



Revista Brasileira de Geografia Física

Homepage: <https://periodicos.ufpe.br/revistas/rbgfe>



Classificação da cobertura do solo com base em imagens RGB e multiespectrais obtidas por VANT para área de floresta seca

Rivaildo da Silva Filho¹, Vicente de Paulo Rodrigues da Silva²

¹Doutor em Engenharia de Recursos Naturais; Programa de Pós-Graduação em Engenharia e Gestão de Recursos Naturais (PPGEGRN); Universidade Federal de Campina Grande (UFCG). ORCID: 0000-0001-5469-6259. E-mail: rivaildofilho@hotmail.com (Autor Correspondente).

²Ph.D.; Professor titular da Universidade Federal de Campina Grande (UFCG). ORCID: 0000-0003-4914-4833. E-mail: vicente.paulo@ufcg.edu.br.

Artigo recebido em 23/12/2023 e aceito em 15/02/2024

RESUMO

A Caatinga Brasileira é um bioma que corresponde à uma das maiores Florestas Tropicais Sazonalmente Secas (FTSS) do mundo e o entendimento da cobertura do solo nesta área contribui para estudos voltados a preservação ambiental e a mitigação de impactos ambientais. Um dos desafios na classificação da cobertura do solo nessa área é a distinção entre os diferentes padrões vegetativos. Nesse contexto, surgem os Veículos Aéreos Não Tripulados (VANT's) capazes de obter dados com alta resolução espacial e superar esta limitação. Esta pesquisa avalia a precisão da classificação da cobertura do solo através de dados obtidos a partir de VANT com câmera multiespectral embarcada. Duas abordagens utilizando o classificador Random Forest (RF) foram aplicadas, a primeira baseada nas bandas Red, Green, Nir e no NDVI obtidos da câmera multiespectral e a outra baseada nas bandas Red, Green, Blue e no NGRDI obtidos da câmera nativa do VANT. Os resultados das classificações foram avaliados com base em amostras de validação do modelo e indicam que a primeira abordagem apresentou o melhor desempenho com Acurácia Global de 95,33% e Coeficiente kappa de 93,33%. A variável mais importante, segundo índice MDG, foi o NDVI, o que mostra a importância do uso de índices de vegetação para realçar as características vegetativas. A partir dos resultados, conclui-se que o uso de VANT com a câmera Mapir Survey 3w embarcada é uma ferramenta eficiente para classificação da cobertura do solo na Caatinga, com alta capacidade de distinção dos padrões vegetativos.

Palavra-chave: Sensoriamento remoto, Random Forest, Drone, Semiárido, Caatinga.

Land Cover classification based on RGB and multispectral images obtained by UAV for dry forest area

ABSTRACT

The Brazilian Caatinga is a biome that corresponds to one of the largest Seasonally Dry Tropical Forests (FTSS) in the world and understanding the Land cover in this area contributes to studies aimed at environmental preservation and mitigation of environmental impacts. One of the challenges in classifying land cover in this area is the distinction between different vegetative patterns. In this context, Unmanned Aerial Vehicles (UAVs) emerge, capable of obtaining data with high spatial resolution and overcoming this limitation. This research evaluates the accuracy of land cover classification using data obtained from a UAV with an onboard multispectral camera. Two approaches using the Random Forest (RF) classifier were applied, the first based on the Red, Green, Nir and NDVI bands obtained from the multispectral camera and the other based on the Red, Green, Blue bands and NGRDI obtained from the UAV's native camera. The classification results were evaluated based on model validation samples and indicate that the first approach presented the best performance with Global Accuracy of 95.33% and Kappa Coefficient of 93.33%. The most important variable, according to the MDG index, was the NDVI, which shows the importance of using vegetation indices to highlight vegetative characteristics. From the results, it is concluded that the use of UAVs with the onboard Mapir Survey 3w camera is an efficient tool for classifying soil cover in the Caatinga, with a high capacity for distinguishing vegetative patterns.

Keywords: Remote sensing, Random Forest, Drone, Semi-arid, Caatinga.

Introdução

Estudos mais recentes sobre o

comportamento da vegetação, com foco na análise de grandes áreas, têm utilizado índices de vegetação (IV) para análises de cobertura do solo, adquiridos por sensores de resolução espacial moderada acoplados à satélites, como MODIS e o LANDSAT, é o caso dos trabalhos na China (Li *et al.*, 2017; Lu *et al.*, 2016) e na África (Di Vittorio e Georgakakos, 2018). Contudo, em áreas pequenas e com heterogeneidade marcante, como na Caatinga, utilizar dados de sensores com resolução moderada podem resultar em interpretações incorretas sobre a cobertura do solo (Liu *et al.*, 2016). Nesse sentido, segundo Boschetti (2015), imagens obtidas a partir de sensores de resolução espacial mais alta, são ideais por fornecerem informações espaciais muito mais detalhadas.

A utilização de Veículos Aéreos Não Tripulados (VANT's) é uma alternativa para superar essa limitação, uma vez que é possível a obtenção de dados multiespectrais em alta resolução espacial e temporal, permitindo captar aspectos importantes da vegetação. (Sampaio *et al.*, 2020; Gomes *et al.*, 2021).

O monitoramento do ambiente baseado em imagens aéreas obtidas por VANT's tem se tornado cada vez mais comum (Anderson E Gaston, 2013; Silveira *et al.*, 2022; Carvalho e Carvalho, 2022; Santos *et al.*, 2021; Santos *et al.*, 2022). Os VANT's podem ser equipados com sensores RGB, multiespectrais, hiperespectrais e ativos. Embora Olariu *et al.* (2022) apresentaram resultados satisfatórios usando apenas câmeras RGB, sensores multiespectrais e hiperespectrais também podem ser usados para mapear vegetação (Kattenborn *et al.*, 2019; Berni *et al.*, 2009; Strecha *et al.*, 2012). Porém, faltam estudos comparando a precisão de sensores RGB e multiespectrais para classificação da cobertura do solo, aplicados à vegetação da Caatinga.

Além disso, a partir do processamento das imagens obtidas com sensores multiespectrais acoplados em VANT, é possível também a obtenção de IV's. Os IV's são sensíveis as diferentes características da vegetação - clorofila, nutrientes, pigmentos, biomassa e teor de água nas folhas, dentre outros (Giovos *et al.*, 2021). Um dos índices mais utilizados para esta finalidade é o NDVI, ele tem sido aplicado em imagens obtidas em VANTs para diversos estudos ambientais, a exemplo de Lima júnior *et al.* (2014), que propõem o uso do índice para estimativa da biomassa na Caatinga; Santos *et al.* (2017) e Brito *et al.* (2020) analisando a sazonalidade da Caatinga, dentre outros.

Diversas pesquisas realizadas na Caatinga lograram êxito na utilização de imagens de alta

resolução obtidas a partir de câmeras multiespectrais acopladas em VANT para uma infinidade de aplicações, como no estudo de Santos *et al.* (2022) em que os autores analisaram o índice de área foliar para uma área de Caatinga em Petrolina – PE, além do estudo de Santos *et al.* (2021) que utilizaram dados de NDVI obtidos a partir de VANT para verificar a precisão dos sensores acoplados aos satélites Sentinel – 2 e Landsat- 8 para captação das características estruturais da vegetação na Caatinga. Áreas de pastagem e cultivo também obtiveram sucesso com aplicação de VANT, é o caso do estudo de Sampaio *et al.* (2020) que compararam índices de vegetação gerados a partir de imagens de alta resolução obtidos a partir de VANT com os mesmos índices gerados a partir de imagens Landsat-8 para uma área de pastagem na Embrapa – SP e da pesquisa de Sá (2022) que aplicou imagens obtidas por VANT para uma área de cultivo no submédio do são francisco em Juazeiro-BA.

Pela característica heterogênea da Caatinga e pela alta resolução espacial obtidas com os VANT's, a combinação de sensores para a finalidade de classificação da cobertura do solo exige alta capacidade de processamento de dados. Algoritmos de aprendizado de máquina são ferramentas amplamente utilizadas na classificação de sensoriamento remoto. Eles podem modelar assinaturas de classes complexas e aceitar diferentes tipos de dados de entrada, incluindo dados sem distribuição normal. Há evidências suficientes do desempenho superior dos algoritmos de aprendizado de máquina em relação às técnicas tradicionais, como a estimativa de máxima verossimilhança (Pal *et al.*, 2002; Pal *et al.*, 2003; Belgiu *et al.*, 2016 e Maxwell *et al.*, 2018).

Um desses algoritmos é o *Random Forest* (RF) (Breiman, 2001), ele tem apresentado bons resultados para aplicação em classificação de cobertura do solo (Ghosh e Joshi, 2014; Chen *et al.*, 2018; Andrade *et al.*, 2021). O RF é um algoritmo de aprendizado de máquina que se baseia na técnica de ensemble, o que significa que ele combina várias árvores de decisão para realizar a classificação.

O diferencial do algoritmo RF reside em sua capacidade de criar múltiplas árvores de decisão independentes durante o treinamento. Cada árvore é treinada em uma subamostra aleatória dos dados de treinamento, o que ajuda a reduzir o risco de overfitting, onde o modelo se ajustaria em excesso aos dados de treinamento. Durante a classificação, todas as árvores contribuem para a decisão final, e a classe mais votada é atribuída a cada pixel na imagem de sensoriamento remoto. Além disso, fornece informações sobre a

importância das variáveis preditoras usadas no processo de classificação, isso é importante para entender quais características ou bandas espectrais são mais relevantes para a classificação do solo, auxiliando na interpretação dos resultados e na identificação de padrões significativos.

Neste sentido, o objetivo deste trabalho é avaliar a precisão da classificação da cobertura do solo para uma área de Caatinga, Floresta Tropical Sazonal Seca (FTSS) brasileira, localizada no município de Patos-PB, a partir de dados RGB e multiespectrais de alta resolução espacial obtidos com uso de VANT, utilizando o classificador *Random Forest*.

Material e métodos

Área de estudo e aquisição de dados

A área de compreensão desta pesquisa está totalmente inserida no Semiárido do Brasil (Figura 1), nos domínios do Bioma Caatinga, que é uma FTSS com inúmeras variações paisagísticas. Segundo o IBGE (2012) ela é classificada como Savana Estépica, com área mais representativa abrangendo a Caatinga do Semiárido Nordeste. O clima predominante, conforme a classificação climática de Köppen, é do tipo Semiárido e de subtipo seco e quente (BSh), com precipitação pluvial anual variando entre os valores médios aproximados a 300,0 mm e 600,0 mm e temperatura média superior a 26°C. O período chuvoso na região de Patos – PB começa em janeiro/fevereiro e encerra-se em maio/junho, enquanto o período de estiagem (seco) é prolongado, de seis a sete meses, tendo início em maio/junho e estendendo-se até dezembro. A precipitação média a partir de uma série histórica dos últimos 10 anos (2013 a 2023) foi de aproximadamente 398 mm/ano, os dados são provenientes da estação meteorológica do Instituto Nacional de Meteorologia (INMET), instalada na sede da Empresa Brasileira de Pesquisa Agropecuária (EMBRAPA), de coordenadas 7°4'47'' S e 37°16'22'' O.

A bacia do riacho do Frango percorre diversos bairros da cidade como: Belo Horizonte, Jardim Lacerda, Bela Vista, Jardim Europa, e deságua no Rio Espinharas, sendo a principal bacia hidrográfica urbana do município.

Neste estudo foram utilizadas imagens obtidas a partir de duas câmeras: Multiespectral Mapir Survey 3W RGN (R – red , G – Green , N – Nir (Near infrared)) acoplada ao VANT com 87° HFOV (19mm) e abertura f/2.8 e a câmera RGB (R

– red , G – Green , B – Blue) modelo CMOS 1/2.3'' FOV 78.8° 26 mm (formato equivalente a 35 mm) e abertura f/2.2, nativa do DJI Mavic Pro, ambas com resolução de 12 MP (4000 x 3000 pixels) e com Sistema de Posicionamento Global (GPS) embarcado.

A Figura 2 apresenta os equipamentos utilizados nesta pesquisa. Os voos sobre a área de estudo foram realizados entre 22/09/2023 e 22/10/2023 sempre no horário compreendido entre 12:00 e 14:00 hrs, para minimizar o efeito de sombreamento nas imagens, com condições de céu claro. O período de coleta dos dados está totalmente compreendido na estação seca, tendo o último evento de chuva ocorrido no dia 20/08/2023 para o município de Patos-PB, segundo dados da AESA (2023). O percurso de cada voo foi previamente definido no Google Earth e depois exportado em formato kml para a plataforma online Drone Deploy, a partir da qual os outros parâmetros do planejamento de voo puderam ser definidos, os quais estão indicados na tabela 1. A partir das predefinições inseridas, o Drone deploy apresenta o tempo de voo, a quantidade de baterias e quantidade de imagens necessárias a serem captadas e envia as informações para o drone, que realiza o voo de forma automática, coletando as imagens de maneira a garantir as sobreposições definidas.

Tabela 1. Parâmetros do planejamento de voo no *Drone Deploy*.

Parâmetro	Valor adotado
Altura de voo	120 m
Velocidade de voo	10 m/s
Sobreposição frontal	75%
Sobreposição lateral	75%
Ângulo de inclinação do gimbal da câmera	-90°

Para a câmera Mapir suurvey 3W RGN os ajustes de configurações para melhor desempenho na captura das fotos foram realizados na própria câmera e estão indicados na tabela 2. A Mapir foi acoplada no VANT de forma a garantir o mesmo ângulo de captura da câmera RGB.

Tabela 2. Parâmetros do planejamento de voo no *Drone Deploy*.

Parâmetro	Valor adotado
Intervalo de disparo	2 s
ISO	100
Equilíbrio do branco	automático
Exposição	+0,0
Ângulo de inclinação do gimbal da câmera	-90°




Figura 1. Localização da área de estudo: 1, 2 e 3 referem-se as áreas selecionadas.




Figura 2. Equipamentos utilizados na pesquisa: Controle RC Mavic Pro (A), Drone DJI Mavic Pro com câmera e GPS acoplados (B) e Câmera multiespectral Mapir Survey 3w (C).

Processamento dos dados

As imagens multiespectrais obtidas pela Mapir inicialmente foram calibradas e corrigidas espectralmente utilizando o software Mapir Camera Control (MCC), fornecido pelo próprio fabricante, disponível para download na homepage da marca. No ambiente do software MCC foram inseridas às

imagens captadas em formato JPEG + RAW e como saída, após o processamento, as imagens são convertidas em formato TIFF e guardadas em uma pasta pré-definida (geralmente a mesma pasta de origem das imagens de entrada). Já para as imagens em formato JPEG obtidas pela câmera RGB não se faz necessária nenhuma etapa de pré-processamento.

Logo após, todas as imagens aéreas foram processadas utilizando o software *Agisoft Metashape* (Agisoft LLC, Russo), no qual seis etapas são necessárias para o processamento das imagens, que inclui o alinhamento de fotos, construção de malha, a geração da nuvem densa de pontos, o modelo digital de elevação, a geração do ortomosaico e, por último, a exportação do ortomosaico em formato *TIFF*. Esse processo foi realizado de forma separado para as imagens coletadas de cada câmera e a quantidade de imagens utilizadas em cada processo foi aquela referente à uma semana de coleta de dados, média de 1500 imagens por processamento, perfazendo uma área de aproximadamente 100 hectares para cada etapa. Essa quantia foi definida de acordo com o tempo de processamento do software, de forma a otimizar a geração dos ortomosaicos, que, ao final do processamento, apresentaram uma resolução espacial de 5,5 cm/pixel para Mapir e 4,0 cm/pixel para câmera nativa do VANT.

Com os ortomosaicos prontos, foi utilizado o software QGIS na sua versão 3.32.3 para união dos mesmos, obtendo assim uma única imagem no formato *TIFF* representando toda a área de estudo. A partir da imagem resultante da união, foram analisadas as condições de sombreamento de nuvens na imagem e definidas áreas específicas nesta ortofoto para a classificação proposta neste trabalho. Foram escolhidas três áreas, com a área 1 correspondendo à 16,6 ha, área 2 com 17,35 ha e a área 3 com 12,32 ha, indicadas na Figura 3. Os critérios de escolha foram: enquadramento na Bacia do Riacho do Frango, ausência de sombra de nuvens e ausência de áreas urbanizadas. Ainda no ambiente do QGIS, a partir da ferramenta “extração de dados”, a ortofoto foi recortada para as áreas de interesse. Por último, foram extraídas as bandas espectrais para as áreas escolhidas, sendo 3 bandas (R, G e B) para a câmera nativa e 3 bandas (R, G, Nir) para a câmera Mapir. As bandas foram então salvas em formato *TIFF* para posterior normalização.

Com as bandas de cada imagem prontas, foi utilizado um script dentro da plataforma *Rstudio* para normalizar os valores de cada banda através do método de normalização pela média (*mean-based normalization*). Essa abordagem foi utilizada para equalizar as escalas das diferentes bandas espectrais, o que é especialmente útil para comparar ou combinar informações de várias bandas em sensoriamento remoto ou análise de imagens multiespectrais aplicadas em algoritmos de classificação como o RF. Além disso, ajuda a reduzir o efeito de diferentes níveis de iluminação

ou sensibilidade do sensor em cada banda. Ainda na plataforma do *Rstudio*, com as bandas já normalizadas, foram gerados os IV's que, além das bandas normalizadas, servirão como parâmetros de entrada para o RF: *NDVI* (Equação 1), obtido com as bandas normalizadas da Mapir e do *NGRDI* (Equação 2), obtido pelas bandas normalizadas do sensor nativo do drone.

$$NDVI = \frac{Nir - Red}{Nir + Red} \quad \text{Eq. (1)}$$

$$NGRDI = \frac{Green - Red}{Green + Red} \quad \text{Eq. (2)}$$

Definição de classes de cobertura e coleta de amostras

A definição das classes de cobertura do solo da Caatinga seguiu a metodologia proposta por Chaves et al. (2008). Esses autores estudaram a vegetação da Caatinga em seus diferentes estágios de antropização, tendo como parâmetros: o tamanho, características morfológicas e graus de cobertura, como indicado na Figura 3.




Figura 3. Grupos e classes para a vegetação Caatinga, Fonte: Chaves et al. (2008).

Segundo os autores, utilizando combinações desses grupos e classes de acordo com a porcentagem de cada grupo na parcela analisada, 201 padrões de vegetação Caatinga poderiam ser diferenciados. Neste trabalho, a partir da análise visual de campo e das imagens, foram diferenciados apenas 3 padrões, quais sejam: Arbustiva Arbórea

Densa (AAD), Subarbastiva Muito Rala (SMR) e Solo Exposto (SE), que serão aplicados na coleta de amostras e na classificação. A imagem apresentada

na Figura 4 exemplifica a distribuição destas classes para uma pequena parcela de solo na área de estudo.




Figura 4. Classes de cobertura identificadas na área de estudo: AAD (A), SMR (B) e SE (C).

Na coleta de amostras foram utilizados 135 pontos para identificar os diferentes agrupamentos vegetais, sendo 15 pontos para cada uma das três classes, totalizando 45 pontos em cada área avaliada. Essas amostras foram definidas dentro do ambiente do QGIS e exportadas de forma agrupada para cada área em um único arquivo no formato shapefile. Do total de pixels amostrados para cada classe (15), 70% (10) foram utilizados para o treinamento do modelo e 30% (5) para teste, definidos de forma aleatória. Os dados utilizados para treinamento e validação do modelo em cada área avaliada estão indicados no material suplementar.

Classificação da cobertura do solo

Nesta etapa foi utilizado script desenvolvido dentro da plataforma Rstudio, aplicando o pacote Random Forest R (Liaw e wiener, 2002). O RF é um classificador baseado em árvores de decisão, que estabelece regras para a tomada de decisão, que por sua vez dependem das variáveis preditoras. O algoritmo então, cria uma

estrutura similar à um fluxograma, onde as condições são verificadas em cada “nó” e, dependendo do resultado se positivo ou negativo, segue por ramos diferentes, até a finalização da

árvore. Os principais parâmetros do RF, definidos pelo usuário, são o número máximo de árvores de decisão a serem geradas no fluxograma (ntree) e o número de variáveis usadas aleatoriamente para dividir cada nó (mtry) da árvore (Belgiu Edrăgut, 2016; Htitiou et al., 2019). Neste estudo, foram utilizadas mil (1.000) árvores de decisão e o mtry foi definido como a raiz quadrada do número de variáveis preditoras, neste caso duas (2). Além disso, as amostras coletadas foram separadas em duas partes: treinamento e teste, que correspondem à 70% e 30% das amostras, respectivamente. Para classificação foram utilizadas duas abordagens distintas, quais sejam:

- Método 1. Classificação baseada em quatro variáveis preditoras correspondentes às bandas normalizadas do vermelho (R), verde (G), Infravermelho Próximo (Nir) e o NDVI, obtidos a

partir de um ortomosaico de alta resolução espacial, cujos dados foram captados da câmera Mapir Survey 3W (RGN) acoplada ao VANT.

- Método 2. Classificação baseada em quatro variáveis preditoras correspondentes às bandas normalizadas do vermelho (R), verde (G), azul (B) e o NGRDI, obtidos a partir de um ortomosaico de alta resolução espacial, cujos dados foram captados da câmera RGB nativa do drone.

Importância das variáveis e precisão da classificação

Para avaliar a importância de cada variável para precisão da classificação no RF em cada modelo, foi utilizado o Mean Decrease Gini (MDG) (Corcoran et al., 2013; Nitze et al., 2015). Quanto maior for o valor do indicador, maior será o grau de importância da variável (Zhang et al., 2019). Finalmente, foi verificado qual melhor método para classificação da área de estudo através dos índices: Acurácia Global (AG), Coeficiente Kappa (k), Precisão do produtor (PP) e Precisão do usuário (PU), obtidos a partir da matriz de confusão de cada método em cada uma das três áreas avaliadas. O Mean Decrease Gini (MDG) (Nitze et al., 2015) é um índice utilizado no RF para definir a importância das variáveis preditoras (Equação 3), e é utilizado para selecionar a melhor divisão em cada nó da árvore, calculando a impureza de cada variável no modelo (Jin et al., 2018).

$$\text{MDG} = \sum_{i=1}^n p_k(1 - p_k) = 1 - \sum_{i=1}^n p_k^2, \text{Eq. 3}$$

Onde, p_k é a probabilidade da n ésima categoria entre as n categorias. Quanto maior for o valor do índice MDG, maior será a importância da variável preditora avaliada e indica também a qualidade da classificação realizada. A precisão da classificação supervisionada pode ser realizada com base em quatro indicadores de desempenho de precisão calculados a partir da matriz de confusão: Acurácia Geral (AG), Coeficiente Kappa (k), precisão do produtor (PP) e precisão do usuário (PU). A matriz de confusão, Segundo Foody (2022), é uma tabela que descreve o desempenho de um modelo de classificação em termos de suas previsões para cada classe com base nos valores de referência indicados nos dados de treinamento do modelo, como indica a tabela 3.

Tabela 3. Matriz de confusão genérica.

Classes	Dados de referência				
	C1	C2	C3	Cm	Total
C1	X11	X12	X13	X1m	X1+
C2	X21	X22	X23	X2m	X2+
C3	X31	X32	X33	X3m	X3+
C4	Xm1	Xm2	Xm3	Xmm	Xm+
Total	X+1	X+2	X+3	X+m	n

C = classe de cobertura, m = total de classes e n = total de pontos avaliados.

O coeficiente de concordância Kappa (k) utiliza todos os elementos da matriz de confusão em seu cálculo (Equação 4). Valores de k menores que 0 significa nenhuma concordância e próximos de 1 significa concordância perfeita, ele constitui um importante avaliador de precisão na análise de imagens.

$$k = \frac{n \sum_{i=1}^m x_{ii} - \sum_{i=1}^m x_{i+} \cdot x_{+i}}{n^2 - \sum_{i=1}^m x_{i+} \cdot x_{+i}}, \text{Eq. 4}$$

Onde, n é o número total de amostras e m é número total de classes, x_{ii} é o valor da diagonal da matriz de confusão na linha e na coluna i, x_{i+} é a soma da linha i e x_{+i} é a soma da coluna i da matriz.

Já a Acurácia Geral (AG) mede a taxa global de previsões corretas feitas pelo modelo em relação ao número total de previsões, ou seja, é quociente da soma dos elementos da diagonal principal da matriz de confusão pelo número total de amostras de referência (Equação 5).

$$\text{AG} = \frac{x_{11} + x_{22} + x_{33} \dots + x_{mm}}{n}, \text{Eq. 5}$$

A precisão do produtor (PP), também conhecida como sensibilidade ou Taxa de Verdadeiros Positivos, é o quociente do número total de amostras classificadas corretamente pelo número total de amostras de referência para aquela classe (Equação 6). Já a precisão do usuário (PU), também conhecida como Valor Preditivo Positivo, é o quociente entre a quantidade total de amostras classificadas corretamente da classe pelo número total de amostras classificadas naquela classe (Equação 7).

$$\text{PP} = \frac{x_{ii}}{x_{+i}}, \text{Eq. 6}$$

$$\text{PU} = \frac{x_{ii}}{x_{i+}}, \text{Eq. 7}$$

Todos os índices analisados (AG, k, PP e PU) variam de 0 até 100%, valores que representam o pior e o melhor desempenho do método de classificação, respectivamente.

Resultados e discussão

Classificação para área 1

A classificação realizada para a área 1 (Figura 5A), utilizando as bandas do Nir, R, G e *NDVI* (método 1) apresentou uma melhor acurácia global (AG = 0,93) quando comparada à classificação realizada pelo método 2 (Figura 5B), utilizando as bandas do R, G, B e *NGRDI*, cujo valor de AG foi de 0,40. Na análise do índice Kappa, o método 1 também apresentou resultado superior ao método 2, com valores de k de 0,90 e 0,10, respectivamente.




Figura 5. Classes de cobertura de solo para a área 1: método 1 (A) e método 2 (B).

As diferenças presentes nas duas classificações tornam-se ainda mais evidentes a partir da análise da porcentagem de cobertura de cada classe em cada método. As Figuras 6A e 6B indicam a porcentagem de cobertura de cada classe para o método 1 e 2, respectivamente.




Figura 6. Porcentagem das classes de cobertura para a área 1: método 1 (A) e método 2 (B).

É possível notar que as porcentagens de cobertura para classe SE foram muito próximas, indicando que nesta área os dois métodos apresentaram bons resultados para detecção desta classe, com valores de PU e PP de 100,0% para o método 1 e 80,0% para o método 2, como mostrado nas Tabelas 4A e 4B referentes à matriz de confusão nos métodos 1 e 2, respectivamente. O método 2 apresentou desempenho insatisfatório ao classificar os pixels para as classes AAD (PU=PP=0,0%) e SMR (PP = 40,0% e PU = 29,0%), ao passo em que o método 1 apresentou valores de PU e PP iguais à 83,0% e 100,0% na classe AAD e 100,0% e 80,0% na classe SMR, nesse caso, com desempenho muito superior ao método 2. A partir dos gráficos apresentados nas Figuras 7A e 7B é possível perceber que as classes AAD e SMR apresentaram as maiores diferenças entre os métodos (23,09% e 23,04%, respectivamente).

Tabela 4. Matrizes de confusão para a área 1.

Matriz de confusão - método 1					
Classes	AAD	SMR	SE	Total	PU (%)
AAD	5	1	0	6	83
SMR	0	4	0	4	100
SE	0	0	5	5	100
Total	5	5	5	15	-
PP (%)	100	80	100	AG (%)	93
k	0,9				

Matriz de confusão - método 2					
Classes	AAD	SMR	SE	Total	PU (%)
AAD	0	2	1	3	0
SMR	5	2	0	7	29
SE	0	1	4	5	80
Total	5	5	5	15	-
PP (%)	0	40	80	AG (%)	40
k	0,10				

A. Método 1 e B. Método 2.

Além disso, através da análise do MDG é possível notar que a variável preditora com maior importância no método 1 para a área 1 foi a banda Red, seguido pelo NDVI. A variável menos importante foi a banda Green, como mostra a Figura 7A. No método 2 a variável mais importante foi o NGRDI, seguida pelas bandas Green e Red. A banda com menor importância para o método 2 foi a banda Blue, como mostra a Figura 7B.




Figura 7. Importância das variáveis preditoras por MDG na área 1: método 1 (A) e método 2 (B).

As Figuras 8A e 8B apresentam os boxplots para os dados de treinamento das bandas e índices analisados para as 3 classes de cobertura identificadas na área 1 nos métodos 1 e 2, respectivamente. É possível notar que o NDVI calculado a partir das bandas Red e Nir da câmera Mapir Survey 3W foi a melhor variável entre todas para captar as diferenças entre as classes. De forma geral todas as variáveis preditoras do método 1 se mostram mais eficazes na diferenciação entre as classes, quando se observa os boxplots das Figuras 8A e 8B. Além disso, é possível perceber que o NDVI apresentou maiores valores para as classes AAD e SMR e menores valores para a classe SE, como era esperado para o índice.

Já para o método 2, o índice NGRDI obteve desempenho semelhante ao apresentar maiores valores para as classes AAD e SMR e menores para SE. Ainda pode-se notar através da Figura 8B, que as classes de SE e SMR apresentaram valores semelhantes para todas as variáveis, o que dificulta a diferenciação entre essas classes e

consequentemente interfere no desempenho do método 2. Por fim, ao analisar as bandas Green e Red para as duas câmeras, é possível notar que as bandas obtidas a partir da câmera Mapir Survey 3W (método 1) apresentaram maior capacidade de diferenciação entre as classes, quando comparadas as mesmas bandas para a câmera RGB.





Figura 8. Boxplots para os dados de treinamento na área 1: método 1 (A) e método 2 (B).

Ao realizar a análise dos IV's obtidos por cada câmera, pode-se notar que o NDVI apresenta melhor desempenho do que o NGRDI para diferenciação entre as classes, isso torna-se claro a partir da análise das Figuras 9A e 9B e pode ser explicado pelo fato do NDVI incorporar a banda do Infravermelho próximo (Nir) que capta informação importantes da fisiologia da vegetação não absorvidas pelas bandas Green e Red do espectro visível, as quais são utilizadas para o cálculo do NGRDI.

A.



Classificação para área 2

Para a área 2, a classificação pelo método 2 apresentou $AG = 0,87$ e $k = 0,80$, valores bem próximos do método 1 que teve desempenho melhor com AG igual à $0,93$ e k igual à $0,90$. As Figuras 11A e 11B apresentam as classificações obtidas pelo método 1 e 2, respectivamente.

Apesar do desempenho semelhante, é possível perceber que no método 2 (Figura 11B), a classe SE apresentou uma cobertura bem superior quando comparada com a classificação realizada pelo método 1 indicada na Figura 11A, o que mostra uma dificuldade do método 2 na separação das classes. Além disso, houveram definições diferentes para as classes AAD e SMR nos dois métodos.




Figura 11. Classes de cobertura de solo para a área 2: método 1 (A) e método 2 (B).

Além disso, houveram definições diferentes para as classes AAD e SMR nos dois métodos. Essas diferenças podem ser melhor visualizadas através das Figuras 12A e 12B.




Figura 9. Comportamento dos IV's para os dados de treinamento em cada classe na área 1.

Por último, a partir de uma análise visual das Figuras 10A e 10B também é possível perceber que o método 1 foi mais preciso ao definir cada uma das classes de cobertura, já que visivelmente a classe AAD é preponderante na área 1, o que corrobora com os resultados encontrados na classificação realizada a partir dos dados da câmera multiespectral.




Figura 10. Ortomosaicos para a área 1 obtidos por: Câmera Multiespectral (A) e Câmera RGB (B).




Figura 12. Porcentagem das classes de cobertura para a área 2: método 1 (A) e método 2 (B).

A partir dos gráficos apresentados nas Figuras 12A e 12B é possível perceber que a classe AAD foi a que apresentou maior diferença na distribuição espacial entre os métodos, seguida por SE e SMR, nessa ordem. Isso pode ser explicado pela matriz de confusão de cada método, indicada nas tabelas 5A e 5B.

Tabela 5. Matrizes de confusão para a área 2.

A.

Matriz de confusão - método 1					
Classes	AAD	SMR	SE	Total	PU (%)
AAD	5	0	0	5	100
SMR	0	5	0	5	100
SE	0	1	4	5	80
Total	5	6	4	15	-
PP (%)	100	83	100	AG (%)	93
k	0,9				

B.


Matriz de confusão - método 2					
Classes	AAD	SMR	SE	Total	PU (%)
AAD	5	0	0	5	100
SMR	0	4	1	5	80
SE	0	1	4	5	80
Total	5	5	5	15	-
PP (%)	100	80	80	AG (%)	87
k	0,8				

A. Método 1 e B. Método 2.

A classe que apresentou melhor desempenho nos dois métodos foi a AAD com valores de PP e PU de 100,0%, seguida pela classe SMR que apresentou valores de PP de 83,0% e 80,0% e valores de PU iguais à 100,0% e 80,0%, nos métodos 1 e 2, respectivamente. Para esta área a classe SE teve o pior desempenho. Além disso, através da análise do MDG é possível notar que a

variável preditora com maior importância no método 1 para a área 2 foi o NDVI, seguido pelo Nir. A variável menos importante foi a banda Green, como mostra a Figura 13A. No método 2 a variável mais importante foi a banda Blue, seguida pelo NGRDI, como indicado na figura 13B.

A.



B.





Figura 13. Importância das variáveis predictorias por MDG na área 2: método 1 (A) e método 2 (B).

As Figura 14A e 14B apresentam os boxplots para os dados de treinamento das bandas e índices analisados para as 3 classes de cobertura identificadas na área 2 nos métodos 1 e 2, respectivamente. É possível notar que o NDVI (calculado a partir das bandas Red e Nir da câmera Mapir Survey 3W) foi a melhor variável entre todas para captar as diferenças entre as classes.

De forma geral todas as variáveis predictorias do método 1 se mostram mais eficazes na diferenciação entre as classes, quando se observa os boxplots das Figuras 14A e 14B. Além disso, é possível perceber que o NDVI apresentou maiores valores para as classes AAD e SMR e menores valores para a classe SE, como era esperado para o índice. Já para o método 2, o índice NGRDI não obteve desempenho semelhante ao apresentar valores maiores para a classe SE e menores para as classes AAD e SMR, o que não é esperado para este índice. Ainda pode-se notar através da Figura 14B, que as classes SE e SMR apresentaram valores semelhantes para todas as variáveis, o que dificulta a diferenciação entre essas classes e consequentemente interfere no desempenho do método 2.

A.



B.





Figura 14. Boxplots para os dados de treinamento na área 2: método 1 (A) e método 2 (B).

Da análise gráfica dos IV's apresentada nas Figuras 15A e 15B observa-se comportamento semelhante ao que ocorreu na área 1, com o NDVI apresentando maior capacidade de distinção entre as Classes AAD, SMR e SE. Além disso, nesta área o NDVI apresentou maiores valores na Classe AAD quando comparado com os valores para a mesma classe na área 1, o que pode ser explicado pela proximidade da área 2 com um corpo hídrico, o que torna a vegetação naquela área mais densa e verde.

A.




B.



Figura 15. Comportamento dos IV's para os dados de treinamento em cada classe na área 2: NDVI (A) e NGRDI (B).

Ainda, a partir das Figuras 16A e 16B, também é possível perceber que o método 1 foi mais preciso ao definir cada uma das classes de cobertura, já que visivelmente a classe AAD é preponderante na área, assim como ocorre para a área 1.

A.



B.





Figura 16. Ortomosaicos para a área 2 obtidos por: Câmera Multiespectral (A) e Câmera RGB (B).

Classificação para área 3

Na área 3, a classificação pelo método 1 apresentou $AG = 1,00$ e $k = 1,00$, melhores resultados entre as áreas e métodos avaliados. Já o método 2 para esta área apresentou $AG = 0,67$ e $k=0,50$, tendo o segundo pior desempenho do método para as três áreas avaliadas, ficando atrás apenas da área 1. Com a diferença no desempenho nos dois métodos era esperado que a distribuição espacial das classes fosse bastante distante entre eles, o que pode ser notado nas Figuras 17A e 17B.

A.



B.






Figura 17. Classes de cobertura de solo para a área 3: método 1 (A) e método 2 (B).

A classe que se apresentou de forma mais semelhante nos dois métodos, foi a SMR, enquanto as classes AAD e SE obtiveram distribuições espaciais bastante distintas. Essas diferenças podem ser melhor visualizadas através das figuras 18A e 18B. É possível perceber que a classe SE foi a que apresentou maior diferença entre os métodos, seguida por AAD e SMR, nessa ordem. Isso pode ser explicado pela matriz de confusão dos dados de treinamento para as duas classes, indicadas nas tabelas 6A e 6B.

A.



B.



■ AAD ■ SMR ■ SE

Figura 18. Porcentagem das classes de cobertura para a área 3: método 1 (A) e método 2 (B).

Tabela 6. Matrizes de confusão para a área 3.

A.

Matriz de confusão - método 1					
Classes	AAD	SMR	SE	Total	PU (%)
AAD	5	0	0	5	100
SMR	0	5	0	5	100
SE	0	0	5	5	100
Total	5	5	5	15	-
PP (%)	100	100	100	AG (%)	100
k	1				

B.


Matriz de confusão - método 2					
Classes	AAD	SMR	SE	Total	PU (%)
AAD	5	0	1	6	83
SMR	0	3	2	5	60
SE	0	2	2	4	50
Total	5	5	5	15	-
PP (%)	100	60	40	AG (%)	67
k	0,5				

A. Método 1 e B. Método 2.

Nesta área, o método 2 apresentou valores de PP e PU bem abaixo do método 1 para as classes SMR e SE, sendo a última de pior desempenho com valores de PP e PU de 40,0% e 50,0%, respectivamente. Esse resultado é condicente com o apresentado na área 2. O método 1 teve o melhor desempenho geral com valores de PP e PU iguais à 100,0% para todas as classes.

Além disso, através da análise do MDG é possível notar que a variável preditora com maior importância no método 1 para a área 3 foi o NDVI, seguido pelo Nir, mesmo resultado obtido na área 2. A variável menos importante foi a banda Green, como mostra a figura 19A. No método 2 a variável mais importante foi a banda Red, seguida pela Blue, como indicado na figura 19B.

A.



B.






Figura 19. Importância das variáveis preditoras por MDG na área 3: método 1 (A) e método 2 (B).

As Figura 20A e 20B apresentam os boxplots para os dados de treinamento das bandas e índices analisados para as 3 classes de cobertura identificadas na área 3 nos métodos 1 e 2, respectivamente. É possível notar que o NDVI foi a melhor variável entre todas para captar as diferenças entre as classes.

De forma geral todas as variáveis preditoras do método 1 se mostram mais eficazes na diferenciação entre as classes. Além disso, é possível perceber que o NDVI apresentou maiores valores para as classes AAD e SMR e menores valores para a classe de SE, como era esperado para o índice. Já para o método 2, o índice NGRDI não obteve desempenho semelhante ao apresentar valores maiores para a classe de SE e menores para as classes AAD e SMR, o que não é esperado para este índice. Ainda pode-se notar através da Figura 20B, que as classes de SE e SMR apresentaram valores semelhantes para todas as variáveis, o que dificulta a diferenciação entre essas classes e consequentemente interfere no desempenho do método 2, assim como ocorreu para a área 2.

A.



B.






Figura 20. Boxplots para os dados de treinamento

na área 3: método 1 (A) e método 2 (B).

Em relação ao comportamento dos IV's observa-se, através das Figuras 21A e 21B, que o NDVI apresentou maior capacidade de distinção entre as Classes AAD, SMR e SE. Além disso, a área 3 apresentou os menores valores de NDVI entre as áreas avaliadas, o que pode ser explicado pela maior porcentagem da classe SE nesta área, já que para esta classe este é um comportamento esperado para o índice. As classes AAD e SMR também apresentaram os menores valores entre todas as áreas, o que indica que o vigor vegetativo nesta área é pequeno, que pode está sendo influenciado pelo avanço da área urbana nesta área.

A.




B.



Figura 21. Comportamento dos IV's para os dados de treinamento em cada classe na área 3: NDVI (A) e NGRDI (B).

Por último, realizando uma análise visual das figura 22A e 22B, também é possível perceber que o método 1 foi mais preciso ao definir cada uma das classes de cobertura, já que visivelmente a classe AAD é preponderante, assim como ocorreu nas áreas 1 e 2.

A.



B.





Figura 22. Ortomosaicos para a área 3 obtidos por: Câmera Multiespectral (A) e Câmera RGB (B).

Análise comparativa do desempenho dos métodos avaliados


Ao avaliar as três áreas, este trabalho indica que o método 1 obteve melhor desempenho na classificação para a Caatinga, isto pode ser validado pelos índices AG e k apresentados pelos dois métodos, os quais estão indicados na Figura 23.

A.



■ Multiespectral ■ RGB

B.



■ Multiespectral ■ RGB

Figura 23. Índices de precisão da classificação: Acurácia Geral – AG (A) e Coeficiente kappa – k (B).

De forma geral o método 1 apresentou melhor desempenho ao avaliar as variações dos índices AG e k nas três áreas, sendo a diferença para o método 2 maior nas áreas 1 e 3.

Conclusões

Na análise de classificação da cobertura do solo para Caatinga é notória a importância do uso de índices de vegetação, isso é indicado pelo MDG nas áreas analisadas, onde as variáveis predictoras mais importantes com maior frequência foram os índices NDVI (método 1) e NGRDI (método 2). Além disso, os gráficos de boxplots apresentados indicam que o NDVI conseguiu melhores resultados na diferenciação entre classes.

Ao analisar todas as áreas ficou evidente que o método 1 testado neste trabalho obteve bom desempenho na classificação da cobertura do solo para a Caatinga com AG média de 95,33% e k médio de 93,33%, diferentemente do método 2 que, para a maioria das áreas, não apresentou bons resultados com AG média de 64,67% e k médio de 46,67%. Isso indica que o uso de câmeras multiespectrais, como é o caso da Mapir Survey 3W, que possam fornecer bons índices como o NDVI, são excelentes ferramentas na análise vegetativa e consequentemente na classificação da cobertura do solo.

De forma geral, é possível afirmar que o método 1 mostrou-se eficiente nas áreas analisadas apresentando bons resultados, o que coloca o Random Forest como uma excelente ferramenta nos processos de classificação de cobertura do solo. Contudo, são necessários mais testes em áreas de Caatinga que possuam uma quantidade maior de padrões vegetativos para garantir a eficácia do

modelo para qualquer porção de Caatinga. Além disso, outras variáveis podem ser inseridas na predição do modelo RF, como outras bandas espectrais, a exemplo da banda termal, e/ou a altura da copa das árvores obtida a partir de um Modelo Digital de Superfície (MDS) e de um Modelo Digital de Elevação (MDT), sabendo que o Random Forest tem a capacidade de receber dados de fontes diversas e com propriedades distintas, o que é uma das importantes vantagens desse classificador.

A qualidade dos dados alcançada com o uso de sensores acoplados em VANT é muitas vezes superior àquela conseguida com dados orbitais captados por satélites, o que torna essa abordagem vantajosa para obtenção precisa de informações sobre a cobertura do solo. Além disso, o mapeamento realizado com o VANT possibilita também alta precisão para aplicações em diversas áreas de Engenharia, como levantamento topográfico, estudos batimétricos de reservatórios, análise do fluxo de vazões em bacias hidrográficas, entre outros. Por fim, conclui-se que o uso de VANT com a câmera Mapir Survey 3W embarcada é uma ferramenta eficiente para classificação da cobertura de solo na Caatinga, com alta capacidade de distinção entre os padrões vegetativos, propiciada principalmente por sua característica multispectral.

Agradecimentos

Ao Programa de Pós-Graduação em Engenharia e Gestão de Recursos Naturais (PPGEGRN) da Universidade Federal de Campina Grande (UFCG). Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pela bolsa de doutorado concedida à Rivaildo da Silva Filho (Processo GM/GD 141214/2019-8). Ao Núcleo de Excelência – PRONEX – Fapesq/CNPq (Termo de concessão 0011/2019, referente ao edital 06/2018) pelo financiamento da pesquisa.

Referências

AESA. Agência Executiva de Gestão das Águas do Estado da Paraíba. (n.d.). Disponível em <http://www.aesa.pb.gov.br/aesa-website/meteorologia-chuvas/>. Acesso em 30 de novembro de 2023

Anderson, K., & Gaston, K. J. (2013). Lightweight unmanned aerial vehicles will revolutionize spatial ecology. *Frontiers in Ecology and the Environment*, 11(3), 138–146. <https://doi.org/10.2307/23470549>

Andrade, J., Cunha, J., Silva, J., Rufino, I., & Galvão, C. (2021). Evaluating single and multi-date Landsat classifications of land-cover in a seasonally dry tropical forest. *Remote*

Sensing, 22, 100–515. <https://doi.org/10.1016/j.rsase.2021.100515>

Belgiu, M., & Drăguț, L. (2016). Random forest in remote sensing: A review of applications and future directions. *ISPRS Journal of Photogrammetry and Remote Sensing*, 114, 24–31. <https://doi.org/10.1016/j.isprsjprs.2016.01.011>

Berni, J., Zarco-Tejada, P. J., Suarez, L., & Fereres, E. (2009). Thermal and narrowband multispectral remote sensing for vegetation monitoring from an unmanned aerial vehicle. *IEEE Transactions on Geoscience and Remote Sensing*, 47, 7722–7738. <https://doi.org/10.1109/TGRS.2008.2010457>

Brito, P. V. S., Santos, T. O., & Morais, Y. B. C. B. (2020). Análise da sazonalidade da vegetação de caatinga do município de Petrolina (Pernambuco) a partir de imagens do satélite Landsat 8-OLI. *Revista Brasileira de Sensoriamento Remoto*, 1, 29–37.

Cai, Z., Jönsson, P., Jin, H., & Eklundh, L. (2017). Performance of smoothing methods for reconstructing NDVI time-series and estimating vegetation phenology from MODIS data. *Remote Sensing*, 9, 12–71. <https://doi.org/10.3390/rs9121271>

Carvalho, R. da S., & Carvalho, J. E. B. (2022). Processamento digital e aprendizado de máquina de imagens aéreas obtidas por aeronaves remotamente pilotadas (RPA) para estimar percentual de cobertura do solo por gramíneas perenes em pomar de citros. Cruz das Almas, BA: Embrapa Mandioca e Fruticultura.

Chaves, I. D. B., Lopes, V. L., Folliott, P. F., & Paes-Silva, A. P. (2008). Uma classificação morfoestrutural para descrição e avaliação da biomassa da vegetação da caatinga. *Revista Caatinga*, 21 (2), 204–213.

Chen, Y., Lu, D., Moran, E., Batistella, M., Dutra, L. V., Sanches, I. D., Silva, R. F. B., Huang, J., Luiz, A. J. B., & Oliveira, M. A. F. (2018). Mapping croplands, cropping patterns, and crop types using MODIS time-series data. *International Journal of Applied Earth Observation and Geoinformation*, 69, 133–147. <https://doi.org/10.1016/j.jag.2018.03.005>

Corcoran, J., Knight, J., & Gallant, A. (2013). Influence of multisource and multitemporal remotely sensed and ancillary data on the accuracy of random forest classification of wetlands in Northern Minnesota. *Remote Sensing*, 5 (7), 3212–3238. <https://doi.org/10.3390/rs5073212>

Di Vittorio, A. C., & Georgakakos, P. A. (2018). Land cover classification and wetland

- inundation mapping using MODIS. *Remote Sensing of Environment*, 204 , 1–17. <https://doi.org/10.1016/j.rse.2017.11.001>
- Foody, G. M. (2002). Status of land cover classification accuracy assessment. *Remote Sensing of Environment*, 80 (1), 185–201. [https://doi.org/10.1016/S0034-4257\(01\)00295-4](https://doi.org/10.1016/S0034-4257(01)00295-4)
- Ghosh, A., & Joshi, P. K. A. (2014). Comparison of selected classification algorithms for mapping bamboo patches in lower Gangetic plains using very high resolution WorldView 2 imagery. *International Journal of Applied Earth Observation and Geoinformation*, 26 , 298–311. <https://doi.org/10.1016/j.jag.2013.08.011>
- Giovas, R., Tassopoulos, D., Kalivas, D., Lougkos, N., & Priovolou, A. (2021). Remote sensing vegetation indices in viticulture: A critical review. *Agriculture*, 11 , 4–57. <https://doi.org/10.3390/agriculture11050457>
- Gomes, A., Queiroz, M. D., Valente, M. S. D., & Pinto, F. (2021). Comparing a single-sensor camera with a multisensor camera for monitoring coffee crop using Unmanned Aerial Vehicles. *Engenharia Agrícola*, 41 (1), 87–97. <https://doi.org/10.1590/1809-4430-Eng.Agric.v41n1p87-97/2021>
- Htitiou, A., Boudhar, A., Lebrini, A., Hadria, Y., Lionboui, R., Mansouri, R., Tychon, L., & Benabdelouahab, B. T. (2019). The performance of Random Forest classification based on phenological metrics derived from Sentinel-2 and Landsat 8 to map crop cover in an irrigated semiarid region. *Remote Sensing in Earth Systems Sciences*, 2 (4), 208–224. <https://doi.org/10.1007/s41976-019-00023-9>
- IBGE. (2022). Manual técnico da vegetação brasileira (271 p.). Rio de Janeiro, RJ: IBGE.
- Kattenborn, T., Lopatin, T., Förster, J., Braun, M., & Fassnacht, A. F. (2019). UAV data as an alternative to field sampling to map woody invasive species based on combined Sentinel-1 and Sentinel-2 data. *Remote Sensing of Environment*, 227 , 61–73. <https://doi.org/10.1016/j.rse.2019.03.02>
- Li, G., Zhang, F., Jing, Y., Liu, Y., & Sun, G. (2017). Response of evapotranspiration to changes in land use and land cover and climate in China during 2001–2013. *Science of the Total Environment*, 596–597 , 256–265. <https://doi.org/10.1016/j.scitotenv.2017.04.080>
- Liaw, A., & Wiener, M. (2002). Classification and regression by Random Forest. *R News*, 2 (3), 18–22.
- Lima, N. A. S., Oliveira, L. M. M., Xavier, M. L. P., Silva Júnior, U. J., & Nascimento, E. F. (2019). Spectral indices for remote sensing with the LANDSAT-5 and SENTINEL-2 satellites around the Poço Cruz reservoir-PE. *Journal of Hyperspectral Remote Sensing*, 9 , 299–309. <http://dx.doi.org/10.29150/jhrs.v9.5.p299-309>
- Liu, R., Shang, R., Liu, Y., & Lu, X. (2017). Global evaluation of gap-filling approaches for seasonal NDVI with considering vegetation growth trajectory, protection of key point, noise resistance and curve stability. *Remote Sensing of Environment*, 189 , 164–179. <https://doi.org/10.1016/j.rse.2016.11.023>
- Lu, M., Chen, J., Tang, H., Rao, Y., Yang, P., & Wu, W. (2016). Land cover change detection by integrating object-based data blending model of Landsat and MODIS. *Remote Sensing of Environment*, 184 , 374–386. <https://doi.org/10.1016/j.rse.2016.07.028>
- Maxwell, A. E., Warner, T. A., & Fang, F. (2018). Implementation of machine-learning classification in remote sensing: An applied review. *International Journal of Remote Sensing*, 39 , 2784–2817. <https://doi.org/10.1080/01431161.2018.1433343>
- Nitze, I., Barrett, B., & Cawkwell, F. (2015). Temporal optimisation of image acquisition for land cover classification with Random Forest and MODIS time-series. *International Journal of Applied Earth Observation and Geoinformation*, 34 , 136–146. <https://doi.org/10.1016/j.jag.2014.08.001>
- Olariu, H. G., Malambo, L., Popescu, S. C., Virgil, C., & Wilcox, B. P. (2022). Woody plant encroachment: Evaluating methodologies for semiarid woody species classification from drone images. *Remote Sensing*, 14 (16), 65. <https://doi.org/10.3390/rs14071665>
- Pal, M., & Mather, P. M. (2003). An assessment of the effectiveness of decision tree methods for land cover classification. *Remote Sensing of Environment*, 86 , 554–565. [https://doi.org/10.1016/S0034-4257\(03\)00132-9](https://doi.org/10.1016/S0034-4257(03)00132-9)
- Pal, M., & Mather, P. M. (2005). Support vector machines for classification in remote sensing. *International Journal of Remote Sensing*, 26 , 1007–1011. <https://doi.org/10.1080/01431160512331314083>
- RStudio. (2020). RStudio: Integrated development for R . Boston: PBC. Disponível em <http://www.rstudio.com/>. Acesso em 21 out. 2021.
- Sá, S. de A. C. (2022). Sensoriamento remoto aplicado em cultivos no submédio São Francisco

- por imageamento aéreo com drones (97 p.).
Dissertação de Mestrado, Universidade Federal do Vale do São Francisco, Juazeiro, BA.
- Sampaio, H. S., Bourscheidt, V., Sarracini, L. H., Jorge, L. A. de C., Bettiol, G. M., & Bernardi, A. C. de C. (2020). Comparação entre índices de vegetação obtidos por imagens aéreas com Veículo Aéreo Não Tripulado (VANT) e satélite. *Revista Brasileira de Engenharia de Biosistemas*, 14, 111-124.
- Santos, C. V. B. Dos, Moura, M. S. B. De, Carvalho, H. F. de S., Galvêncio, J. D., Miranda, R. de Q., Nishiwaki, A. A. M., & Montenegro, S. M. G. L. (2022). Avaliação do índice de área foliar e índice de área da planta em floresta seca utilizando modelos simplificados em imagens de alta resolução com o uso de VANT. *Journal of Hyperspectral Remote Sensing*, 12 (3), 109-123.
- Santos, C. V. B. dos, Moura, M. S. B. de, Galvêncio, J. D., Carvalho, H. F. de S., Miranda, R. de Q., & Montenegro, S. M. G. L. (2021). Comparação de imagens multiespectrais utilizando satélites e VANT para a análise de mudanças estruturais em área de floresta seca. *Revista Brasileira de Geografia Física*, 14 (6), 2510-2522.
- Silva, C. R., Machado, S. L. D., Araújo, A. A., & Abreu Júnior, C. A. M. (2018). Analysis of the phenology dynamics of Brazilian caatinga species with NDVI time series. *Cerne*, 24 (1), 48-58.
<https://doi.org/10.1590/0104776020182401248>
21. Silveira, M. A., Andrade, P., Filho, C., Bremm, M., & Santos, C. F. (2022). Aprendizado de máquina com base na resposta espectral de imagens aéreas obtidas por ANT's e aplicado no manejo de pastagens. *Embrapa Pecuária Sul*.
- Souza, R., Feng, X., Antonino, A., Montenegro, S., Souza, E., & Porporato, A. (2016). Vegetation response to rainfall seasonality and interannual variability in tropical dry forests. *Hydrological Processes*, 30 (20), 3583-3595.
<https://doi.org/10.1002/hyp.10953>
- Strecha, C., Fletcher, A., Lechner, A., Erskine, P., & Fua, P. (2012). Developing species specific vegetation maps using multi-spectral hyperspatial imagery from Unmanned Aerial Vehicles. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 3, 311-316.
<https://doi.org/10.5194/isprsannals-I-3-311-20>
- Zhang, Z., Yang, Z., Ren, W., & Wen, G. (2019). Random forest based real-time defect detection of Al alloy in robotic arc welding using optical spectrum. *Journal of Manufacturing Processes*, 42, 51-59.
<https://doi.org/10.1016/j.jmapro.2019.04.023>

Material Suplementar 1 (MS1) - Amostras de treinamento na área 1 pelo método 1.

Ponto	Nir	Red	Green	NDVI	Classe
17	1,42	0,92	0,66	0,21	AAD
19	1,52	0,78	0,71	0,32	AAD
20	1,43	0,93	0,64	0,21	AAD
21	1,6	0,68	0,73	0,41	AAD
23	1,48	0,85	0,67	0,27	AAD
25	1,48	0,85	0,67	0,27	AAD
26	1,34	0,97	0,69	0,16	AAD
27	1,46	0,84	0,7	0,27	AAD
29	1,46	0,89	0,65	0,24	AAD
30	1,52	0,84	0,64	0,29	AAD
31	1,41	0,96	0,63	0,19	SMR
32	1,2	1,15	0,65	0,02	SMR
33	1,37	0,97	0,66	0,17	SMR
37	1,34	1,04	0,62	0,13	SMR
38	1,42	1,07	0,51	0,14	SMR
39	1,37	0,99	0,64	0,16	SMR
41	1,4	0,99	0,61	0,17	SMR
43	1,33	1,08	0,6	0,11	SMR
44	1,3	1,06	0,63	0,1	SMR
45	1,28	1,07	0,65	0,09	SMR
1	1,12	1,24	0,64	-0,05	SE
5	1,15	1,29	0,57	-0,06	SE
6	1,25	1,17	0,58	0,03	SE
8	1,16	1,28	0,56	-0,05	SE
9	1,19	1,24	0,57	-0,02	SE
10	1,19	1,22	0,6	-0,01	SE
11	1,18	1,31	0,51	-0,05	SE
13	1	1,37	0,63	-0,15	SE
14	1,17	1,23	0,59	-0,03	SE
15	1,15	1,21	0,65	-0,03	SE

AAD. Arbórea Arbustiva Densa; SMR. Subarbustiva Muito Rala e SE. Solo Exposto.

Material Suplementar 2 (MS2) - Amostras de treinamento na área 1 pelo método 2.

Ponto	Red	Green	Blue	NGRDI	Classe
16	1,02	1,00	0,98	-0,01	AAD
18	1,00	1,04	0,96	0,02	AAD
19	1,11	1,04	0,86	-0,03	AAD
20	1,09	1,06	0,85	-0,01	AAD
21	1,08	1,06	0,86	-0,01	AAD
23	1,04	1,12	0,84	0,04	AAD
24	1,04	1,10	0,87	0,03	AAD
25	1,08	0,98	0,94	-0,05	AAD
27	1,05	0,99	0,96	-0,03	AAD
29	1,04	1,08	0,87	0,02	AAD
31	1,03	1,12	0,85	0,04	SMR
32	1,11	0,94	0,95	-0,08	SMR
33	1,03	1,01	0,96	-0,01	SMR
35	1,05	1,00	0,95	-0,03	SMR
36	1,07	0,94	0,99	-0,07	SMR
37	1,06	0,97	0,97	-0,04	SMR
39	1,05	1,00	0,96	-0,02	SMR
40	1,05	0,99	0,97	-0,03	SMR
42	1,03	1,01	0,95	-0,01	SMR
43	1,06	0,99	0,95	-0,04	SMR
1	1,08	1,00	0,92	-0,04	SE
2	1,08	0,99	0,92	-0,04	SE
4	1,11	0,97	0,92	-0,06	SE
5	1,07	0,99	0,94	-0,04	SE
6	1,07	0,98	0,96	-0,04	SE
9	1,06	0,98	0,96	-0,04	SE
10	1,10	0,98	0,92	-0,06	SE
13	1,07	1,00	0,93	-0,04	SE
14	1,08	0,99	0,93	-0,04	SE
15	1,07	0,99	0,94	-0,04	SE

AAD. Arbórea Arbustiva Densa; SMR. Subarbustiva Muito Rala e SE. Solo Exposto.

Material Suplementar 3 (MS3) – Coordenadas geográficas das amostras para a área 1

Ponto	Latitude	Longitude
1	-37,31726	-7,01721
2	-37,31573	-7,01777
3	-37,31524	-7,01579
4	-37,31571	-7,01586
5	-37,31685	-7,01571
6	-37,31440	-7,01778
7	-37,31542	-7,01866
8	-37,31389	-7,01839
9	-37,31372	-7,01820
10	-37,31663	-7,01634
11	-37,31628	-7,01580
12	-37,31616	-7,01534
13	-37,31444	-7,01558
14	-37,31507	-7,01688
15	-37,31745	-7,01783
16	-37,31570	-7,01582
17	-37,31662	-7,01759
18	-37,31403	-7,01892
19	-37,31450	-7,01678
20	-37,31621	-7,01718
21	-37,31439	-7,01657
22	-37,31599	-7,01810
23	-37,31494	-7,01877
24	-37,31639	-7,01543
25	-37,31594	-7,01665
26	-37,31446	-7,01734
27	-37,31474	-7,01765
28	-37,31502	-7,01855
29	-37,31489	-7,01842
30	-37,31719	-7,01811
31	-37,31706	-7,01792
32	-37,31739	-7,01807
33	-37,31484	-7,01765
34	-37,31431	-7,01656
35	-37,31460	-7,01581
36	-37,31435	-7,01579
37	-37,31610	-7,01666
38	-37,31713	-7,01598
39	-37,31678	-7,01723
40	-37,31495	-7,16976
41	-37,31576	-7,01560
42	-37,31690	-7,01836
43	-37,31504	-7,01755
44	-37,31349	-7,01610
45	-37,31584	-7,01582

Material Suplementar 4 (MS4) - Amostras de treinamento na área 2 pelo método 1.

Ponto	Nir	Red	Green	NDVI	Classe
16	2,06	0,71	0,23	0,49	AAD
17	2,01	0,70	0,29	0,48	AAD
19	1,72	0,96	0,33	0,28	AAD
20	2,00	0,73	0,28	0,47	AAD
21	1,64	0,86	0,51	0,31	AAD
22	1,54	0,93	0,53	0,25	AAD
23	1,79	0,91	0,30	0,33	AAD
24	1,49	1,03	0,48	0,18	AAD
26	1,45	1,07	0,48	0,15	AAD
27	1,77	0,91	0,32	0,32	AAD
31	1,37	0,91	0,72	0,20	SMR
34	1,28	1,07	0,66	0,09	SMR
35	1,29	1,07	0,64	0,09	SMR
36	1,32	1,04	0,64	0,12	SMR
37	1,26	1,02	0,71	0,10	SMR
39	1,15	1,12	0,73	0,01	SMR
41	1,20	1,12	0,68	0,04	SMR
42	1,20	1,14	0,66	0,03	SMR
43	1,23	1,04	0,73	0,09	SMR
45	1,05	1,19	0,77	-0,06	SMR
1	1,03	1,42	0,55	-0,16	SE
3	0,97	1,43	0,60	-0,19	SE
7	1,05	1,35	0,59	-0,12	SE
9	1,23	1,19	0,58	0,01	SE
10	1,01	1,39	0,59	-0,16	SE
11	1,06	1,38	0,56	-0,13	SE
12	1,03	1,43	0,53	-0,16	SE
13	0,99	1,43	0,57	-0,18	SE
14	1,11	1,42	0,46	-0,12	SE
15	1,03	1,46	0,51	-0,17	SE

AAD. Arbórea Arbustiva Densa; SMR. Subarbustiva Muito Rala e SE. Solo Exposto.

Material Suplementar 5 (MS5) - Amostras de treinamento na área 2 pelo método 2.

Ponto	Red	Green	Blue	NGRDI	Classe
16	1,00	1,17	0,83	0,08	AAD
18	0,96	1,05	0,99	0,04	AAD
19	0,90	1,25	0,84	0,16	AAD
20	0,91	1,00	1,10	0,05	AAD
21	1,01	1,06	0,93	0,03	AAD
22	1,04	1,08	0,88	0,02	AAD
23	0,98	1,07	0,95	0,05	AAD
25	0,99	1,04	0,97	0,03	AAD
27	0,98	1,06	0,96	0,04	AAD
28	1,03	0,99	0,98	-0,02	AAD
32	0,97	1,01	1,02	0,02	SMR
34	1,01	1,01	0,98	0,00	SMR
35	1,02	1,00	0,98	-0,01	SMR
36	1,02	1,00	0,98	-0,01	SMR
38	0,99	1,00	1,01	0,00	SMR
39	0,98	1,00	1,01	0,01	SMR
40	1,00	1,00	1,00	0,00	SMR
41	0,99	1,01	1,00	0,01	SMR
44	1,00	0,99	1,02	0,00	SMR
45	0,97	0,99	1,04	0,01	SMR
2	1,04	0,98	0,97	-0,03	SE
3	1,01	1,00	0,99	0,00	SE
4	1,03	1,01	0,97	-0,01	SE
5	1,02	1,01	0,97	-0,01	SE
6	1,04	1,00	0,96	-0,02	SE
8	0,98	1,00	1,02	0,01	SE
11	1,08	0,99	0,93	-0,04	SE
12	1,03	0,99	0,98	-0,02	SE
14	1,04	0,99	0,97	-0,03	SE
15	1,06	0,99	0,95	-0,03	SE

AAD. Arbórea Arbustiva Densa; SMR. Subarbustiva Muito Rala e SE. Solo Exposto.

Material Suplementar 6 (MS6) – Coordenadas geográficas das amostras para a área 2

Ponto	Latitude	Longitude
1	-37,30307	-7,02042
2	-37,30077	-7,02145
3	-37,30252	-7,02111
4	-37,30276	-7,01942
5	-37,30130	-7,01962
6	-37,30221	-7,02090
7	-37,30005	-7,02154
8	-37,30051	-7,02102
9	-37,30128	-7,01896
10	-37,30217	-7,02036
11	-37,30208	-7,02153
12	-37,29933	-7,01940
13	-37,29898	-7,01961
14	-37,30116	-7,02067
15	-37,30319	-7,02061
16	-37,30114	-7,02037
17	-37,30057	-7,01999
18	-37,30301	-7,01974
19	-37,29951	-7,01976
20	-37,30085	-7,01936
21	-37,30217	-7,01881
22	-37,30331	-7,02089
23	-37,29941	-7,02094
24	-37,30200	-7,02052
25	-37,30179	-7,01947
26	-37,30367	-7,02010
27	-37,30178	-7,02115
28	-37,30028	-7,01944
29	-37,30317	-7,01863
30	-37,30051	-7,02044
31	-37,30238	-7,02080
32	-37,30252	-7,02086
33	-37,30277	-7,02122
34	-37,30111	-7,02189
35	-37,30263	-7,01885
36	-37,30297	-7,02059
37	-37,30370	-7,02105
38	-37,30161	-7,02183
39	-37,30315	-7,02054
40	-37,30195	-7,02136
41	-37,30080	-7,02157
42	-37,29990	-7,02179
43	-37,30355	-7,02129
44	-37,30346	-7,02132
45	-37,29985	-7,02209

Material Suplementar 7 (MS7) - Amostras de treinamento na área 3 pelo método 1.

Ponto	Nir	Red	Green	NDVI	Classe
16	1,47	1,00	0,54	0,19	AAD
17	1,67	0,89	0,44	0,30	AAD
19	1,54	0,90	0,57	0,26	AAD
20	1,35	1,06	0,59	0,12	AAD
22	1,45	0,99	0,55	0,19	AAD
24	1,38	1,03	0,59	0,14	AAD
25	1,59	0,99	0,42	0,23	AAD
28	1,36	0,95	0,69	0,18	AAD
29	1,82	0,73	0,45	0,43	AAD
30	1,47	0,94	0,59	0,22	AAD
31	1,26	1,09	0,66	0,07	SMR
32	1,25	1,06	0,69	0,09	SMR
33	1,18	1,11	0,71	0,03	SMR
35	1,12	1,17	0,71	-0,03	SMR
37	1,29	1,06	0,65	0,10	SMR
39	1,19	1,14	0,66	0,02	SMR
40	1,24	1,14	0,62	0,04	SMR
41	1,14	1,16	0,70	-0,01	SMR
43	1,19	1,09	0,71	0,04	SMR
44	1,15	1,11	0,74	0,02	SMR
3	1,09	1,26	0,66	-0,07	SE
4	1,01	1,42	0,57	-0,17	SE
7	1,12	1,35	0,53	-0,10	SE
8	0,97	1,39	0,64	-0,18	SE
9	1,05	1,36	0,59	-0,13	SE
10	1,01	1,37	0,62	-0,15	SE
11	1,11	1,21	0,68	-0,04	SE
12	0,99	1,41	0,59	-0,17	SE
14	1,05	1,34	0,61	-0,12	SE
15	1,07	1,35	0,57	-0,11	SE

AAD. Arbórea Arbustiva Densa; SMR. Subarbustiva Muito Rala e SE. Solo Exposto.

Material Suplementar 8 (MS8) - Amostras de treinamento na área 3 pelo método 2.

Ponto	Red	Green	Blue	NGRDI	Classe
16	0,97	1,05	0,98	0,04	AAD
18	1,04	1,00	0,97	-0,02	AAD
19	0,99	0,99	1,02	0,00	AAD
20	0,94	0,99	1,07	0,03	AAD
24	1,01	0,97	1,03	-0,02	AAD
25	0,92	0,96	1,11	0,02	AAD
26	0,99	1,00	1,01	0,01	AAD
28	0,88	1,00	1,13	0,06	AAD
29	1,04	0,99	0,97	-0,02	AAD
30	0,98	0,99	1,03	0,01	AAD
31	1,04	1,01	0,95	-0,01	SMR
32	1,06	1,02	0,93	-0,02	SMR
33	1,02	1,00	0,98	-0,01	SMR
34	1,00	1,00	1,00	0,00	SMR
35	1,00	1,01	0,99	0,00	SMR
36	1,04	1,00	0,96	-0,02	SMR
40	1,01	1,01	0,98	0,00	SMR
41	1,01	1,01	0,98	0,00	SMR
42	1,01	1,01	0,98	0,00	SMR
44	1,02	1,00	0,98	-0,01	SMR
1	1,05	1,01	0,95	-0,02	SE
2	1,03	0,99	0,98	-0,02	SE
3	1,06	1,00	0,94	-0,03	SE
5	1,00	1,01	0,99	0,00	SE
6	1,01	1,01	0,98	0,00	SE
9	1,02	1,00	0,98	-0,01	SE
10	1,06	0,99	0,95	-0,04	SE
12	1,04	1,01	0,95	-0,01	SE
13	1,03	0,99	0,97	-0,02	SE
15	1,02	1,00	0,98	-0,01	SE

AAD. Arbórea Arbustiva Densa; SMR. Subarbustiva Muito Rala e SE. Solo Exposto.

Material Suplementar 9 (MS9) – Coordenadas geográficas das amostras para a área 3.

Ponto	Latitude	Longitude
16	-37,30438	-7,01370
17	-37,30615	-7,01326
19	-37,30397	-7,01400
20	-37,30524	-7,01327
22	-37,30756	-7,01359
24	-37,30756	-7,01461
25	-37,30780	-7,01285
28	-37,30714	-7,01341
29	-37,30420	-7,01450
30	-37,30517	-7,01346
31	-37,30500	-7,01489
32	-37,30446	-7,01506

33	-37,30656	-7,01383
35	-37,30715	-7,01371
37	-37,30586	-7,01312
39	-37,30703	-7,01426
40	-37,30676	-7,01439
41	-37,30726	-7,01400
43	-37,30793	-7,01373
44	-37,30605	-7,01424
3	-37,30444	-7,01475
4	-37,30824	-7,01414
7	-37,30881	-7,01287
8	-37,30808	-7,01447
9	-37,30677	-7,01410
10	-37,30414	-7,01408
11	-37,30394	-7,01484
12	-37,30543	-7,01474
14	-37,30728	-7,01304
15	-37,30785	-7,01346
18	-37,30621	-7,01451
21	-37,30881	-7,01452
23	-37,30651	-7,01361
26	-37,30858	-7,01405
27	-37,30862	-7,01279
34	-37,30836	-7,01419
36	-37,30561	-7,01333
38	-37,30864	-7,01480
41	-37,30726	-7,01400
45	-37,30596	-7,01301
1	-37,30517	-7,01412
2	-37,30596	-7,01413
5	-37,30726	-7,01375
6	-37,30579	-7,01303
13	-37,30492	-7,01366

Material Suplementar 10 (MS10) - Amostras de validação na área 1 pelo método 1.

Ponto	Nir	Red	Green	NDVI	Classe
16	1,38	0,86	0,76	0,23	AAD
18	1,32	1,02	0,67	0,13	AAD
22	1,50	0,89	0,61	0,26	AAD
24	1,49	0,86	0,65	0,27	AAD
28	1,40	1,05	0,54	0,14	AAD
34	1,20	1,10	0,69	0,04	SMR
35	1,22	1,10	0,68	0,05	SMR
36	1,33	1,01	0,65	0,13	SMR
40	1,25	1,07	0,68	0,08	SMR
42	1,33	1,06	0,62	0,11	SMR
2	1,05	1,35	0,59	-0,12	SE
3	1,20	1,26	0,55	-0,02	SE

4	1,07	1,29	0,64	-0,09	SE
7	1,14	1,30	0,56	-0,07	SE
12	1,19	1,20	0,61	-0,01	SE

AAD. Arbórea Arbustiva Densa; SMR. Subarbustiva Muito Rala e SE. Solo Exposto.

Material Suplementar 11 (MS11) - Amostras de validação na área 1 pelo método 2.

Ponto	Red	Green	Blue	NGRDI	Classe
17	1,04	0,98	0,98	-0,03	AAD
22	1,04	0,96	0,99	-0,04	AAD
26	1,09	0,98	0,94	-0,05	AAD
28	1,06	1,06	0,88	0,00	AAD
30	1,05	1,04	0,91	-0,01	AAD
34	1,04	1,00	0,96	-0,02	SMR
38	1,03	0,99	0,98	-0,02	SMR
41	1,03	0,99	0,97	-0,02	SMR
44	1,05	1,02	0,93	-0,01	SMR
45	1,04	1,00	0,96	-0,02	SMR
3	1,15	0,95	0,90	-0,10	SE
7	1,07	0,98	0,95	-0,04	SE
8	1,09	0,96	0,95	-0,06	SE
11	1,07	0,98	0,94	-0,04	SE
12	1,08	0,99	0,93	-0,05	SE

AAD. Arbórea Arbustiva Densa; SMR. Subarbustiva Muito Rala e SE. Solo Exposto.

Material Suplementar 12 (MS12) - Amostras de validação na área 2 pelo método 1.

Ponto	Nir	Red	Green	NDVI	Classe
18	1,76	0,89	0,35	0,33	AAD
25	1,47	0,96	0,57	0,21	AAD
28	1,66	0,79	0,55	0,36	AAD
29	1,52	1,01	0,47	0,20	AAD
30	1,60	0,94	0,46	0,26	AAD
32	1,31	1,04	0,65	0,12	SMR
33	1,17	1,17	0,66	0,00	SMR
38	1,24	1,03	0,72	0,09	SMR
40	1,15	1,19	0,66	-0,01	SMR
44	1,30	1,03	0,67	0,11	SMR
2	0,95	1,47	0,58	-0,21	SE
4	1,09	1,36	0,55	-0,11	SE
5	1,10	1,33	0,57	-0,09	SE
6	0,91	1,60	0,50	-0,28	SE
8	0,98	1,45	0,57	-0,19	SE

AAD. Arbórea Arbustiva Densa; SMR. Subarbustiva Muito Rala e SE. Solo Exposto.

Material Suplementar 13 (MS13) - Amostras de validação na área 2 pelo método 2.

Ponto	Red	Green	Blue	NGRDI	Classe
17	0,96	1,07	0,97	0,05	AAD
24	0,97	1,07	0,96	0,05	AAD
26	0,98	1,07	0,95	0,04	AAD
29	0,97	1,00	1,03	0,01	AAD

30	1,12	0,98	0,90	-0,07	AAD
31	1,01	1,00	0,98	0,00	SMR
33	1,00	0,99	1,01	-0,01	SMR
37	1,01	1,01	0,98	0,00	SMR
42	0,98	0,99	1,04	0,01	SMR
43	0,98	1,01	1,01	0,01	SMR
1	1,05	0,99	0,97	-0,03	SE
7	1,04	0,98	0,98	-0,03	SE
9	1,06	0,99	0,95	-0,04	SE
10	1,02	1,00	0,98	-0,01	SE
13	1,05	0,99	0,96	-0,03	SE

AAD. Arbórea Arbustiva Densa; SMR. Subarbustiva Muito Rala e SE. Solo Exposto.

Material Suplementar 14 (MS14) - Amostras de validação na área 3 pelo método 1.

Ponto	Nir	Red	Green	NDVI	Classe
18	1,32	1,06	0,62	0,11	AAD
21	1,29	1,13	0,58	0,07	AAD
23	1,50	0,95	0,54	0,22	AAD
26	1,46	0,98	0,56	0,20	AAD
27	1,47	0,88	0,64	0,25	AAD
34	1,19	1,14	0,68	0,02	SMR
36	1,22	1,07	0,71	0,06	SMR
38	1,29	1,13	0,58	0,06	SMR
41	1,14	1,16	0,70	-0,01	SMR
45	1,26	1,04	0,69	0,09	SMR
1	1,17	1,23	0,60	-0,02	SE
2	1,10	1,36	0,53	-0,11	SE
5	1,13	1,31	0,56	-0,08	SE
6	1,13	1,26	0,61	-0,05	SE
13	1,11	1,32	0,57	-0,08	SE

AAD. Arbórea Arbustiva Densa; SMR. Subarbustiva Muito Rala e SE. Solo Exposto.

Material Suplementar 15 (MS15) - Amostras de validação na área 3 pelo método 2.

Ponto	Red	Green	Blue	NGRDI	Classe
17	0,91	1,03	1,06	0,06	AAD
21	0,98	0,99	1,03	0,00	AAD
22	0,58	1,00	1,42	0,27	AAD
23	0,97	0,98	1,05	0,01	AAD
27	0,93	0,97	1,11	0,02	AAD
37	1,01	0,99	1,00	-0,01	SMR
38	1,05	1,01	0,93	-0,02	SMR
39	1,02	1,01	0,97	0,00	SMR
43	1,01	1,02	0,98	0,00	SMR
45	1,01	1,00	1,00	-0,01	SMR
4	1,05	0,99	0,96	-0,03	SE
7	1,03	1,02	0,95	0,00	SE
8	1,00	1,03	0,97	0,01	SE
11	1,03	1,00	0,97	-0,02	SE
14	1,02	1,00	0,97	-0,01	SE

AAD. Arbórea Arbustiva Densa; SMR. Subarbustiva Muito Rala e SE. Solo Exposto.