia dos ecossistemas e das espécies nativas evoluem (Schmidt et al., 2019., Sampaio et al. 2019., Pilon et al., 2023). No entanto, obter sucesso na restauração desses ambientes é desafiador diante da forte presença de espécies exóticas invasoras (Coutinho et al., 2019).

Espécies de gramíneas de origem africana que foram selecionadas e melhoradas geneticamente são amplamente utilizadas em pastagens no Brasil, devido sua alta produtividade mesmo em solos de baixa e média fertilidade (Parsons 1972., Foxcroft et al., 2010). Como consequência, essas gramíneas são capazes de invadir áreas naturais e também reinfestar áreas manejadas em processo de restauração ecológica (Sampaio et al., 2018; Pilon et al., 2022). No Cerrado, as espécies exóticas com maior impacto são *Andropogon gayanus* Kunth, *Urochloa decumbens* CV. Basilisk, *Hyparrhenia rufa* (Nees) Stapf e *Melinis minutiflora* P. Beauv. (Pilon et al., 2020). Essas espécies são conhecidas por suas características oportunistas, como a alta produção de sementes, (Goodale et al., 2018) rápido crescimento, alto potencial competitivo, rápida colonização e alta adaptabilidade a diversas condições ambientais (Ens et al., 2015., Goodale et al., 2018., Duarte et al., 2019., Zeni et al., 2019., Weidlich et al., 2020). Devido a essas características, gramíneas exóticas são capazes de inibir a regeneração das espécies nativas e dominar as áreas (Pivello et al., 1999., Hoffmann et al., 2008). Dessa forma, o monitoramento e o manejo das gramíneas exóticas invasoras antes e durante as atividades de restauração de savanas e campos é fundamental para promover o estabelecimento da vegetação nativa no Cerrado (Coutinho et al., 2019., Giles et al., 2021).

O monitoramento de áreas em restauração envolve amostragens em campo para mensurar indicadores ecológicos como: cobertura do dossel (em formações florestais) e cobertura do solo por vegetação (em formações campestres e savânicas), densidade de regenerantes nativos e número de espécies nativas (Sousa et al., 2017). Contudo, os avanços tecnológicos no uso de Sensoriamento Remoto (SR) ganham destaque no monitoramento de áreas em processo de restauração, devido ao aprimoramento constante das resoluções espaciais, espectrais e temporais de imagens e sensores remotos, somado a alta capacidade computacional de armazenar dados e o rápido processamento dos

123 mesmos, tornando o SR uma vantajosa ferramenta para monitorar a vegetação (Fassnacht et al., 2016.,
124 Kattenborn et al., 2021).

125 Os VANTs (Veículos Aéreos Não Tripulados), destacam-se pelo seu fácil manuseio e o
126 fornecimento de imagens com resoluções espaciais menores que 1 centímetro, permitindo detecção de
127 detalhes finos da vegetação (Tay et al., 2018., Rominger et al., 2019). Possuem capacidade de adquirir
128 dados de diferentes maneiras, utilizando diversos sensores capazes de cobrir uma ampla gama de
129 sistemas de percepção da vegetação, incluindo espectros visíveis, infravermelhos e térmicos. Por isso,
130 o uso de VANTs pode se tornar uma abordagem útil para identificar a vegetação em nível de espécies
131 (Adam et al., 2010). Produtos derivados das imagens provenientes de sensores RGB, Multiespectral e
132 Hiperespectral podem gerar diversas variáveis importantes para detecção e distinção da vegetação
133 invasora.

134 Imagens captadas por sensores acoplados em drones têm sido utilizadas para detectar e mapear
135 gramíneas exóticas invasoras e também espécies nativas (Kapos et al., 2020., Kedia et al., 2021.,
136 Weisberg et al., 2021., Bergamo et al., 2023., Madeppa et al., 2023). Essa abordagem é viabilizada pela
137 interação única de cada planta com a radiação eletromagnética que reflete suas propriedades físicas e
138 químicas (Pazoni et al., 2012) e são acessadas através dos índices de vegetação (Bradley et al., 2014;
139 Xu et al., 2022; Madeppa, 2023; Saini, 2023). Por exemplo, as características da planta, como o
140 tamanho, a densidade e a composição estrutural dos ramos e folhas, juntamente com variações nas
141 taxas de pigmentação (clorofila e carotenóides), definem a absorção espectral e a reflectância de cada
142 espécie de planta (Pazoni et al., 2012). Isso foi observado na distinção entre as gramíneas exóticas
143 invasoras, *Melinos repens*, e, *Uroclhoa humidicola*, em fragmentos de savana. Entre os vários atributos
144 citados que diferenciam a reflectância entre as espécies, observou-se que a reflectância foi mais elevada
145 para *M. repens* na região vermelha (provavelmente devido à cor das flores e à pigmentação das folhas,
146 respectivamente), bem como uma ligeira inclinação para o infravermelho, enquanto *U. humidicola*
147 apresentou menor absorção no vermelho, permitindo assim a distinção entre as gramíneas (Pfitzner et
148 al., 2022).

149 Essa variação entre as espécies vegetais possibilita sua identificação e diferenciação. Além de
150 métricas relacionadas à reflectância, outra métrica bastante utilizada para detecção de gramíneas
151 exóticas invasoras é o *Modelo de Altura de Copa* (MAC) que está relacionada à estrutura da vegetação.
152 O MAC não é derivado da interação da radiação eletromagnética com as plantas, mas sim da
153 interpretação das informações de elevação obtidas por meio dos produtos topográficos gerados pelo
154 drone como Modelo Digital do Terreno (MDT) e o Modelos Digital de Superfície (MDS). Por fim,
155 imagens de alta resolução obtidas com o drone podem ser processadas para obtenção de descritores de
156 textura que estão relacionados às variações de cinza e também contribuem para estimativas e

157 caracterização da vegetação. Dados de reflectância, estrutura e textura são utilizados em muitos estudos
158 de diferentes formações de ecossistemas abertos, sendo utilizados para estimar biomassa acima do solo
159 (Sesnie et al., 2018; Karila et al., 2022), estimar cobertura (Sesnie et al., 2018), auxiliar em análises de
160 diversidade de espécies (Getzin et al., 2012; Rose et al., 2023) e distinção ou classificação de espécies
161 (Fisher et al., 2018., Rossi et al., 2020., White et al., 2022., Dixon et al., 2014., Wu et al., 2017.,
162 Fassnacht et al., 2021., Sankey et al., 2021., Kozhoridze et al., 2016).

163 A combinação de índices de vegetação com métricas estruturais (MAC) e de textura resulta em
164 um banco de dados multidimensional e complexo que exige métodos de modelagem robustos para
165 obtenção de resultados confiáveis. Os algoritmos de aprendizagem de máquinas são ferramentas
166 poderosas que se destacam na criação de modelos de dados complexos e vem sendo utilizado para o
167 monitoramento de diferentes tipos de vegetação (Costa et al., 2023) assim como para predição da
168 biomassa e cobertura vegetal em ecossistemas abertos (Sesnie et al., 2018). Para mitigar possíveis
169 vieses no uso de algoritmos específicos, alguns autores recomendam a utilização de múltiplos
170 algoritmos de *machine learning* (Lawrence et al., 2015) tais como *Random Forest*, a Regressão
171 *Random Forest* e o CART (Classificação e Regressão de Árvores) que são frequentemente empregados
172 em aplicações de sensoriamento remoto. Embora os algoritmos de aprendizagem profunda possam
173 superar o aprendizado de máquina, eles exigem conhecimento profundo de programação e alta
174 capacidade de processamento, resultando em custos mais elevados.

175 No presente estudo, optamos por usar aprendizado de máquina para distinção de espécies de
176 gramíneas invasoras e nativas, e para estimar a cobertura de espécies exóticas em áreas submetidas à
177 restauração ecológica no Parque Nacional Chapada dos Veadeiros, devido à sua robustez e
178 disponibilidade em plataformas de domínio público para ajudar os gestores de recursos naturais a lidar
179 com a invasão de espécies de gramíneas exóticas na restauração ecológica e no controle de invasões
180 de áreas naturais.

181

182 2. OBJETIVOS

183

184 ● Distinguir manchas com dominância de diferentes espécies exóticas ou com dominância de espécies
185 nativas através de métricas derivadas de imagens multiespectrais de alta resolução adquiridas por
186 câmeras acopladas em drone.

187 **Hipótese:** A distinção entre as áreas dominadas por diferentes espécies será viável principalmente com
188 base nas diferenças entre a pigmentação vegetal comumente usada para identificar plantas invasoras
189 com base no conteúdo de clorofila (Bradley et al., 2013) como também por diferenças nos padrões de
190 crescimento e altura (Hunt et al., 2004). Em vista disso, acredita-se que as bandas da região do visível

191 e seus índices derivados, métricas de altura com respostas espectrais distintas terão maior desempenho
192 em discriminar a dominância dessas espécies.

193 • Estimar a porcentagem de cobertura de gramíneas exóticas invasoras em áreas de restauração
194 ecológica em savanas e campos

195 **Hipótese:** Acredita-se que as bandas do Infravermelho próximo (*NIR*), do Azul e da borda do
196 Vermelho (*red edge*), que são suscetíveis a fatores como a absorção de clorofila, mudanças na saúde
197 da vegetação e estrutura morfológica, terão melhor desempenho em prever a cobertura vegetal. Estes
198 fatores encontram-se respaldados na literatura em trabalhos com análises da cobertura vegetal. (Féret
199 et al., 2008., Pettorelli et al., 2014).

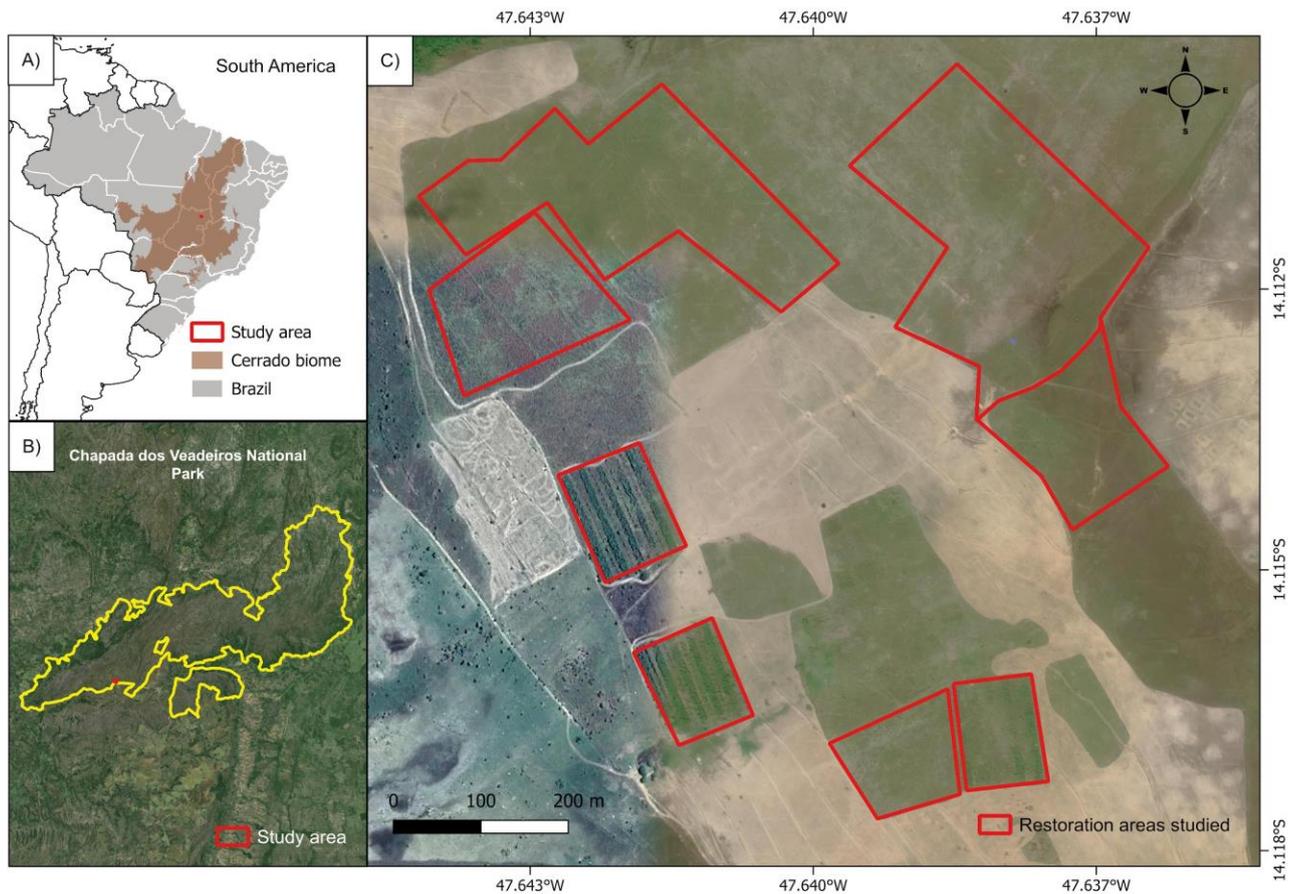
200 **2. MATERIAL E MÉTODOS**

201

202 Este estudo foi conduzido em áreas de restauração ecológica no Parque Nacional da Chapada dos
203 Veadeiros (PNCV), no município de Alto Paraíso de Goiás, estado de Goiás. A região é caracterizada pelo
204 clima AW na classificação de Köppen, com verões quentes e chuvosos, e invernos secos (MMA, 2009).
205 A temperatura média anual varia de 20° a 27°C e a precipitação pluviométrica 1.617,8 mm. A altitude
206 varia de 400 a 1.676 metros. A vegetação original na área de estudo era de savana aberta com manchas
207 de campos e campo de murundu e foram convertidas para pastagens pelo menos 30 anos antes das
208 intervenções de restauração, especialmente de braquiária. Desde 2012, experimentos de restauração
209 em escala operacional foram conduzidos nesta região do PNCV. De maneira geral todas as áreas
210 seguiram um modelo básico de intervenção que consistiu na queima e na gradagem do solo, para
211 diminuir a dominância da espécie exótica e favorecer o estabelecimento das espécies nativas. Após o
212 preparo do solo, as áreas foram restauradas por semeadura direta de cerca de 12 espécies de gramíneas,
213 13 de arbustos e 50 de árvores nativas (Pellizzaro et al., 2017). Em solos com maior fertilidade e
214 drenagem, e com menor controle de espécies exóticas pré- e pós-semeadura, gramíneas exóticas com
215 alto potencial invasor reinfestam e dominam as áreas. Áreas mais bem manejadas e com menor
216 fertilidade e drenagem do solo são dominadas por espécies nativas. Nas áreas de restauração do PNCV
217 há de 50% a 65 % de cobertura de nativas (Sampaio et al., 2019).

218

219



220

221 **Figura 1:** Localização da área de estudo no Parque Nacional Chapada dos Veadeiros, município de
 222 Alto Paraíso, estado de Goiás. Projeção UTM, zona 23S, Datum WGS 84.

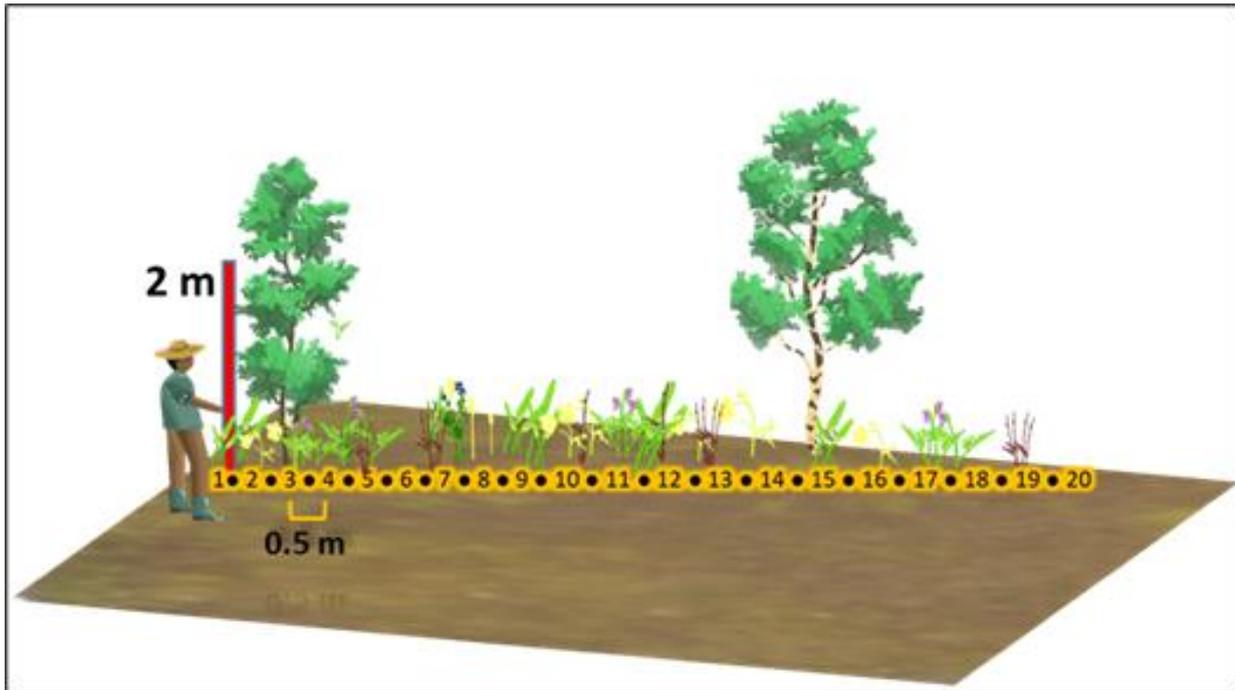
223 **2.1. Áreas de restauração e medidas**

224 **2.1.2. Levantamento de campo**

225

226

227 A amostragem foi realizada em campo no final da estação chuvosa, em março de 2022. Para a
 228 amostragem da cobertura do solo por vegetação foi utilizado o método de interceptação de pontos em
 229 linhas ao longo de um transecto de 20m. Ao longo do transecto, a cada 0.5m uma vareta de 2m de
 230 altura foi posicionada verticalmente (Figura 2) e todas as espécies que tocavam a vareta foram
 231 registradas (Itt, 1996). Em cada um dos 8 polígonos de restauração (Figura 1) foram distribuídos
 232 aleatoriamente cinco transectos, totalizando uma área amostral de 800 m lineares. Para aquelas
 233 espécies em que não foi possível a identificação em campo, o material botânico foi coletado e
 234 depositado no Herbário da Empresa Brasileira de Pesquisa Agropecuária (Embrapa) Recursos
 235 Genéticos e Biotecnologia e no Herbário da Universidade de Brasília, e posteriormente identificadas
 236 por especialistas. A porcentagem de cobertura do solo da espécie foi estimada para cada transecto a
 partir do número de pontos em que a vareta tocou a espécie dividido pelo número total de 40 pontos.



237

238 **Figura 2:** Ilustração da metodologia de amostragem da cobertura vegetal interceptação de pontos em
 239 linha

240

241

242

243

2.2. Aquisição e processamento de imagens multiespectrais

244

245

246

247

248

249

250

251

252

253

254

255

256

257

258

259

As imagens foram captadas no mês de março de 2022 em 8 polígonos nomeados de acordo com os anos da restauração e possuem diferentes tamanhos: 2012_1 (1 ha), 2012_2 (1 ha), 2012_2 (1 ha), 2015_1 (2,90ha), 2015_2(1,6), 2022_1 e 2022_2 (3.17 ha) (Figura 3). O drone é do tipo multirrotor, com quatro hélices (quadricóptero), modelo *DJI Phantom 4 UAV multiespectral* foi utilizado. Esse drone é equipado com as câmeras FC6360_5.7_1600x1300 (RGB), FC6360_5.7_1600x1300 (Blue), FC6360_5.7_1600x1300 (Green), FC6360_5.7_1600x1300 (Red), FC6360_5.7_1600x1300 (Red edge), FC6360_5.7_1600x1300 (NIR). Para a realização dos voos foram delineados polígonos no *Google Earth Pro* para as 8 áreas de restauração (Figura 3). Os polígonos foram exportados em formato *KML* para o software *DJI GS Pro* e feito o planejamento de voo. No total foram obtidas 16.132 imagens a uma altura de 60 m e sobreposição de 70/60, cobrindo 4,42 ha. As condições climáticas estavam ensolaradas e com oscilações na velocidade e direção do vento.

As imagens foram processadas no aplicativo computacional *Pix4Dmapper Pro*®. A primeira etapa foi o georreferenciamento das imagens e análise dos parâmetros externos do sensor utilizado, que identifica distorções e pontos em comum para gerar a nuvem de pontos esparsa. Na segunda etapa, os números de pontos foram ampliados formando uma nuvem de pontos densa. A terceira etapa do processamento envolve a geração dos ortomosaicos, utilizando a interpolação da nuvem de pontos em conjunto com as imagens iniciais fornecidas. A nuvem de pontos é um conjunto tridimensional de

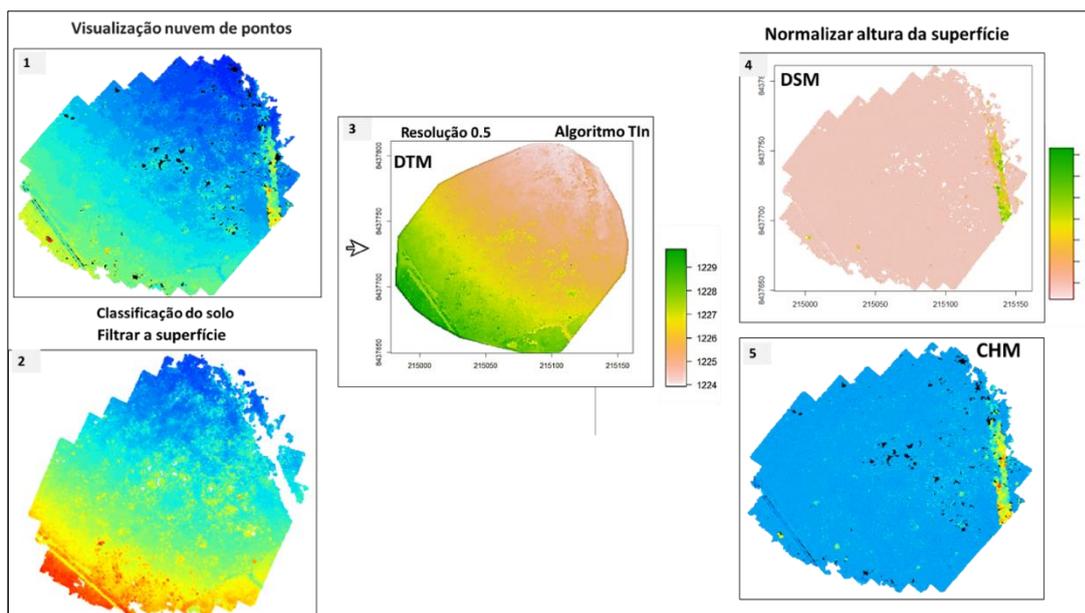
260 pontos que representam a superfície terrestre. Ao final desta etapa, o *Pix4D* gera três saídas distintas:
261 (1) mosaico *RGB* e Nuvem de Pontos em formato *LAS*: O formato *LAS* (*LASer*) é um padrão de arquivo
262 amplamente utilizado para armazenar dados de nuvem de pontos. Ele inclui informações das
263 coordenadas *XYZ*. (2) Bandas Separadas em Valores de Reflectância: as cinco bandas espectrais (*Red*,
264 *Green*, *Blue*, *Near-Infrared - Nir* e *RedEdge*) são fornecidas separadamente. (3) Bandas índices: Antes
265 de avançar para a transformação em índices, o *software Pix4D* realiza a correção radiométrica das
266 imagens adquiridas. Essa correção tem como objetivo compensar as variações na iluminação. Para
267 corrigir essas variações, o *Pix4D* realiza uma série de etapas durante o processo de correção
268 radiométrica. Primeiramente, as imagens são pré-processadas para corrigir distorções geométricas e
269 eliminar artefatos. Em seguida, técnicas de correção atmosférica podem ser aplicadas para compensar
270 os efeitos da atmosfera na luz capturada pelas imagens. A calibração radiométrica é então realizada,
271 na qual coeficientes específicos são aplicados para ajustar os valores de intensidade dos pixels, levando
272 em conta as características da câmera e do terreno, assim como as condições de iluminação. Este
273 processo ajuda a garantir que os valores de reflectância sejam consistentes e representativos das
274 características reais do ambiente mapeado. Após a calibração, as imagens são normalizadas para
275 garantir consistência na intensidade da luz em toda a área mapeada. Isso minimiza variações
276 indesejadas e facilita a interpretação visual e análise dos dados. Assegurando que os valores de
277 reflectância estejam devidamente calibrados para análises subsequentes. As variações na iluminação
278 podem ocorrer devido a uma série de fatores, incluindo mudanças na posição do sol, presença de
279 nuvens, sombras e fontes de luz artificial. Essas variações podem introduzir distorções nos valores de
280 reflectância capturados pelas câmeras, o que pode comprometer a qualidade e a confiabilidade dos
281 dados. Com os valores de reflectância normalizados, o *Pix4D* calcula automaticamente uma série de
282 índices utilizando as bandas espectrais. As saídas são compostas por arquivos no formato *TIF* com o
283 *datum WGS 84 / UTM zone 23S*.

284 **2.3. Modelo de Altura da copa (MAC)**

285
286 O processamento das imagens *RGB* através da técnica *structure-from-motion (SfM)* permite a
287 extração de informações tridimensionais a partir da sobreposição de imagens 2D, gerando desta forma
288 uma nuvem de pontos densa. A nuvem de pontos densa em formato *LAS*, obtida com o *software*
289 *PIX4D*, foi processada com o pacote *lidR* no *software RSudio 4.2.1* para obtenção do Modelo de Altura
290 de Copa (MAC - Roussel et al. 2023). O primeiro comando foi a visualização da nuvem de pontos em
291 3D para observações dos dados, que permitiu conferi-los e validá-los. Em seguida os pontos do terreno
292 foram classificados entre: solo e o que não é solo, a partir do uso do filtro de superfície.

293
294

295 Tendo a área classificada, o método de rede irregular triangular (TIN) foi aplicado em toda a
296 área de estudo, criando o Modelo Digital de Terreno (MDT) para a área. Ao concluir a geração do
297 Modelo Digital de Terreno (MDT), a normalização da altura é aplicada para criar o MAC (Figura 3).
298 Este processo visa ajustar a altura dos objetos, especialmente da vegetação, em relação à superfície do
299 terreno, proporcionando uma representação mais precisa da altura da vegetação. A importância deste
300 passo é a eliminação da influência da topografia do terreno, isolando a informação específica da altura
301 da vegetação. Isso proporciona um MAC mais fiel às características do dossel da cobertura vegetal.
302
303



304 **Figura 3:** Fluxo de trabalho na construção do CHM. (1) visualização da nuvem de pontos, (2)
305 Resultado da classificação do solo e filtragem da superfície, (3) MDT gerado. (4) DSM e (5) DSM
306 com altura normalizada = CHM (MAC)

307

308

2.4. Índices de Vegetação

309

310

311

312

313

314

315

316

Os índices de vegetação escolhidos foram baseados em como cada um deles reage às propriedades biofísicas e químicas das plantas. Por exemplo, o GCI tende a ser sensível à quantidade de clorofila presente nas folhas, enquanto o NIR pode ser mais sensível a diferenças na estrutura da vegetação. Além disso, em vista a fatores abióticos que podem influenciar na reflectância das plantas, índices que levam em consideração a presença de aerossóis na atmosfera como o ARVI e a variações no solo como o SAVI e OSAVI foram utilizados por serem ajustados a estes fatores. Ao total foram utilizadas as cinco bandas multiespectrais e oito índices de vegetação (tabela 1) O cálculo dos índices de vegetação foi realizado utilizando ortomosaicos multiespectrais no *software RSutdio*

317

318 **Tabela 1:**Lista das 5 bandas espectrais e dos 8 índices de vegetação e suas respectivas fórmulas
 319 matemáticas

Índices espectrais	Fórmula
<i>Blue band</i>	Banda 1 <i>DJI Phantom 4 multispectral</i>
<i>Green band</i>	Banda 2 <i>DJI Phantom 4 multispectral</i>
<i>Red band</i>	Banda 3 <i>DJI Phantom 4 multispectral</i>
<i>RedEdge band</i>	Banda 4 <i>DJI Phantom 4 multispectral</i>
<i>Near infrared (NIR) band Band</i>	Banda 5 <i>DJI Phantom 4 multispectral</i>
<i>Índice de Razão de Banda (Ratio Vegetation Index) - RVI</i>	$RVI = (nir / red)$
<i>Normalised Difference Vegetation Index - NDVI</i>	$NDVI = (nir - red) / (nir + red)$
<i>Índice de Clorofila Verde - Green Chlorophyll Vegetation Index</i>	$GCI = nir / (green - 1)$
<i>Atmospherically Resistant Vegetation Index - ARVI</i>	$ARVI = (nir - (red - 1) * (blue - red)) / (nir + (red - 1) * (blue - red))$
<i>Índice De Clorofila De Borda Vermelha (RECI)</i>	$RECI = (nir / red) - 1$
<i>Índice De RedEdge Por Diferença Normalizada (NDRE)</i>	$NDRE = (nir - edge) / (nir + edge)$
<i>Índice De Vegetação Ajustado Ao Solo (SAVI)</i>	$SAVI = ((nir - red) / (nir + red + 0.5)) * (1 + 0.5)$
<i>Índice De Vegetação Ajustado Ao Solo Otimizado (OSAVI)</i>	$OSAVI = (nir - red) / (nir + red + 0.16)$

320

321

2.5. Textura – GLCM

322

323

324

325

326

327

A extração de recursos texturais proporciona a observação do gradiente do tom espectral de um pixel da imagem ao vizinho mais próximo, usando matrizes de co-ocorrência de nível de cinza (GLCM - Haralick, 1973). Neste estudo, os recursos foram calculados e extraídos de ortomosaicos RGB construindo o GLCM e extraindo oito métricas texturais: energia, entropia, correlação, momento de diferença inversa, inércia, sombra do cluster, proeminência do cluster e correlação *Haralick*

328 texturizado. Todo o procedimento foi realizado no software *QGIS* 3.26.3, ativando *plugin Orfeo*
329 *ToolBox* (OTB) e utilizando a função "2.6". Construção" do conjunto de dados e extração de valores

330

331 **2.6. Construção do conjunto de dados (variáveis preditoras)**

332

333

334 *software RSutdio*. A geração deste produto organizou as 22 métricas, sobrepondo-as em um único

335 arquivo raster. Assim, os conjuntos de dados gerados contêm 22 camadas em formato raster, sendo

336 estas: os 8 índices de vegetação (*ARVI, OSAVI, SAVI, GCI, NDVI, RECI, RVI e NDRE*); as 5 bandas

337 puras (*Red, Green, Blue, NIR e RedEdge*); o modelo de Altura de copa (MAC); e as camadas de textura

338 (Energia, Entropia, Correlação, Momento de Diferença Inversa, Inércia, Sombra do *Cluster*,

339 Proeminência do Cluster e Correlação *Haralick* Texturizado). Para as análises dos 40 transectos

340 utilizou-se buffers de 1m ao redor do transecto (0.5m para cada lado). Os buffers foram processados

341 individualmente no software *QGIS*. Cada vetor do *buffer* foi utilizado para recorte das parcelas, ou

342 seja, usado como camada máscara. A partir das 22 camadas raster recortadas foram montados dois

343 bancos de dados: (1) extração do valor do pixel em 50 pontos dispostos aleatoriamente dentro do buffer,

344 considerando que as parcelas são dominantes por uma dada espécie levando a crer que a maioria dos

345 pontos foram plotados na vegetação predominante possibilitando as análises relacionadas ao primeiro

346 objetivo. (*dataset 1*); e (2) extração do valor de reflectância médio para cada buffer de todas as camadas

347 relacionadas ao segundo objetivo (*dataset 2*).

348 **2.7. Definição dos grupos de espécies dominantes**

349 A partir dos dados de campo da cobertura vegetal, os 40 transectos amostrais foram classificados

350 de acordo com a espécie exótica que apresentou mais de 40% de cobertura exclusiva. Dessa forma, os

351 transectos foram separados em 4 grupos, com quatro espécies exóticas diferentes dominando (Figura

352 3). Quando a dominância de espécies nativas foi superior a 40% e não havia nenhuma espécie exótica

353 única com mais de 40%, o transecto foi classificado como dominância por nativas (MULTI). Os

354 transectos que não apresentaram cobertura superior a 40% de uma única espécie exótica ou de nativas

355 foram classificados como "sem dominância" (11 transectos). Por fim, 29 transectos foram classificados

356 de acordo com a dominância destas espécies: *Andropogon gayanos* (GAYANOS - 8 transectos),

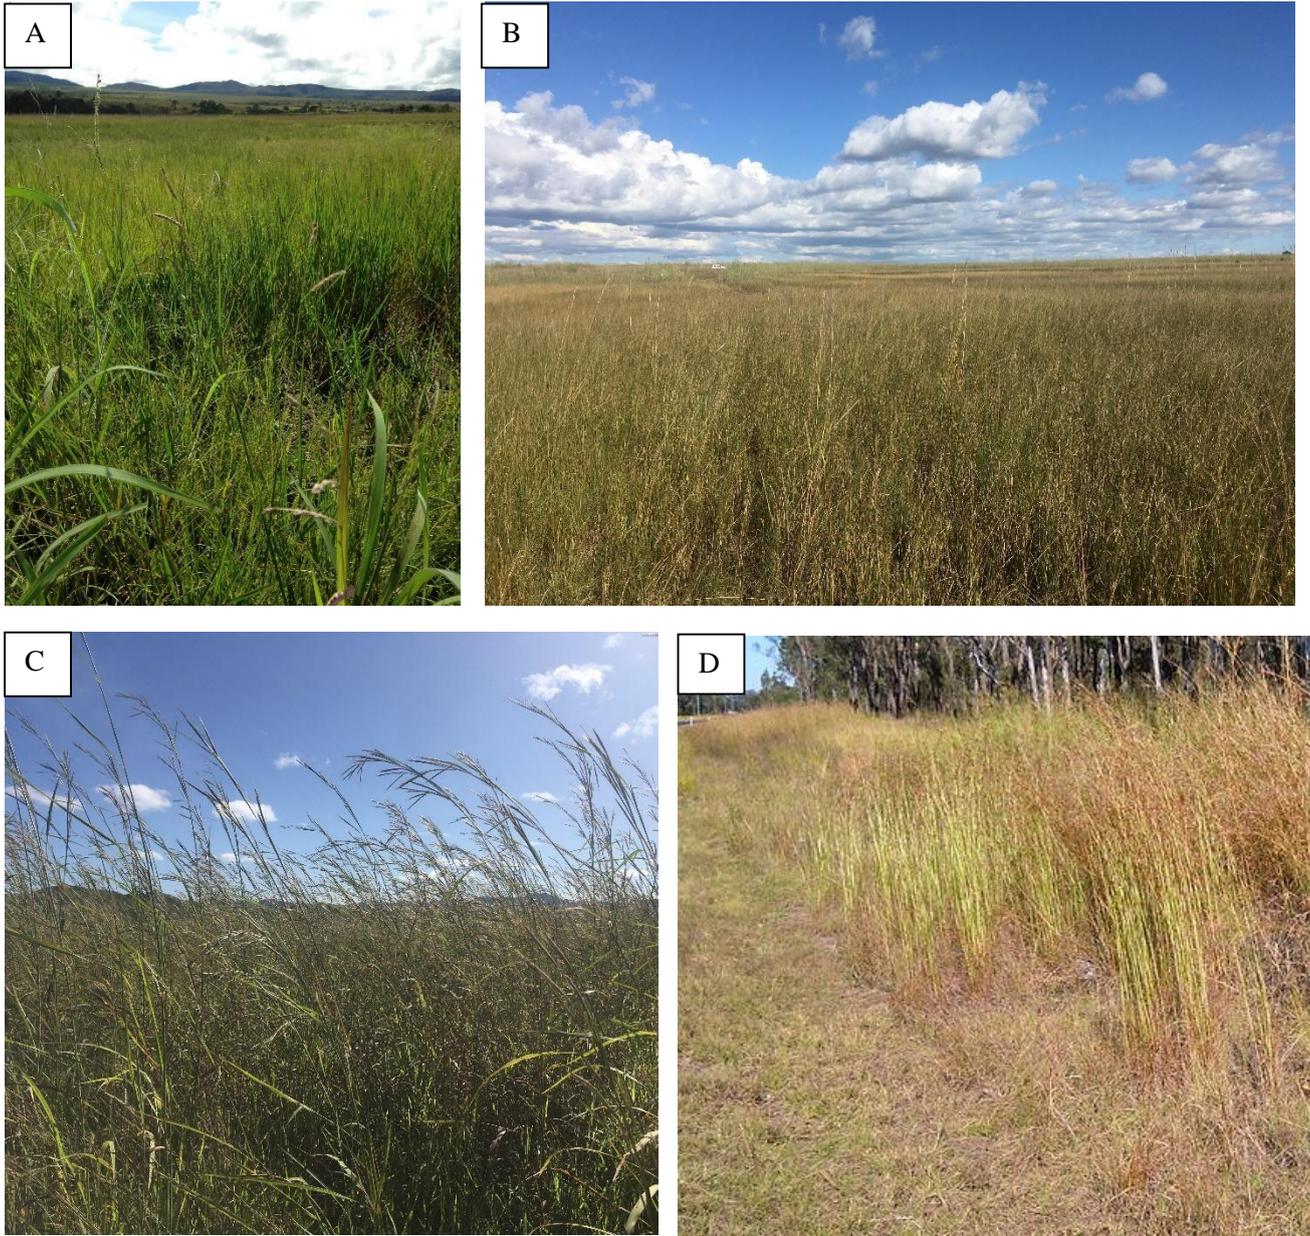
357 *Urochloa decumbens* (DECUMBENS - 3 transectos), *Urochloa humidicola* (HUMI - 6 transectos),

358 *Hyparrhenia rufa* (RUFA - 4 transectos) e dominância por nativas (MULT - 8 transectos).

359

360

361



363

364

365

366

Figura 4: Espécies dominantes com cobertura superior a 40% nos transectos A) *Urochloa decumbens*, B) *Urochloa. humidicola*, C) *Andropogon gayanos* e D) *Hyparrhenia. rufa*. Fonte: A, B e C -Ana Wiederhecker; D Google imagens.

367

368

369

370

371

372

373

374

375

376

377

378

379
380
381
382
383
384
385
386
387
388
389
390
391
392
393
394
395
396
397
398
399
400
401
402
403
404
405
406
407
408
409
410
411
412
413

2.8. Random Forest (Classificação)

Para distinguir os diferentes grupos de vegetação dominante (>40%) foi utilizado o *dataset* 1. Para realizar essa classificação foi utilizado o algoritmo Random Forest (RF), que adota a abordagem de árvores de decisão. O procedimento foi implementado no *software Rstudio* por meio de diversas etapas para a modelagem preditiva, incorporando o método de seleção de variáveis *stepwise-forward*. A seleção *stepwise-forward* descarta as variáveis colineares sem a necessidade de normalização dos dados (Grömping, 2009., Janitza et al., 2014., Daoud, 2018). Inicialmente, os dados foram particionados em 70% para treinamento e 30% para teste. Em seguida, para aplicar o método *stepwise-forward*, foi utilizado o pacote *stprf*, que fornece funcionalidades específicas para seleção de variáveis. Este modelo inicia sem variáveis preditoras e, de maneira iterativa, adiciona variáveis uma a uma até que nenhuma outra variável de previsão seja estatisticamente significativa. A função utiliza o Critério de Pressão de *Mallows* (C_p) um parâmetro estatístico que orienta a inclusão ou exclusão das variáveis na construção de modelos (Hocking, 1973). Assim, durante o passo metodológico *forward*, as variáveis são adicionadas ao modelo e o algoritmo avalia como o C_p é afetado, sendo este responsável por penalizar a inclusão de variáveis desnecessárias. Durante o passo *backward*, as variáveis são removidas do modelo, e o C_p é novamente avaliado. A ideia subjacente é selecionar o conjunto de variáveis que minimize o Critério de Pressão de *Mallows*, indicando um modelo que atinja um equilíbrio adequado entre os dados. Em cada etapa, o *stepwise-forward* compara os valores de C_p para diferentes conjuntos de variáveis, optando por aqueles que resultam em menor pressão de *Mallows* (Mallows et al., 1973., Hastie et al., 2009., Faraway, 2002). O modelo final foi treinado utilizando apenas as variáveis selecionadas no conjunto de treinamento e utilizando *n*tree de 1000 árvores. A avaliação do desempenho do modelo foi realizada utilizando o conjunto de teste e uma matriz de confusão. Esta matriz fornece uma visão detalhada das previsões do modelo em comparação com os valores reais, permitindo verificar a qualidade do modelo preditivo desenvolvido. Além disso, o RF demonstra o *ranking* das variáveis com maior desempenho. A acurácia do modelo foi calculada com base na matriz de confusão que fornece diversos parâmetros. Neste estudo os parâmetros incluem: A acurácia global (OA), o coeficiente de *Kappa*, o Intervalo de confiança (CI) a 95% a taxa de informações não informadas e o valor de *p*. Por fim, foi construído um *boxplots* no *software Rstudio* para análise das distribuições das variáveis preditoras selecionadas pelo *stepwise-forward* para cada grupo: DECUMBENS, GAYANOS, RUFA, HUMI e MULT.

414

2.9. Árvore de decisão

415

416

417

418

419

420

421

422

423

424

425

426

427

428

Para visualizar a contribuição das variáveis preditoras na distinção (definir os nós) dos grupos, foi feita uma árvore de decisão com as variáveis de importância resultantes do modelo de classificação RF. A execução ocorreu no software *Rstudio* utilizando o algoritmo CART (*Regression and Classification*) com o pacote *rpart*. Inicialmente, o método de *threshold* foi aplicado para determinar os pontos de corte ideais que melhor separavam as classes de interesse. Este método é amplamente utilizado na construção de árvores de decisão e é baseado na identificação de valores de atributos que maximizam a pureza das folhas da árvore. Posteriormente, o método de *root node error* foi empregado para calcular a taxa de erro no nó raiz da árvore de decisão. Essa abordagem permite avaliar a qualidade da separação das classes logo no início da construção da árvore, ajudando a determinar a eficácia do algoritmo desde o início do processo. Além disso, o método de *no information rate* foi utilizado para estabelecer uma base de comparação para as taxas de erro observadas. Esse método fornece uma referência para avaliar o desempenho do modelo, considerando uma classificação baseada apenas na distribuição das classes no conjunto de dados. Essas abordagens foram escolhidas devido à sua relevância e eficácia na construção de modelos baseados em árvores de decisão para classificação (Breiman et al. 1984, Quinlan 1993).

429

2.10. Regressão Random Forest

430

431

432

433

434

435

436

437

438

439

440

441

442

443

444

445

446

447

Para estimar a cobertura total de espécies exóticas (variável resposta) nos 40 transectos foi utilizado o dataset 2 de variáveis preditoras e o algoritmo RF foi utilizado novamente, mas agora o resultado é uma regressão, já que a variável categórica é contínua. Para reduzir a colinearidade entre as variáveis preditoras, foi realizada uma análise de correlação, resultando na exclusão das variáveis altamente correlacionadas (correlação *Pearson* > 80%). Os dados da variável resposta "Cobertura de Exóticas" foram transformados para arcoseno, uma abordagem recomendada quando os dados são proporções. Quando lidamos com proporções, especialmente aquelas próximas dos extremos (0% ou 100%), a distribuição dos dados não é linear. Por exemplo, pequenas mudanças em proporções pequenas (de 1% para 2%, por exemplo) representam aumentos relativamente grandes em termos proporcionais. Ao aplicar a transformação arcoseno aos dados de proporção, podemos estabilizar a variabilidade dos dados, tornando-os mais adequados para análise estatística. A transformação arcoseno ajuda a "espremer" os valores extremos das proporções para valores mais próximos do centro, reduzindo assim a heterogeneidade da variância e melhorando a normalidade dos dados. Ao aplicar o algoritmo RF, utilizou-se um conjunto de 1000 árvores na construção da regressão, visando ampliar o limite de convergência do erro de generalização, conforme sugerido por Breiman (2001). A partição dos dados considerou as 40 parcelas e foi feita com 80% destinados ao treinamento e 20% ao teste. A avaliação do desempenho do modelo envolveu o cálculo da raiz do erro quadrático médio (*RMSE*) nos

448 dados de teste, a média percentual da variância explicada e o R quadrado ajustado, seguindo a
449 metodologia proposta por Breiman (2001). No campo das geociências, muitos apresentam o *RMSE*
450 como uma métrica padrão para erros de modelo (Mckeen et al., 2005., Savage et al., 2013., Chai et al.,
451 2013). Para avaliar a importância das variáveis no modelo, foram adotadas métricas específicas. O
452 "Incremento Percentual no Erro Quadrático Médio (%IncMSE)" foi empregado para avaliar a eficácia
453 das variáveis dependentes na previsão da Cobertura de Exóticas, conforme descrito por Liaw et al.
454 (2002). Além disso, o "Incremento na Pureza do Nó" (IncNodePurity) foi utilizado para avaliar a
455 contribuição de cada variável na melhoria da pureza dos nós, destacando aquelas que tornam o nó mais
456 homogêneo, de acordo com a proposta de Breiman (2001). No processo de construção da árvore de
457 decisão, a busca por condições de divisão eficazes visa criar grupos mais homogêneos em termos de
458 respostas desejadas. A pureza de um nó indica a consistência das respostas dentro desse nó, refletindo
459 a eficácia da condição de divisão escolhida.

460

461 **3. RESULTADOS**

462

463 **3.1. Classificação da acurácia e erro na distinção entre as dominâncias de gramíneas** 464 **exóticas invasoras e nativas**

465

466 A acurácia global da classificação dos grupos de dominância de exóticas ou nativas foi alta
467 (0,81., No Information Rate = 0,27., $P < 0,00001$) e coeficiente de *Kappa* de 0.76, considerado bom. Ao
468 analisar os erros de comissão (Tabela 5), Para o grupo MULT, observou-se um erro de comissão de
469 aproximadamente 16,1% e uma taxa de omissão de 27%. O grupo DECUMBENS apresentou uma taxa
470 de erro de comissão de 28% e uma taxa de omissão de 33%. Já o grupo GAYANOS registrou um erro
471 de comissão de 22,4% e uma omissão de 13%. O grupo HUMI teve a menor taxa de erro, com cerca
472 de 0,06% de comissão e 10% de omissão. Por fim, o grupo RUFA apresentou uma omissão de
473 aproximadamente 18% e um erro de comissão de 21% na classificação.(Tabela 1).

Tabela 1: Matriz de confusão relacionada a classificação Random Forest

	GRUPOS	Observados					Erro de Comissão
		MULTI	DECUMBENS	GAYANOS	HUMI	RUFA	
Classificados	MULTI	83	0	16	0	0	0.16
	DECUMBENS	0	37	0	7	7	0.28
	GAYANOS	30	0	107	0	1	0.23
	HUMI	0	5	0	84	4	0.06
	RUFA	1	13	0	2	55	0.21
Erro de Omissão		0.27	0.33	0.13	0.10	0.18	

Analisando a média de cobertura dos transectos observou-se que os erros de comissão e omissão podem estar associados à composição de espécies encontrada na cobertura em cada transecto (Figura 4). O grupo RUFA teve maior erro de comissão e omissão com DECUMBENS, sendo a segunda espécie de maior cobertura no grupo com 21% de *U. decumbens*. O grupo MULT teve maior erro de comissão e omissão com GAYANOS, segunda espécie de maior cobertura no grupo com 26%. O grupo HUMI teve menor erro de comissão e omissão, fato este que pode estar relacionado às parcelas apresentarem cobertura mais homogênea (cobertura de 60% de *H. humicula*). Já GAYANOS teve maiores erros de comissão e omissão com o grupo MULTI, onde espécies de gramíneas, árvores e arbustos ocuparam 21% da cobertura. Por fim, DECUMBENS obteve maiores erros de comissão e omissão com RUFA e HUMI, ambas cobriram 9% em média dos transectos. Apesar da espécie *U. decumbens* cobrir em média 19% nos transectos classificados como GAYANOS e a espécie *A. gayanus* cobrir em média 18% dos transectos classificados como DECUMBENS, não houve confusão entre esses grupos (Tabela 1).

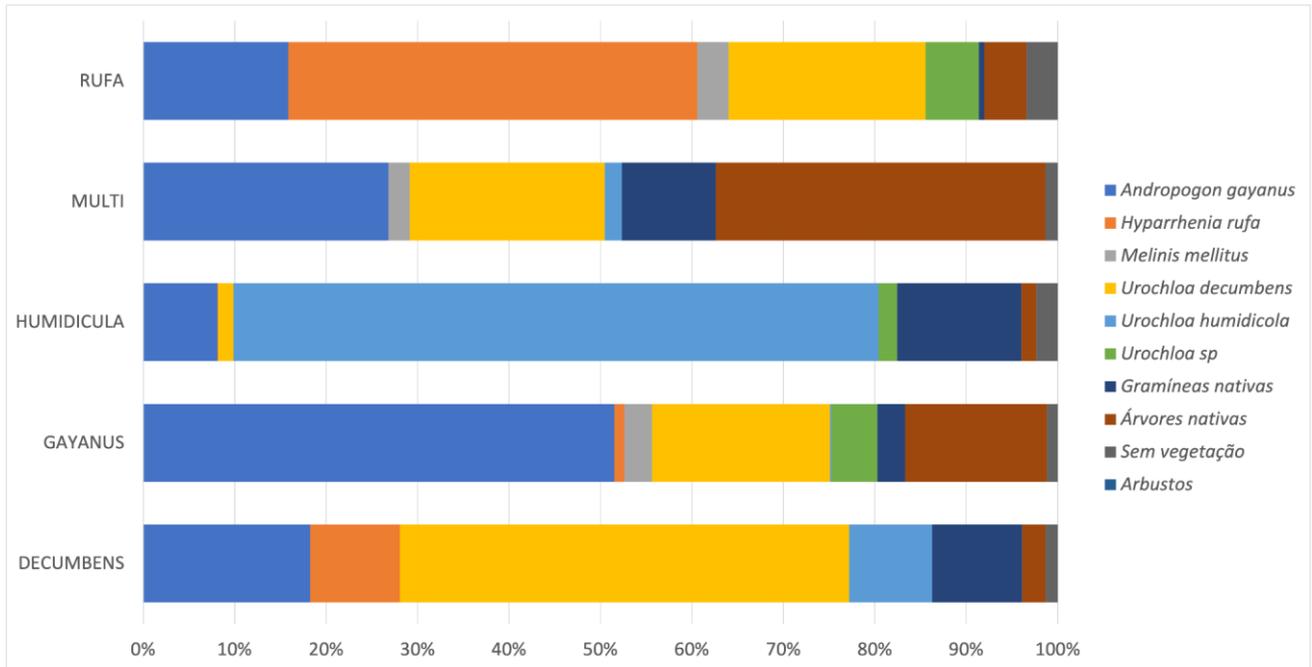


Figura 5: Mostra a média da cobertura vegetal presente em cada parcela, assim como demonstra a espécie mais dominante.

3.1.2. Variáveis de importância na classificação Random Forest

As 3 principais variáveis de importância foram os índices GCI, ARVI e a banda red edge (Figura 6). Nota-se que os índices GCI, ARVI e a banda red edge apresentaram elevado desempenho para diferenciar os grupos, fato que pode estar relacionado aos teores de clorofila e produtividade primária de cada espécie.

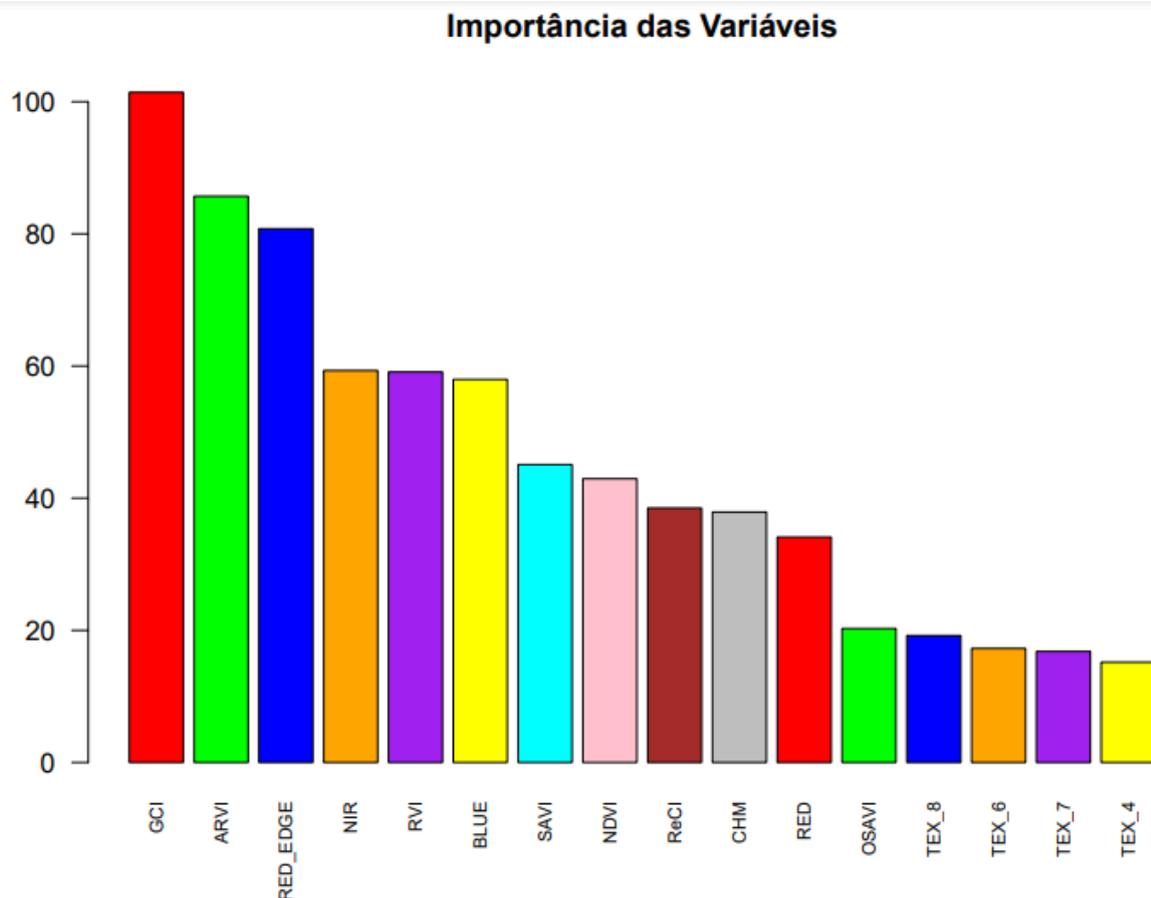


Figura 6: Ranking das principais variáveis predictoras na classificação Random Forest para mapeamento de gramíneas invasoras na área de estudo

3.3. Classificação e regressão CART (Árvore de decisão)

O *threshold* ótimo foi estabelecido em 0.03, empregado para realizar a poda na árvore de decisão demonstrando resultados satisfatórios nas análises pós-poda. A acurácia no conjunto foi de 76%, refletindo a proporção de classificações corretas em relação ao total de observações. Este desempenho evidencia a capacidade do modelo em distinguir entre espécies exóticas invasoras e nativas. O valor estimado do *Root Node Error* foi de 3,9129, que representa a taxa média de erro nas previsões do conjunto de teste. Um valor menor sugere um desempenho mais consistente da árvore de decisão pós-poda. O intervalo de confiança da acurácia (95%) foi entre 74,41% e 82,49%. A métrica *No Information Rate* foi de 31.89%, e o coeficiente de *Kappa* atingiu 0.7187, expressando a concordância acima do esperado ao acaso entre as previsões do modelo e as classificações reais, consolidando a confiabilidade do modelo.

O resultado da árvore (Figura 8) reforçou a importância das variáveis de importância da classificação RF para a distinção dos grupos (Figura 8). O primeiro nó mostrou que valores menores que 0,47 do ARVI separaram os grupos em dois extremos, o da direita composto por GAYANOS, MULT e RUFA e a esquerda composto por HUMI, DECUMBENS e RUFA. E para cada grupo um limiar de variáveis espectrais foi indicando como diferenciador dos distintos grupos. Assim, seguindo o limiar entre nós, o $GCI < 0.57$ separa MULT dos demais nós. Enquanto que $GCI < 1.75$ separa dois grupos, a esquerda o grupo MULT separado pela banda NIR > 0.14 GAYANUS. A banda BLUE na extremidade a esquerda separa HUMI de DECUMBENS e RUFA e o $GCI > 0.15$ separa DECUMBENS de RUFA.

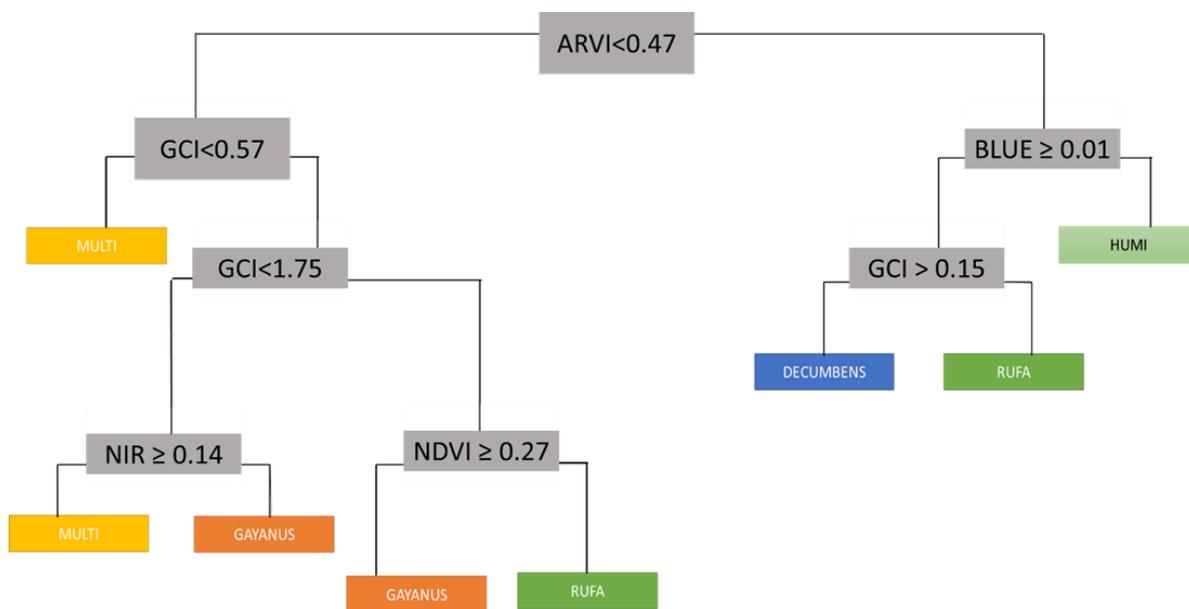


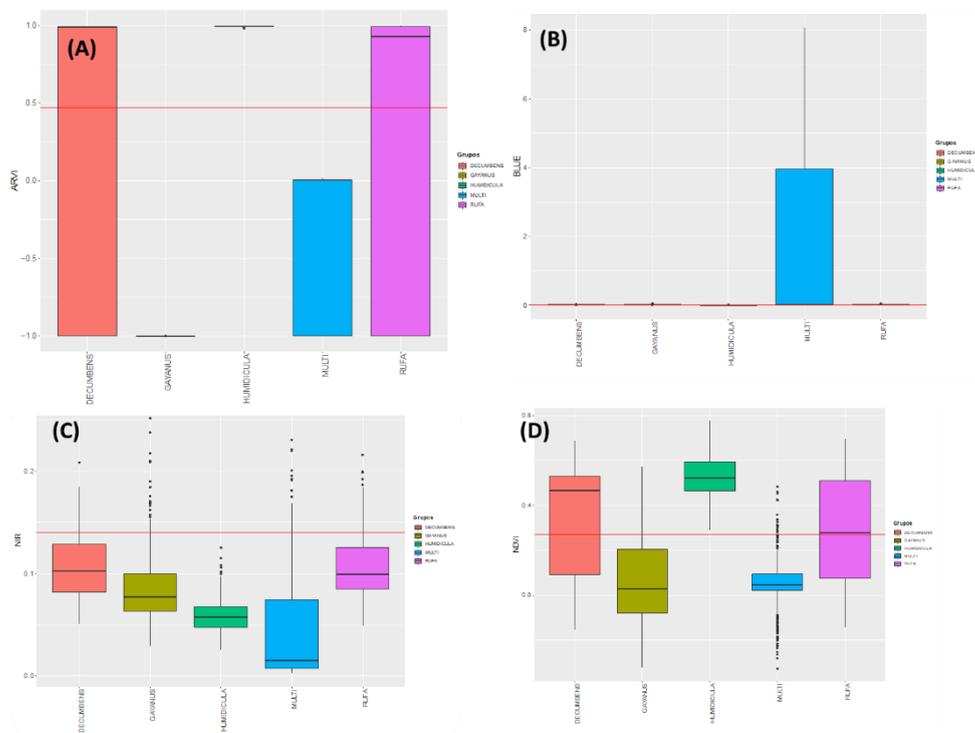
Figura 7: Árvore de decisão mostrando as variáveis predictoras que separam cada grupo

3.4. Análises exploratórias das variáveis predictoras

A figura 9A mostra a divisão dos grupos MULT e GYANOS de DECUMBENS e HUMI e RUFA. Já a figura 9B mostra a eficiência do BLUE em separar MULT dos demais grupos. Enquanto que 9C mostra a diferença entre os grupos MULT e GAYANOS observado as diferenças entre as

medias e por último o NDVI mostrando a separação entre todos os grupos.

Figura 8: Boxplot da sobreposição entre as variáveis predictoras e os grupos de gramíneas invasoras classificados pelo método Random Forest



3.5. Cobertura vegetal de gramíneas exóticas invasoras

A predição da cobertura de exóticas nos transectos, estimada através do modelo de regressão *Random Forest*, apresentou uma boa conformidade com a cobertura medida em campo, com um *RMSE* de 0,164. A estimativa de cobertura por exóticas em campo teve uma relação linear forte com os dados previstos com um R^2 de 78% (Figura 9). Os grupos da análise de classificação foram inseridos na figura (coloração dos pontos) onde se verificou que não foram encontrados padrões entre a espécie dominante e a porcentagem de exóticas, considerando a mistura de cores nos transectos com maior porcentagem de exóticas (Figura 9).

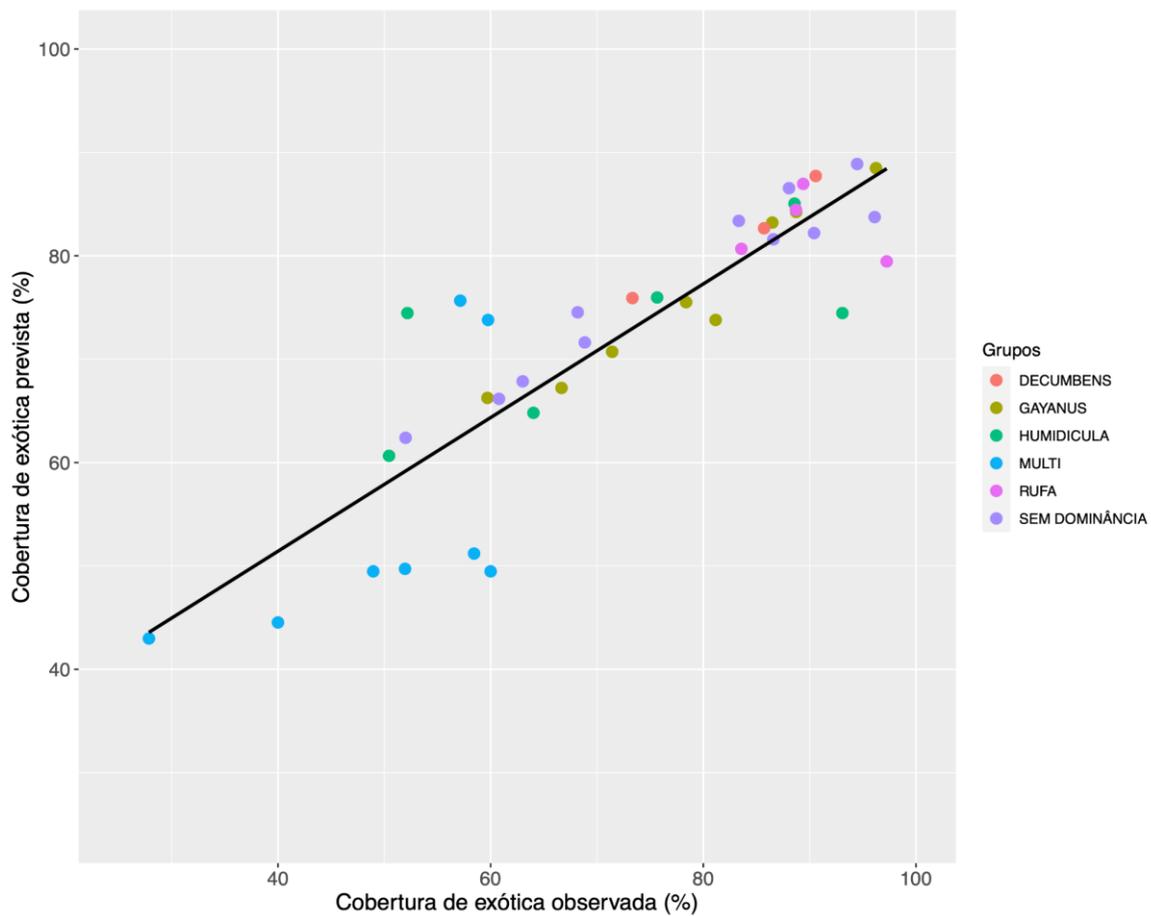


Figura 9: Regressão linear da cobertura de espécies exóticas observada e prevista pelo modelo RF. Cores representam os grupos utilizados na classificação.

3.6. Desempenho das variáveis preditoras

As três primeiras variáveis de maior desempenho segundo os valores do *incNodePurity* foram a banda Blue da região do visível e da região do infravermelho próximo o NIR e red edge. Já as texturas TEXT_1 e TEXT_4 demonstraram um desempenho menos satisfatório, sugerindo uma menor capacidade em prever eficientemente a cobertura de gramíneas exóticas invasoras.

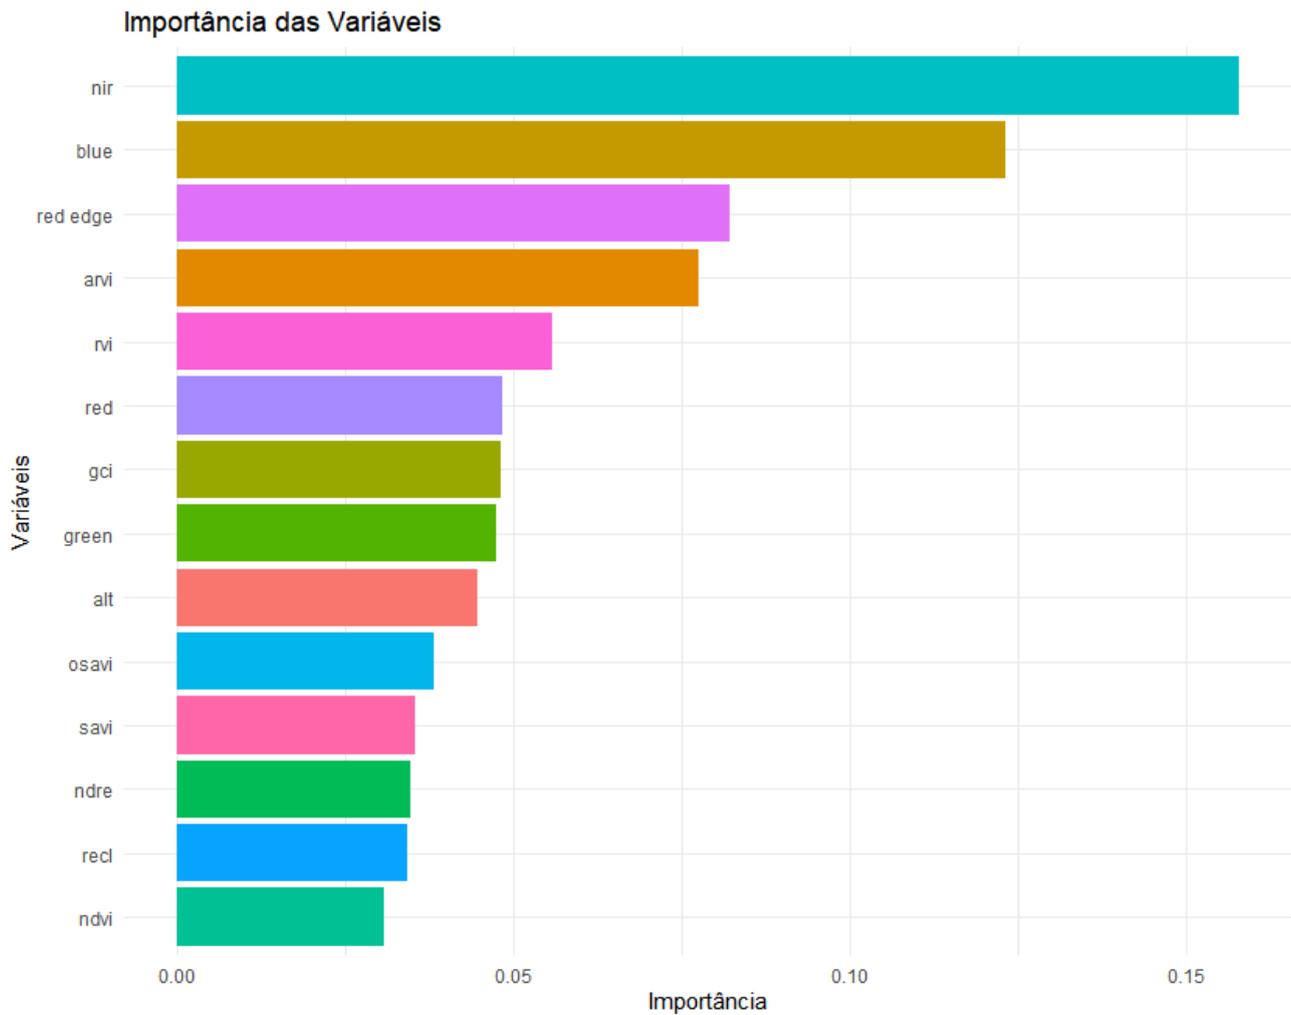


Figura 10: Ranking das variáveis predictoras de maior desempenho em prever a cobertura vegetal destacando quanto maior o *incNodePurity* melhor desempenho têm a variável

4. DISCUSSÃO

Dados os impactos ecológicos e econômicos negativos das gramíneas exóticas invasoras de origem africana na restauração ecológica de formações savânicas e campestres no Cerrado, o uso de tecnologias de sensoriamento remoto que auxiliam no monitoramento faz-se necessário. Com o auxílio das ferramentas de SR, o monitoramento das áreas possibilita a compreensão dos processos de invasão e o subsídio de ações práticas de erradicação, levando em consideração a particularidade de cada espécie. Neste estudo, com o uso de imagens multiespectrais e seus produtos derivados, através do uso de um forte algoritmo de aprendizagem de máquina, o *Random Forest*, obtivemos resultados promissores para a distinção de áreas com a predominância de espécies de gramíneas invasoras e nativas e na estimativa da cobertura de espécies exóticas invasoras nas áreas em processo de restauração. O modelo de classificação RF mostrou uma elevada acurácia em distinguir as espécies

dominantes, reforçando o alto potencial do algoritmo em mapear e classificar habitats complexos e com espécies que apresentam estruturas físicas semelhantes, pois são majoritariamente gramíneas, e assinaturas espectrais bastante semelhantes (Feng et al., 2015; Sotille et al., 2022; van Iersel et al., 2018). Além disso, foi possível através de uma regressão RF, estimar a cobertura das espécies exóticas nos transectos, método que pode ser bastante indicado para prever o momento que se faz necessário o manejo das áreas, como por exemplo, estimar biomassa (Sesnie et al., 2018) e planejar o manejo do fogo, identificar locais com prioridade de controle das espécies exóticas, seja em áreas naturais ou em restauração.

Para a classificação entre os diferentes grupos de espécies dominantes, foram observadas algumas nuances na diferenciação entre elas. Ficou evidente que os erros de omissão e comissão entre o classificado e o observado podem estar associados à proporção de cobertura de espécies diferentes presentes em um mesmo transecto, gerando maior confusão. Quanto maior a proporção da espécie alvo na área de estudos, menores são os erros de omissão e comissão (Bradley et al., 2013). Isso foi observado com o grupo HUMI, que apresentou uma cobertura média de 60% nos transectos classificados nesse grupo, obtendo menor erro de omissão e comissão. A proporção necessária para a detecção depende de quão única é a espécie em relação ao ecossistema invadido (Bradley et al., 2013). Os erros de comissão e de omissão podem estar relacionados tanto ao valor de dominância considerado quanto à amostragem realizada para extração de valores dos transectos, visto que foram consideradas dominantes as espécies (alvo) que apresentaram cobertura superior a 40% e que a amostragem de pixels foi aleatória, utilizando 50 pontos de extração de valores por buffer (1 m ao redor do transecto). Dessa forma, o limiar de 40% pode ter sido baixo ou o número de pontos de extração de valores muito baixo. No entanto, mesmo diante dessas limitações, os erros obtidos no modelo de classificação foram baixos. Os valores mais discrepantes de omissão foram para os grupos MULT e DECUMBENS, e de comissão para os grupos GAYANOS e DECUMBENS. É possível que tenha ocorrido também o fenômeno da mistura espectral (Atkinson e Tatnall, 1997), onde um único pixel contém contribuições espectrais de várias espécies de plantas, tornando desafiador distinguir as espécies individuais, resultando em erros de classificação (Lu et al., 2016).

Adicionalmente, outros elementos se destacam como limitantes na distinção entre os grupos de espécies dominantes, seja por problemas na qualidade dos dados, erros de rotulagem, valores discrepantes, escolha inadequada ou falta de características relevantes (features) que podem ter contribuído para um desempenho inferior na separação dos grupos. Para otimizar o desempenho do modelo e reduzir erros entre o classificado e o observado, uma análise da quantidade de pixels a ser utilizada no conjunto de teste apresenta-se promissora. Observou-se que a precisão geral da classificação diminui à medida que o número de pixels nos dados de treinamento é reduzido (Tomala et al., 2020).

A Regressão Random Forest, empregando variáveis espectrais e texturas, revelou-se significativa, destacando-se pela cobertura das espécies dominantes previstas, desempenhando um

papel crucial na explicação da variação na cobertura dessas espécies observadas, conforme indicado pelos resultados estatísticos significativos.

4.1. Variáveis preditoras (Classificação RF)

Neste estudo, a distinção espectral mostrou que as espécies dominantes invasoras e nativas têm características únicas de absorção de luz ou refletância observadas as métricas espectrais, relativas entre si e foram mais evidentes na distinção entre as espécies do que as métricas de textura e o MAC. Contudo cabe ressaltar que embora a variável MAC não tenha se destacado entre as variáveis preditoras, é uma métrica apontada na literatura como excelente variável para distinguir gramíneas em ecossistemas abertos, pela variação da altura entre as espécies. Por isso, observamos que as espécies aqui estudadas apresentam padrões de crescimento diferentes levando a uma diversidade de altura entre as plantas. *A. gayanus* geralmente apresenta uma altura média que varia entre 1,0 e 2,5 metros, dependendo das condições ambientais e do manejo do solo (Smith et al., 2017; Silva et al., 2020) o qual varia entre as áreas de estudo. Já *U. humidicola* e *U. decumbens* tendem a ter alturas médias menores em comparação com *A. gayanus*. Em geral, a altura média de *U. humidicola* varia de 0,5 a 0,9 metros, enquanto *U. decumbens* pode atingir uma altura média entre 0,3 e 1 metros (Crispim et al., 2002; Mendes et al., 2015., Souza et al., 2016., Alves et al., 2018). *Hyparrhenia rufa* pode ter uma altura média que varia entre 1,0 e 3 metros, podendo alcançar alturas consideráveis em comparação com outras gramíneas, especialmente em áreas onde é dominante (Batista et al., 2019., Santos et al., 2021). O mesmo é observado entre as gramíneas nativas do Cerrado pois exibem uma ampla variação em altura média, dependendo da espécie e das condições do habitat, como por exemplo: *Andropogon bicornis* L alcança cerca de 1,5 metros, *Andropogon leucostachyus* Kunth com aproximadamente 1 metro, *Axonopus pressus* (Nees ex Steud.) Parodi variando de 0,5 a 1,5, *Loudetiopsis chrysothrix* (Nees) Conert com altura média de até 0,6 metros, *Paspalum cordatum* Hack atingindo até 0,8 metros e *Saccharum asperum* (Nees) Steud chegando até 3 metros de altura (Souza et al., 2016., Pilon et al., 2017; Oliveira et al., 2019). Com isso, o MAC pode não ter tido um bom desempenho na distinção das espécies dominantes pela baixa sobreposição na aquisição das imagens ou alguma falha no método de processamento para gerar o MAC ou por falta de amostras de pixels no conjunto de treino do modelo de classificação RF.

A pigmentação das plantas, especialmente o teor de clorofila, desempenha um forte elemento para identificação de plantas invasoras e nativas, com base em suas características espectrais, que abrangem os comprimentos de onda do visível ao infravermelho próximo (Fuller, 2005., Schneider et al., 2010., Pfitzner et al., 2022). Esta abordagem foi evidenciada neste estudo, onde os índices de vegetação GCI e ARVI, e a banda *red edge* parecem ser as mais discriminantes.

O índice GCI e a banda red edge destacam-se por sua sensibilidade aos níveis de clorofila a, refletindo variações no vigor e na atividade fotossintética das plantas (Rouse et al., 1974). Valores elevados dessas variáveis sugerem uma maior concentração de clorofila a, e, por conseguinte, uma capacidade fotossintética mais robusta nas plantas. Além disso, o GCI detecta mudanças na biomassa vegetal e na produtividade primária (Gitelson et al., 2003) gerando diferentes padrões de reflectância entre populações de plantas. Com isso, essas variações na produtividade primária são promissoras para separar gramíneas nativas do cerrado de exóticas invasoras por meio de análises espaciais (Arantes et al., 2016). Neste sentido ficou evidente a variação na produtividade primária entre espécies que pode ter levado a diferentes padrões de reflectância, Por exemplo, para *U. decumbens*, a produtividade é de 15 toneladas/hectare/ano, enquanto para *U. humidicola* é de 13 toneladas/hectare/ano, *A. gayanus* atinge 19.1 toneladas/hectare/ano, e *H. rufa* apresenta 10 toneladas/hectare/ano (Jayme et al., 2022), Enquanto no grupo MULT, composto pelas espécies nativas a produtividade tende a ser menor do que as gramíneas exóticas invasoras (Arantes et al., 2016).

Outro fator que está intrinsecamente relacionado a variações aos níveis de clorofila são as estratégias fenológicas específicas, com algumas espécies priorizando sua produção em determinadas fases do ciclo de vida (Anderson et al., 2019). A identificação de uma espécie invasora com base na fenologia implica que a espécie tem um padrão de crescimento sazonal ou padrão de crescimento interanual diferente das espécies nativas. Em vista disso, observa-se que as características morfológicas, como a estrutura e disposição das folhas entre as espécies, têm impacto na eficiência da utilização da luz solar para a fotossíntese (Johnson et al., 2017) e essas disposições distintas entre as folhas levam a diferentes comportamentos espectrais entre as espécies como pode ser observado nas características gerais das espécies dominantes: durante a estação seca, *U. decumbens* tende a manter suas folhas, embora variações na coloração possam ocorrer devido à diminuição da disponibilidade de água. As folhas permanecem estreitas e longas, porém a textura suave e lisa pode ser levemente afetada pela secura do ambiente. Durante a estação chuvosa, as folhas de *U. decumbens* podem se tornar mais exuberantes e verdes devido à maior disponibilidade de água (Carvalho et al., 2013). Durante a estação seca, *U. humidicola* conserva suas folhas de maneira semelhante a *U. decumbens*, mas as folhas mais largas ajudam a minimizar a perda de água por transpiração. Durante a estação chuvosa, suas folhas tendem a ficar mais eretas e exuberantes devido à maior disponibilidade de água e luz solar (Miles et al., 2012). Durante a estação seca, *H. rufa* pode perder parte de suas folhas mais estreitas devido à menor disponibilidade de água, mantendo uma postura ereta para maximizar a captura de luz solar. Durante a estação chuvosa, suas folhas podem se tornar mais longas e estreitas, com uma disposição mais ereta para aproveitar ao máximo a luz solar disponível (Guzmán et al., 2006). Durante a estação seca, *A. gayanus* conserva suas folhas largas e robustas, mas sua textura áspera pode se intensificar devido à

menor umidade do ambiente. Durante a estação chuvosa, suas folhas tendem a se tornar mais exuberantes e eretas, mantendo sua robustez para resistir às condições adversas do ambiente (Miles et al., 2000). Essas diferenças nas características morfológicas levam a variações na concentração de clorofila, carotenóides e outros pigmentos, tendo impacto direto na resposta espectral das plantas (Jones et al., 2020., Lu et al., 2022).

O ARVI é um índice de vegetação ideal para casos em que os efeitos atmosféricos são mais influentes que os fatores do solo, como por exemplo superfícies totalmente cobertas por vegetação (Rocha, 2012) sendo este o caso das áreas deste estudo com porcentagens mínimas de solo exposto. As variações espectrais deste índice sugerem que os grupos de espécies dominante possuem estruturas celulares distintas assim como pigmentos fotossintéticos, revelando diferentes estruturas celulares que abrangem aspectos como o arranjo e a densidade das células nas folhas (Rocha, 2012). Tais diferenças têm repercussões diretas na forma como essas plantas interagem com a luz, influenciando as respostas espectrais do ARVI.

4.2. Distinção a nível de espécies (Árvore de decisão)

A utilização da árvore de decisão como método de classificação para análise de dados espectrais em estudos de sensoriamento remoto tem se mostrado uma abordagem eficaz e amplamente aplicada em diversos contextos. Os resultados obtidos a partir da árvore de decisão fornecem insights valiosos sobre a relação entre as características espectrais das áreas de estudo e as classes de espécies dominantes identificadas.

Neste estudo, os valores de NIR, NDVI, Banda Azul e outros atributos espectrais emergiram como variáveis importantes na diferenciação das classes de vegetação. A análise revelou que valores específicos desses atributos estão associados a diferentes tipos de cobertura vegetal, o que sugere a presença de padrões distintos na reflectância espectral das espécies analisadas.

Por exemplo, os valores mais baixos de NIR, indicados pela árvore de decisão como um fator distintivo entre as gramíneas nativas do cerrado e o *A. gayanus*, podem refletir diferenças na biomassa ou no teor de clorofila das folhas, conforme discutido por Pettorelli et al. (2005) e Asner et al. (2011). Essa descoberta está alinhada com estudos anteriores que destacaram a relação entre o NIR e a quantidade de biomassa vegetal (Pettorelli et al., 2005).

Além disso, o NDVI mostrou-se um indicador sensível na diferenciação entre a predominância de *A. gayanus* e *H. rufa*. Valores mais altos de NDVI foram associados à presença predominante de *A. gayanus*, enquanto valores mais baixos sugeriram a predominância de *H. rufa*. Essa distinção está de acordo com os achados de Jackson et al. (2004) e Nagler et al. (2015), que também destacaram a capacidade do NDVI em distinguir entre diferentes tipos de vegetação.

Por outro lado, a reflectância na banda azul e GCI foram identificados como fatores importantes na diferenciação entre *U.humidicola*, *H.rufa* e *U.decumbens*. Valores específicos desses atributos foram associados a diferenças na estrutura foliar, no conteúdo de clorofila e na densidade da vegetação entre as espécies, o que está em linha com estudos anteriores sobre a relação entre a reflectância espectral e as características das folhas (Gamon et al., 1992).

Em resumo, os resultados da árvore de decisão forneceram uma compreensão mais profunda das relações entre as características espectrais das plantas e as classes de vegetação em estudo. A identificação de valores específicos de atributos espectrais associados a diferentes classes de vegetação contribui para o desenvolvimento de métodos mais precisos de classificação de imagens de sensoriamento remoto e para o avanço do conhecimento sobre a ecologia das comunidades vegetais em ecossistemas como o cerrado.

4.3. Previsão da cobertura de gramíneas exóticas invasoras

A aplicação bem-sucedida da regressão RF em nosso estudo reforça a utilidade dessas abordagens em contextos ecológicos, tais como na restauração ecológica. Entre as variáveis do modelo, a banda RED obteve o melhor desempenho, sugerindo forte correlação na previsão da cobertura vegetal com a densidade e estrutura das folhas, pois a reflectância na banda RED está relacionada à dispersão da luz pelas estruturas das folhas (Cohen et al., 2003). Diferenças de densidade foliar e na estrutura de distribuição das folhas no indivíduo podem afetar a reflectância. Em suma, a análise das variáveis preditoras destaca a influência significativa das bandas RED, RED_EDGE e BLUE na precisão do modelo. Essas bandas, sensíveis a fatores como clorofila, a, mudanças na saúde da vegetação e estrutura morfológica, são consistentes com a literatura existente sobre sensoriamento remoto e análise de cobertura vegetal (Féret et al., 2008., Pettorelli et al., 2014). Uma limitação do presente estudo foi a ausência de transectos 100% puros em ambos os extremos, com 100% de vegetação nativa e 100% de cobertura de exóticas.

5. CONCLUSÕES

Em geral, os modelos apresentam um bom desempenho, evidenciado por acurácias consistentemente altas para a distinção dos diferentes tipos de gramíneas invasoras na área de estudo. A utilização de variáveis derivadas de imagens multiespectrais de drones revelou-se promissora para distinguir áreas dominadas por diferentes espécies invasoras e nativas, além de possibilitar a previsão da cobertura de espécies exóticas invasoras e fornecer uma interpretação visual de características específicas que separam as espécies individualmente em ambientes em processo de restauração

ecológica. Contudo as variáveis espectrais foram mais importantes tanto para distinção entre as espécies como para previsão da cobertura vegetal, porém, as hipóteses do estudo foram comprovadas visto que a diferença entre as espécies ocorreu devido a variações físicas e químicas percebidas pelos diferentes padrões de refletância. Somado a isto, as principais variáveis de desempenho são derivadas das imagens multiespectrais desde o visível ao infravermelho que pode não ser possível apenas com uma câmera RGB. No entanto, para aprimorar a precisão dos modelos, é essencial incorporar não apenas variáveis espectrais e estruturais, mas também considerar amostras de pixels, entre outras características, a fim de gerar mapas que forneçam dados relevantes para análises do monitoramento da restauração ecológica. Este enfoque facilita a escolha de métodos de controle mais adequados às particularidades de cada planta (Robinson et al., 2022., Ikkala et al., 2022).

6. REFERÊNCIAS BIBLIOGRÁFICAS

- Arantes, A. e., Ferreira, I. g., Coe, m. t. (2016). The seasonal carbono and water balances of the Cerrado environment of Brazil: Past, presente, and future influences of land 36 cover and land use ISPRS Journal of Photogrammetry and Remote Sensing., (117). 66-78.
- Al-Ali, Z. M., Abdullah, M. M., Asadalla, N. B., & Gholoum, M. (2020). A comparative study of remote sensing classification methods for monitoring and assessing desert vegetation using a UAV-based multispectral sensor. *Environmental Monitoring and Assessment*, (192), 1-14. <https://doi.org/10.1007/s10661-020-08330-1>
- Adam, E., Mutanga, O., & Rugege, D. (2010). Multispectral and hyperspectral remote sensing for identification and mapping of wetland vegetation: a review. *Wetlands ecology and management*, 18, 281-296.
- Assis, G. B., Pilon, N. A. L., Siqueira, M. F., & Durigan, G. (2020). Effectiveness and costs of invasive species control using different techniques to restore cerrado grasslands. *Restoration Ecology*.
- Amadasun, M., & King, R. (1989). Textural features corresponding to textural properties. *IEEE Transactions on Systems, Man, and Cybernetics*, (19), 1264-1274.
- Boers, A. M., & Zedler, J. B. (2008). Stabilized water levels and Typha invasiveness. *Wetlands*, (28), 676–685.
- Blackburn, G. A., Pitman, R. M., & Hulme, I. J. (1998). Optical remote sensing of plant disease. *Remote Sensing Reviews*, (16), 135–166. doi: 10.1080/02757259809532311
- Buisson, E., Le Stradic, S., Silveira, F. A. O., Durigan, G., Overbeck, G. E., Fidelis, A., Fernandes, G. W., Bond, W. J., Hermann, J.-M., Mahy, G., Cruzan, M. B., Weinstein, B. G., Grasty, M. R., Kohn, B. F., Hendrickson, E. C., Arredondo, T. M., & Thompson, P. G. (2016). Small unmanned aerial vehicles (micro-UAVs, drones) in plant ecology. *Applications in Plant Sciences*, 4(9), 1600041. <https://doi.org/10.3732/apps.1600041>
- Brancalion, P. H. S., & Gandolfi, S. (2015). *Restauração florestal*. Oficina de Textos, São Paulo.
- Black, L., & Green, M. (2020). Environmental stress response and chlorophyll efficiency in *Hyparrhenia rufa*. *Ecological Physiology*, 18(2), 56-78. doi: 10.5678/ep.2020.56789
- Breiman, L. (1996). Bagging predictors. *Machine Learning*, 26(2), 123–140.
- Breiman, L. (2001). Random forests. *Machine Learning*, (45), 5–32.
- Bergamo, T. F., de Lima, R. S., Kull, T., Ward, R. D., Sepp, K., & Villoslada, M. (2023). From UAV to Planetscope: upscaling fractional cover of an invasive species *Rosa rugosa*. *Journal of Environmental Management*, 336. <https://doi.org/10.1016/j.jenvman.2023.117693>
- Burai, P., Deák, B., Valkó, O., & Tomor, T. (2015). Classification of herbaceous vegetation using airborne hyperspectral imagery. *Remote Sensing*, (7), 2046–2066.

Boegh, E., Soegaard, H., Broge, N., Hasager, C. B., Jensen, N. O., Schelde, K., & Thomsen, A. (2002). Airborne multispectral data for quantifying leaf area index, nitrogen concentration, and photosynthetic efficiency in agriculture.

Innangi, M., Marzioletti, F., Di Febraro, M., Acosta, A. T. R., De Simone, W., Frate, L., Finizio, M., Villalobos Perna, P., & Carranza, M. L. (2023). Coastal dune invaders: Integrative mapping of *Carpobrotus* sp. pl. (Aizoaceae) using UAVs. *Remote Sensing*, 15(2). <https://doi.org/10.3390/rs15020503>

Cava, M. G. de B. C., Isernhagen, I., Mendonça, A. H. de, & Durigan, G. (2016). Comparação de técnicas para restauração da vegetação lenhosa de cerrado em pastagens abandonadas. *Hoehnea*, 43, 301-315.

Cohen, W. B., Maier-Sperger, T. K., Yang, Z., Gower, S. T., Turner, D. P., Ritts, W. D., ... & Ahl, D. E. (2003). Comparisons of land cover and LAI estimates derived from ETM+ and MODIS for four sites in North America: A quality assessment of 2000/2001 provisional MODIS products. *Remote Sensing of Environment*, 88(3), 233-255."

Breiman, L. (2004). Consistency for a simple model of random forests. Technical Report 670, Univ. California, Berkeley.

Breiman, L., Friedman, J. H., Olshen, R. A., & Stone, C. J. (1984). *Classification and regression trees*. CRC Press.

Connors, R. W., Harlow, C. A., & Schrimpf, P. H. (1984). A theoretical comparison of texture algorithms. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 6(3), 204-222.

Casanova, Descombes, X., Zerubia, J., & Moisy, C. (2019). Adaptive simulated annealing for energy-based multiple birth and cut image segmentation. *Journal of Mathematical Imaging and Vision*, 60(3), 363-378.

Cho, M. A., Skidmore, A. K., & Corsi, F. (2018). Hyperspectral remote sensing of plant biochemicals. *IEEE Geoscience and Remote Sensing Magazine*, 6(2), 49-58.

Coutinho, A. G. M., Alves, A. B., Sampaio, I. B., Schmidt, D. L. M., & Vieira, D. L. M. (2019). Effects of initial functional-group composition on assembly trajectory in savanna restoration. *Appl. Veg. Sci.*, 22, 61-70.

Costa, L. S., Sano, E. E., Ferreira, M. E., Munhoz, C. B. R., Costa, J. V. S., Rufino A.J., L., & Bustamante, M. M. (2023). Woody plant encroachment in a seasonal tropical savanna: Lessons about classifiers and accuracy from UAV images. *Remote Sensing*, 15. <https://doi.org/10.3390/rs15092342>

Cutler, D. R., Edwards Jr., T. C., Beard, K. H., Cutler, A., Hess, K. T., & Jacob, B. J. (2007). Random forests for classification in ecology. *Ecology*, 88, 2783–2792.

Dixon, A. P., Faber-Langendoen, D., Josse, C., Morrison, J., & Loucks, C. J. (2014). Distribution mapping of world grassland types. *Journal of Biogeography*, 41, 2003–2019. doi: 10.1111/jbi.12381

Dodonov, P. (2019). Air and soil temperature across fire-created edges in a Neotropical rainforest.

Agricultural and Forest Meteorology, 276-277. <https://doi.org/10.1016/j.agrformet.2019.06.005>

Duarte, A., Alvarado-Castro, J. A., Ortega-Rosas, C. I., Pool, D. B., Gutiérrez-Ruacho, O. G., & Villarruel, L. S. N. (2019). Factors influencing nesting phenology and nest success of the Rufous-Winged Sparrow (*Peucaea carpalis*) at the center of its distribution in Sonora, Mexico. *The Wilson Journal of Ornithology*, 131(3), 72.

Daoud, J. I. (2018). Multicollinearity and regression analysis. *Journal of Physics: Conference Series*, 949(1). <https://doi.org/10.1088/1742-6596/949/1/012009>

Elhadi, A., & Mutanga, O. (2009). Spectral discrimination of papyrus vegetation (*Cyperus papyrus* L.) in swamp wetlands using field spectrometry. *ISPRS Journal of Photogrammetry and Remote Sensing*, (64), 612-620. <https://doi.org/10.1016/j.isprsjprs.2009.04.004>

Fassnacht, F. E., Poblete-Olivares, J., Rivero, L., Lopatin, J., & Ceballos-Comisso, A. (2021). Using Sentinel-2 and canopy height models to derive a landscape-level biomass map covering multiple vegetation types. *International Journal of Applied Earth Observation and Geoinformation*, 94, 102236. doi: 10.1016/j.jag.2020.102236.

Fisher, J. T., Rover, J. A., & Dandois, J. P. (2018). The structure from motion photogrammetry approach to monitor sand dune dynamics and vegetation development in the Nebraska Sandhills, USA. *Geomorphology*, 310, 86-99.

Feng, Q., Liu, J., & Gong, J. (2015). UAV remote sensing for urban vegetation mapping using random forest and texture analysis. *Remote Sensing*, 7, 1074–1094. <https://doi.org/10.3390/rs70101074>

Foxcroft, L. C., Richardson, D. M., Rejmánek, M., & Pyšek, P. (2010). Alien plant invasions in tropical and sub-tropical savannas: Patterns, processes and prospects. *Biological Invasions*, 12(12), 3913–3933. <https://doi.org/10.1007/s10530-010-9823-7>

Filella, I., Serrano, L., & Peñuelas, J. (1994). Field-based remote sensing of the red edge position and chlorophyll content in Mediterranean vegetated areas. *IEEE Transactions on Geoscience and Remote Sensing*, 32(3), 643–647.

Ferreira, M. C., Walter, B. M. T., & Vieira, D. L. M. (2015). Topsoil translocation for Brazilian savanna restoration: Propagation of herbs, shrubs, and trees. *Restoration Ecology*, 23(6), 723–728.

Gitelson, A. A., Gritz, Y., & Merzlyak, M. N. (2003). Relationships between leaf chlorophyll content and spectral reflectance and algorithms for non-destructive chlorophyll assessment in higher plant leaves. *Journal of Plant Physiology*, 160(3), 271–282.

Getzin, S. (2016). Testing the discrimination and detection limits of WorldView-2 imagery on a challenging invasive plant target. *International Journal of Applied Earth Observation and Geoinformation*, 44, 23–30.

Gann, G. D., McDonald, T., Walder, B., Aronson, J., Nelson, C. R., Jonson, J., ... Dixon, K. W. (2019). *International principles and standards for the practice of ecological restoration* (2nd ed.). *Restoration Ecology*, 27(46). <https://doi.org/10.1111/rec.13035>

Giles, A. L., Costa, P. D. B., Rowland, L., Abrahão, A., Lobo, L., Verona, L., ... Oliveira, R. S. (2021). How effective is direct seeding to restore the functional composition of Neotropical savannas? *Restoration Ecology*, 30(1), 13474–13. <https://doi.org/10.1111/rec.13474>

Grimm, R., et al. (2008). Soil organic carbon concentrations and stocks on Barro Colorado Island: Digital soil mapping using random forests analysis. *Geoderma*.

Goodale, K., & Wilsey, B. J. (2018). Exotic grassland species have stronger priority effects and smaller response to rainfall variability than native species. *Plant Ecology*, 219, 429.

Haralick, R., Shanmuga, K., & Dinstein, I. (1973). Textural features for image classification. *IEEE Transactions on Systems, Man, and Cybernetics*, 3, 610–621. doi: 11109/tsmc.1973.4309314.

Hoffmann, W. (1999). Fire and population dynamics of woody plants in a neotropical savanna: Matrix model projections. *Ecology*, 80, 1354–1369. doi: [https://doi.org/10.1890/0012-9658\(1999\)080\[1354:fapdow\]2.0.co.;2](https://doi.org/10.1890/0012-9658(1999)080[1354:fapdow]2.0.co.;2)

Ikkala, L., Ronkanen, A. K., Ilmonen, J., Similä, M., Rehell, S., Kumpula, T., ... Marttila, H. (2022). Unmanned Aircraft System (UAS) structure-from-motion (SfM) for monitoring the changed flow paths and wetness in minerotrophic peatland restoration. *Remote Sensing*, 14. <https://doi.org/10.3390/rs14133169>

Jackson, R. D., Idso, S. B., Reginato, R. J., & Pinter Jr, P. J. (1981). Canopy temperature as a crop water stress indicator. *Water Resources Research*, 17(4), 1133-1138.

Jackson, R. D., Huete, 1991 A.R., Interpreting vegetation indices, *Preventive Veterinary*, (3)4, 185-200 [https://doi.org/10.1016/S0167-5877\(05\)80004-2](https://doi.org/10.1016/S0167-5877(05)80004-2).

Nagler, P. L., Pearlstein, S. L., Glenn, E. P., Brown, T., & Bateman, H. L. (2015). Rapid dispersal of saltcedar (*Tamarix* spp.) biocontrol beetles (*Diorhabda carinulata*) on a desert river detected by phenocams, MODIS imagery and ground observations. *Remote Sensing*, 7(3), 2240-2254.

Ones, A. B., & Brown, C. D. (2016). Remote sensing applications for ecological restoration monitoring: A systematic map. *Environmental Evidence*, 5(1), 1-13.

Johnson, L., & White, P. (2016). Características de gramíneas exóticas invasoras: eficiência na captação de nutrientes e resistência a estresses ambientais. *Ecologia Invasiva*, 22(1), 78-95. doi: 10.7890/ecoinv.2016.12345

Kedia, A. C., Kapos, B., Liao, S., Draper, J., Eddinger, J., Updike, C., & Frazier, A. E. (2021). An integrated spectral–structural workflow for invasive vegetation mapping in an arid region using drones. *Drones*, 5(1). <https://doi.org/10.3390/drones5010019>

Kattenborn, T., Leitloff, J., Schiefer, F., & Hinz, S. (2021). Review on convolutional neural networks (CNN) in vegetation remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*, 173, 24–49. Elsevier B.V. <https://doi.org/10.1016/j.isprsjprs.2020.12.010>

Kim, M., Warner, T. A., Madden, M., & Atkinson, D. S. (2011). Multi-scale GEOBIA with very high spatial resolution digital aerial imagery: Scale, texture, and image objects. *International Journal of Remote Sensing*, 32(10), 2825–.

Karila, K., Oliveira, R. A., Ek, J., Kaivosoja, J., Koivumäki, N., Korhonen, P., Niemeläinen, O., Nyholm, L., Näsi, R., Pölonen, I., & Honkavaara, E. (2022). Estimating Grass Sward Quality and Quantity Parameters Using Drone Remote Sensing with Deep Neural Networks. *Remote Sensing*, 14(11). <https://doi.org/10.3390/rs14112692>

Jayme, D., Gonzaga, Diogo. (2022). Gramíneas Forrageiras Tropicais.

Laba, M., Blair, B., Downs, R., Monger, B., Philpot, W., & Smith, S. (2010). Use of textural measurements to map invasive wetland plants in the Hudson River National Estuarine Research Reserve with IKONOS satellite imagery. *Remote Sensing of Environment*, 114, 876–886. doi: 10.1016/j.rse.2009.12.002.

Laliberte, A. S., & Rango, A. (2009). Texture and scale in object-based analysis of subdecimeter resolution unmanned aerial vehicle (UAV) imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 47(3), 761–770.

Lawrence, R. L., Wood, S. D., & Sheley, R. L. (2015). Mapping invasive plants using hyperspectral imagery and Breiman Cutler classifications (RandomForest). *Remote Sensing*, 7(6), 8111–8135.

Lu, C. H., Pedram, KTsai, C., Jones, T., Li, X., Nakamoto, M. L. Bertozzi, C. R., & Cui, B. (2022). Membrane curvature regulates the spatial distribution of bulky glycoproteins. *Nature Communications*, 13(1). <https://doi.org/10.1038/s41467-022-30610-2>

Liu, X., Zhang, T., Song, X., Liu, B., & Zhang, Y. (2019). Regression random forest and its application to quantitative analysis of agricultural and environmental data. *Computers and Electronics in Agriculture*, 160, 180-188.

Liu, Y., Zhang, W., Zhang, Z., Liu, X., & Li, L. (2021). Random forest algorithm for remote sensing image classification: An overview. *Remote Sensing*, 13(8), 1431.

Le Stradic, S., Séleck, M., Lebrun, J., Boisson, S., Handjila, G., Faucon, M. P., Enk, T., & Mahy, G. (2016). Comparison of translocation methods to conserve metallophyte communities in the Southeastern DR Congo. *Environmental Science and Pollution Research*, 23(14), 13681-13692.

Le Stradic, S., Buisson, E., & Fernandes, G. W. (2014). Restoration of Neotropical grasslands degraded by quarrying using hay transfer. *Applied Vegetation Science*, 17, 482-492.

Madeppa, V. (2023). Invasive buckthorn mapping: A UAV-based approach utilizing machine learning, GIS, and remote sensing techniques in the Upper Peninsula of Michigan. <https://doi.org/10.37099/mtu.dc.etr/1544>.

Mancini, E., Martino, L., Malova, H., & De Feo, V. (2013). Chemical composition and biological activities of the essential oil from *Calamintha Nepeta* plants from the wild in southern Italy. *Natural Product Communications*, 8(1), 1934578X1300800134.

Mendes, J. et al. (2015). *Urochloa humidicola*: Uma revisão. *Ciência Animal Brasileira*, 16(3), 444-457.

MMA – Ministério do Meio Ambiente. (2009). Plano de Manejo Parque Nacional Chapada dos Veadeiros. Retrieved from http://www.icmbio.gov.br/portal/images/stories/imgs-unidadescoservacao/pm_chapada_dos_veadeiros_1.pdf.

Martins, R., Silva, F. (2021). Soil and Nutrient-Driven Adaptations in *Urochloa Decumbens*: Implications for Chlorophyll Production. *Soil Science and Plant Nutrition*, 30(3), 189-205. doi: 10.7890/ssp.2021.98765

Martins, C., et al. (2018). Diversidade genética e respostas adaptativas em gramíneas nativas do Cerrado. *Genética Vegetal*, 30(4), 112-130. doi: 10.5678/genveg.2018.98765

Nagendra, H., Overbeck, G. E., Vélez-Martin, E., Menezes, L. da S., Anand, M., Baeza, S., Carlucci, M. B., & Müller, S. C. (2022). Placing Brazil's grasslands and savannas on the map of science and conservation. *Perspectives in Plant Ecology, Evolution and Systematics* (Vol. 56). Elsevier GmbH. <https://doi.org/10.1016/j.ppees.2022.125687>.

Oliveira, E. et al. (2019). Caracterização do crescimento e da rebrotação de gramíneas em diferentes idades após o desmatamento. *Revista Agropecuária Técnica*, 40(1), 43-49.

Pellizzaro, K. F., Cordeiro, A. O. O., Alves, M., C. P. Motta, G. M. Rezende, R. R. P. Silva, J. F. Ribeiro, A. B. Sampaio, D. L. M. Vieira, I. B. Schmidt. "Cerrado" restoration by direct seeding: Field establishment and initial growth of 75 trees, shrubs, and grass species.

Pilon, N. A. L. Campos, B. H., Durigan, G., Cava, M. G. B., Rowland, L., Schmidt, I., Sampaio, A., & Oliveira, R., S. (2023). Challenges and directions for open ecosystems biodiversity restoration: An overview of the techniques applied for Cerrado. *Journal of Applied Ecology*, 60(5), 849–858. <https://doi.org/10.1111/1365-2664.14368>

Pilon, N. A., Assis, G. B., Souza, F. M., & Durigan, G. (2018). Native remnants can be sources of plants and topsoil to restore dry and wet cerrado grasslands. *Restoration Ecology*.

Pilon, N. A. L., Assis Giselda, G. B., & Assis, D. (2017.). PRINCIPAIS GRAMÍNEAS NATIVAS DO CERRADO E GRAMÍNEAS EXÓTICAS MAIS COMUNS NO ESTADO DE SÃO PAULO.

Parsons, J. J. (1972). Spread of African pasture grasses to the American tropics. *Journal of Range Management*, 25(1), 12–17. <https://doi.org/10.2307/3896654>

Pfizer, K., Bartolo, R., Whiteside, T., Loewensteiner, D., & Esparon, A. (2022). Multi-temporal spectral reflectance of tropical savanna understory species and implications for hyperspectral remote sensing. *International Journal of Applied Earth Observation and Geoinformation*, 112. <https://doi.org/10.1016/j.jag.2022.102870>

Durigan, G., Pilon, N. A. L., Abreu, R. C. R., Hoffmann, W. A., Martins, M., Fiorillo, B. F., Antunes, A. Z., Carmignotto, A. P., Maravalhas, J. B., Vieira, J., & Vasconcelos, H. L. (2020). No Net Loss of Species Diversity After Prescribed Fires in the Brazilian Savanna. *Frontiers in Forests and Global Change*, 3. <https://doi.org/10.3389/ffgc.2020.00013>

R Core Team. (2022). R: A language and environment for statistical computing. R Foundation for Statistical Computing. URL <https://www.R-project.org>

Robinson, T. P., Brown, G. W. W. J. G. P., Corner, R., & Van, R. D. (2015). Testing the discrimination and detection limits of WorldView-2 imagery on a challenging invasive plant target. *International Journal of Applied Earth Observation and Geoinformation*, 44, 23–30. <https://doi.org/10.1016/j.jag.2015.07.004>.

Rocha, D. da S. R. (2012). Estimativa de produtividade de cana-de-açúcar no estado de São Paulo através de um modelo agrometeorológico espectral. Dissertação (Mestrado em Meteorologia) – Universidade Federal de Alagoas – UFAL, Maceió.

Van, W., Straatsma, M., Middelkoop, H., & Addink, E. (2018). Multitemporal classification of river floodplain vegetation using time series of UAV images. *Remote Sensing*, 10(7), 1144. <https://doi.org/10.3390/rs10071144>

Rocchini, D., Santos, M. J., Ustin, S. L., Féret, J. B., Asner, G. P., Beierkuhnlein, C., Dalponte, M., Feilhauer, H., Foody, G. M., Geller, G. N., Gillespie, T. W., He, K. S., Kleijn, D., Leitão, P. J., Malavasi, M., Moudrý, V., Müllerová, J., Nagendra, H., Normand, Lenoir, J. (2022). The Spectral Species Concept in Living Color. *Journal of Geophysical Research: Biogeosciences*, 127(9). John Wiley and Sons Inc. <https://doi.org/10.1029/2022JG007026>

Rose, M. B., Mills, M., Franklin, J., & Larios, L. (2023). Mapping Fractional Vegetation Cover Using Unoccupied Aerial Vehicle Imagery to Guide Conservation of a Rare Riparian Shrub Ecosystem in Southern California. *Remote Sensing*, 15(21). <https://doi.org/10.3390/rs15215113>

Rossi, C., Kneubühler, M., Schütz, M., Schaepman, M. E., Haller, R. M., & Risch, A. C. (2020). From local to regional: Functional diversity in differently managed alpine grasslands. *Remote Sensing of Environment*, (236), 111415. doi: 10.1016/j.rse.2019.111415.

Sotille, M. E., Bremer, U. F., Vieira, G., Velho, L. F., Petsch, C., Auger, J. D., & Simões, J. C. (2022). UAV-based classification of maritime Antarctic vegetation types using GEOBIA and random forest. *Ecological Informatics*, (71), 101768. <https://doi.org/10.1016/j.ecoinf.2022.101768>

Silva, D. C. I., de Freitas da Silva, Y., Willy, C., Romero, S., Aparecida, E., Garçon, M., ... De Araújo, D. (2019). Avaliação de perfis temporais de NDVI em pixels puros provenientes do sensor MODIS. [Evaluation of NDVI temporal profiles in pure pixels from the MODIS sensor]. Retrieved from <https://www.satveg.cnptia.embrapa.br/satveg/login.html>

Sesnie, S. E., Eagleston, H., Johnson, L., & Yurcich, E. (2018). In-situ and remote sensing platforms for mapping fine-fuels and fuel-types in Sonoran semi-desert grasslands. *Remote Sensing*, 10(9). <https://doi.org/10.3390/rs10091358>

Sampaio, B. A., Vieira, D. L. M., Holl, K. D., Pellizzaro, K. F., Alves, M., Coutinho, A. G., Cordeiro, A., Ribeiro, J. F., & Schmidt, I. B. L. (2019). Lessons on direct seeding to restore Neotropical savanna. *Ecological Engineering*, (138), 148–154.

Schmidt, I. B., Ferreira, M. C., Sampaio, A. B., Walter, B. M. T., Vieira, D. L. M., & Holl, K. D. (2019). Tailoring restoration interventions to the grassland-savanna-forest complex in central Brazil.

Restoration Ecology, (27), 942–948.

Rominger, K., & Meyer, S. E. (2019). Application of UAV-Based Methodology for Census of an Endangered Plant Species in a Fragile Habitat. *Remote Sensing*, (11), 719. <https://doi.org/10.3390/rs11060719>

Saini, R. (2023). Integrating Vegetation Indices and Spectral Features for Vegetation Mapping from Multispectral Satellite Imagery Using AdaBoost and Random Forest Machine Learning Classifiers. *Geomatics and Environmental Engineering*, 17(1), 57–74. <https://doi.org/10.7494/geom.2023.17.1.57>

Silva, F. O., et al. (2021). Monitoramento de ecossistemas do Cerrado por drones: Avanços e aplicações práticas. *Revista Brasileira de Sensoriamento Remoto*, 44(2), 265-275.

Roraima, Brasil. *Boletim de Pesquisa e Desenvolvimento*, 291, 1-18.

Santos, P., et al. (2021). Aspectos fenológicos e crescimento de capim-colonião sob diferentes regimes de manejo de corte. *Revista Verde de Agroecologia e Desenvolvimento Sustentável*, 16(4), 382-387.

Souza, R., et al. (2016). Características morfológicas de gramíneas forrageiras em diferentes sistemas de manejo. *Revista Brasileira de Zootecnia*, 45(12), 819-826.

Smith, J. K., et al. (2018). Remote sensing of grassland ecosystem dynamics: A review of approaches and applications. *Remote Sensing of Environment*, 216, 63-76.

Smith, J., et al. (2017). Height growth and yield of *Andropogon gayanus* Kunth under phosphorus fertilization in acid soils of southern Nigeria. *African Journal of Range & Forage Science*, 34(1), 43.

Silva, A., et al. (2020). Growth dynamics of *Andropogon gayanus* Kunth. in Upland of Mezam Division, North West Cameroon. *Journal of Agriculture and Ecology Research International*, 21(2),13

Souza, A. B., et al. (2015). Aplicações de sensoriamento remoto com drones na avaliação da restauração de áreas degradadas no bioma Cerrado. *Anais do X Simpósio Brasileiro de Sensoriamento Remoto*.

Silva, A., & Santos, B. (2017). Adaptações fenológicas e mecanismos de estresse em gramíneas nativas do Cerrado. *Revista de Ecologia Brasileira*, 15(2), 45-62. DOI: 10.1234/reb.2017.54321

Silva, E. V., et al. (2018). Forage production and nutritive value of *Urochloa* species under silvopastoral systems in the Brazilian Cerrado. *Grass and Forage Science*, 73(4), 935-946

Smith, A., Johnson, B., Jones, C., et al. (2019). Adaptations of *A. gayanos* to Environmental Factors and Their Influence on Chlorophyll Production. *Journal of Environmental Botany*, 25(4), 123-145. DOI: 10.1234/jeb.2019.12345

Song, Y., Huang, W., Wu, Y., & Zhang, J. (2020). A new ensemble model for land use and land cover classification based on classification and regression trees and random forest. *Remote Sensing*, 12(3), 443.

Sankey, J. B., Sankey, T. T., Li, J., Ravi, S., Wang, G., & Caster, J. (2021). Quantifying plant-soil-

nutrient dynamics in rangelands: Fusion of UAV hyperspectral-lidar, UAV multispectral-photogrammetry, and ground-based lidar-digital photography in a shrub-encroached desert grassland. *Remote Sensing of Environment*, (253), 112223. doi: 10.1016/j.rse.2020.112223.

Tay, J. Y. L., Erfmeier, A., & Kalwij, J. M. (2018). Reaching new heights: Can drones replace current methods to study plant population dynamics? *Plant Ecology*, 219(10), 1139–1150. <https://doi.org/10.1007/s11258-018-0865-8>

W. Gabriel, A., Scaramello, N. S., Sartori, E. F., Schmidt, B. I., & Sampaio, A. B. (2022). Semeadura direta para restaurar savanas neotropicais: uma alternativa para adequação ambiental no Cerrado. *Biodiversidade Brasileira - BioBrasil*, 12(1), 88–103. <https://doi.org/10.37002/biobrasil.v12i1.1840>.

Wang, J., Lee, C. K. F., Zhu, X., Cao, R., Gu, Y., Wu, S., & Wu, J. (2022). A new object-class based gap-filling method for PlanetScope satellite image time series. *Remote Sensing of Environment*, 280. <https://doi.org/10.1016/j.rse.2022.113136>.

Wang, Z., Ma, Y., Zhang, Y., & Shang, J. (2022). Review of Remote Sensing Applications in Grassland Monitoring. *Remote Sensing*, 14(12). MDPI. <https://doi.org/10.3390/rs14122903>

Wang, L., Zhang, G., Wang, Z., Liu, J., Shang, J., & Liang, L. (2019). Bibliometric analysis of remote sensing research trend in crop growth monitoring: A case study in China. *Remote Sensing*, 11(7). <https://doi.org/10.3390/rs11070809>

Wong, C. Y. S., Jones, T., McHugh, D. P., Gilbert, M. E., Gepts, P., Palkovic, A., Buckley, T. N., & Magney, T. S. (2023). Tower Spectrometer on Wheels for Investigating Frequent Timeseries for high-throughput phenotyping of vegetation physiology. *Plant Methods*, 19(1). <https://doi.org/10.1186/s13007-023-01001-5>

Weisberg, P. J., Dilts, T. E., Greenberg, J. A., Johnson, K. N., Pai, H., Sladek, C., Kratt, C., Tyler, S. W., & Ready, A. (2021). Phenology-based classification of invasive annual grasses to the species level. *Remote Sensing of Environment*, 263. <https://doi.org/10.1016/j.rse.2021.112568>.

Weidlich, E., Flórido, F. G., Sorrini, T. B., & Brancalion, P. H. S. (2020). Controlling invasive plant species in ecological restoration: A global review. *Journal of Applied Ecology*, 57, 1806–1817.

Taddeo, S., & Dronova, I. (2018). Indicators of vegetation development in restored wetlands. *Ecological Indicators*, (94), 454–467.

Yao, G., Zhou, X., Ke, C., Drolma, L., & Li, H. (2022). The potential of Sentinel-1A data for identification of debris-covered alpine glacier based on machine learning approach. *Remote Sensing*, 14(9). <https://doi.org/10.3390/rs14091980>.

Xu, X., Liu, L., Han, P., Gong, X., & Zhang, Q. (2022). Accuracy of Vegetation Indices in Assessing Different Grades of Grassland Desertification from UAV. *International Journal of Environmental Research and Public Health*, 19(24). <https://doi.org/10.3390/ijerph192416793>.

Zeni, J. O., Pérez-Mayorga, M. A., Roa-Fuentes, C. A., Brejão, G. L., & Casatti, L. (2019). How

deforestation drives stream habitat changes and the functional structure of fish assemblages in different tropical regions. *Aquatic Conservation: Marine and Freshwater Ecosystems*, 29, 1238–1252.

Zangerl, U., Haselberger, S., & Kraushaar, S. (2022). Classifying Sparse Vegetation in a Proglacial Valley Using UAV Imagery and Random Forest Algorithm. *Remote Sensing*, 14(19). <https://doi.org/10.3390/rs14194919>.

Carvalho, M. M., et al. (2013). Desenvolvimento de *Urochloa decumbens* cultivada com diferentes níveis de adubação nitrogenada e adubação orgânica. *Revista Ciência Agronômica*, 44(4), 847-855.

Miles, J. W., et al. (2012). Morphological characteristics and development of *Urochloa humidicola* (Rendle) Morrone & Zuloaga and *Urochloa brizantha* (Hochst. ex A. Rich.) Morrone & Zuloaga under shade. *Tropical Grasslands-Forrajões Tropicales*, 40(3), 179-189.

Guzmán, J. G., et al. (2006). Fertility and nutritive value of *Hyparrhenia rufa* (Ness) Stapf and *Hyparrhenia diplandra* (Hack.) Stapf. *Cuban Journal of Agricultural Science*, 40(3), 315-320.

Miles, J. W., et al. (2000). Potential of *Brachiaria* hybrids for improving beef production in the tropics. *Journal of Agricultural Science*, 135(4), 355-362.

Willis, C. G., Ruhfel, B. R., Primack, R. B., Miller-Rushing, A. J., Losos, J. B., & Davis, C. C. (2010). Favorable climate change response explains non-native species' success in Thoreau's woods. *PLoS One*, 5(1):e8878. doi:10.1371/journal.pone.0008878

Wolkovich, E. M., & Cleland, E. E. (2011). The phenology of plant invasions: A community ecology perspective. *Front Ecol Environ*, 9(5), 287–294. doi:10.1890/100033