

MAPEAMENTO DA DISTRIBUIÇÃO ESPACIAL E VARIAÇÃO TEMPORAL DA VEGETAÇÃO RUPESTRE NA SERRA DO CIPÓ – MG ATRAVÉS DE IMAGENS DE SENSORIAMENTO REMOTO OBTIDAS POR AERONAVES REMOTAMENTE PILOTADAS

Thais Pereira de Medeiros¹, Thiago Sanna Freire Silva², Leonor Patrícia Cerdeira Morellato³

¹ UNESP – Universidade Estadual Paulista, Instituto de Geociências e Ciências Exatas, Campus de Rio Claro, Ecosystem Dynamics Observatory (EcoDyn), thaismedeiros97@hotmail.; ² UNESP – Universidade Estadual Paulista, Instituto de Geociências e Ciências Exatas, Campus de Rio Claro, Ecosystem Dynamics Observatory (EcoDyn), thiago.sf.silva@unesp.br; ³ UNESP – Universidade Estadual Paulista, Instituto de Biociências, Campus de Rio Claro, Laboratório de Fenologia (PhenoLab), patricia.morellato@gmail.com

RESUMO

A Cadeia do Espinhaço é o centro de diversidade de vários grupos de plantas, incluindo mais de 4000 espécies. Somente a Serra do Cipó, ao sul, abriga mais que um terço dessa diversidade. Os Veículos Aéreos Não Tripulados (VANTs) representam uma das principais evoluções tecnológicas do sensoriamento remoto atual e vêm contribuindo para os estudos de padrões e processos ecológicos, biológicos e geográficos. Deste modo, o objetivo do trabalho foi avaliar o efeito da variação fenológica sobre a acurácia da discriminação dos tipos de vegetação para a área de monitoramento localizada na Serra do Cipó – MG através dos VANTs. A partir das análises feitas foi possível entender como a mudança de temperatura, de pluviosidade e de umidade de acordo com as estações do ano interfere no comportamento das fitofisionomias de campo rupestre.

Palavras-chave: VANTs, fenologia, biodiversidade.

ABSTRACT

The Espinhaço Range is the center of diversity of various groups of plants, including more than 4000 species. The Serra do Cipó alone, to the south, harbors more than a third of this diversity. Unmanned Aerial Vehicles (UAVs) represent one of the major technological developments in current remote sensing and have contributed to the study of ecological, biological and geographic patterns and processes. Therefore, our objective was to evaluate the effect of the phenological variation on the accuracy of the discrimination of the vegetation types for the monitoring area located in the Serra do Cipó – MG – through the UAVs. Based on the analyzes, it was possible to understand how the temperature, rainfall and humidity changes according to the seasons interfere with the behavior of the rock field physiognomy.

Key words: UAVs, phenology, biodiversity.

1. INTRODUÇÃO

A Serra do Cipó, localizada na Cadeia do Espinhaço, apresenta o predomínio da vegetação com fisionomia de campos rupestres, parte do domínio florístico do Cerrado [1]. A Cadeia do Espinhaço é o centro de diversidade de vários grupos de plantas, incluindo mais de 4000 espécies. Somente a Serra do Cipó, ao sul da cadeia, com aproximadamente 200 km² (menos de 5% da área total), abriga mais que um terço dessa diversidade [2].

Esta vegetação se encontra em altitudes acima de 900 metros [3], e acredita-se que os principais condicionantes da flora nestes sistemas estejam relacionados ao clima, à geologia e à geomorfologia, além das interações bióticas e antrópicas sobre estes fatores [2].

Apesar da enorme relevância ecológica, estas regiões se encontram atualmente sob grande ameaça devido ao alto grau de expansão no que se refere ao uso antrópico da terra, e possivelmente devido à mudanças climáticas [4]. Portanto, fazem-se necessários novos métodos e abordagens que permitam o monitoramento eficaz destes ambientes, e uma melhor compreensão de seu funcionamento e vulnerabilidades.

O avanço das tecnologias de sensoriamento remoto vem contribuindo para os estudos e monitoramentos das vulnerabilidades ambientais e ecológicas desses ambientes. Neste sentido, os Veículos Aéreos Não Tripulados (VANTs) representam uma das principais evoluções tecnológicas no sensoriamento remoto atual [5]. Estes equipamentos apresentam baixo custo de operação, podem ser equipados com câmeras convencionais, multiespectrais ou sensores avançados (hiperespectral ou LiDAR), possuem alta flexibilidade no que se refere à capacidade de controlar a frequências temporal e possibilitam imageamentos com altíssimas resoluções espaciais [6].

Contudo, os VANTs introduzem diversos desafios para a classificação automática de elementos da superfície terrestre, isso porque o máximo nível de detalhes registrado pela imagem são os elementos estruturais, como por exemplo, folhas, galhos e rochas, resultando em uma altíssima heterogeneidade das respostas exibidas pelos objetos [7]. O mapeamento de vegetações heterogêneas, tal

como a vegetação rupestre da Serra do Cipó, através do uso de imagens de VANTs na atualidade ainda é desafiador por conta da grande complexidade espacial, estrutural e radiométrica existente nesses ambientes.

Deste modo, o objetivo do trabalho foi avaliar o efeito da variação fenológica sobre a acurácia da discriminação dos tipos de vegetação para a área de monitoramento localizada na Serra do Cipó – MG.

2. MATERIAIS E MÉTODOS

A área de estudo do trabalho compreende uma área particular, pertencente à empresa Cedro Têxtil S.A, na região da Serra do Cipó e inserida na Área de Proteção Ambiental (APA) do Morro da Pedreira (MG), denominada doravante de CEDRO (Figura 1). Esta região apresenta o predomínio de vegetação da fisionomia de campos rupestres, parte do domínio florístico do Cerrado, e é caracterizada por ocupar trechos de afloramentos rochosos e de rochas quartzíticas e apresentar alta riqueza e endemidade de espécies herbáceas [8].

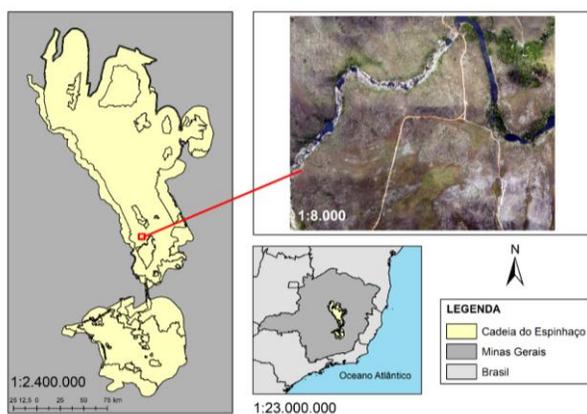


Figura 1: Mapa de localização da área “Cedro”, na Serra do Cipó, sul da Cadeia do Espinhaço, onde foram realizados os imageamentos utilizando VANTs. Fonte: Elaborado pela autora.

As imagens utilizadas no trabalho foram adquiridas com um VANT de asa fixa modelo G-Plane, equipado com uma câmera CANON SX260, sensor RGB de 12 megapixels de resolução. Os voos foram realizados a uma altitude de 150 metros acima do solo, recobrimo uma área de 64 hectares com uma resolução espacial aproximada de 5 centímetros. Para a realização do trabalho foram utilizadas as imagens do mês mais seco (24 de julho de 2016) e do mês mais úmido (01 de janeiro de 2017).

As fotos foram processadas com o uso do software Pix4D Mapper 3.1 Educational, através do algoritmo Structure from Motion (SfM). Este algoritmo permite a geração de uma nuvem de pontos tridimensional através da extração automática de pontos de referência individuais que, posteriormente, é usada para a geração do modelo digital de superfície e dos ortomosaicos bidimensionais [9].

Para a realização do processo de classificação foi necessário realizar a segmentação da imagem em objetos individuais, com o uso do *K-means clustering*, algoritmo não supervisionado que agrupa um conjunto de dados a partir de um certo número de clusters [10]. Nessa etapa foi utilizada a biblioteca RSGISLib acessível pela linguagem Python [11]. Foram utilizados os seguintes valores para cada um dos parâmetros existentes: NumClusters (número de agrupamentos = 5); MinPxls (tamanho mínimo aceitável para os segmentos = 500); DistThres (distância limite para a junção de segmentos = 5000); Sampling (k-means = 200) e KmMaxIter (número máximo de iterações para definição de clusters = 100).

Posteriormente, iniciou-se o processo de definição das classes e o processo de treinamento (coleta das amostras), com o uso do software ENVI 5.0. Para cada classe foram coletadas amostras com base em transectos georreferenciados de levantamento de vegetação realizados como parte do projeto FAPESP “*e-Phenology: combining new technologies to monitor phenology from leaves to ecosystems*”. A partir do processo de treinamento, 30% das amostras de cada classe foram destinadas à validação e 70% à classificação.

| Classe | Características | Número de amostras coletadas |
|---------------------|---|------------------------------|
| Solo exposto | Rodovias e estradas em geral; | 84 |
| Rocha exposta | Exposição de rochas na superfície terrestre, com ausência completa de vegetação; | 116 |
| Mata ciliar | Formação vegetal localizada na margem de córregos, rios, lagos, represas e nascentes; | 225 |
| Corpo d'água | Rios, córregos, canais e lagos; | 54 |
| Afloramento rochoso | Exposição de rochas na superfície terrestre, com presença de cobertura vegetal; | 126 |
| Campo úmido | Formações herbáceo-subarbustivas que ocorrem em terrenos alagadiços, com afloramento de lençol freático ou em depressões que acumulam água durante a estação chuvosa; | 132 |
| Campo sujo | Formações arbustiva-herbáceas, com arbustos esparsos, encontrado em solos rasos, com pequenos afloramentos rochosos e de baixa fertilidade; | 144 |
| Campo pedregoso | Formações predominantemente herbáceas, com raros arbustos, ausência completa de árvores e presença de substrato pedregoso; | 25 |
| Campo arenoso | Formações predominantemente herbáceas, com o predomínio de solos arenosos, pobres em nutriente e água, que apresentam alta porosidade e permeabilidade, além de apresentar alta susceptibilidade erosiva. | 216 |

Tabela 1: Descrição das características de cada classe de classificação da vegetação rupestre para a área “Cedro”, localizado na Serra do Cipó, sul da Cadeia do Espinhaço.

A classificação para cada uma das imagens foi realizada utilizando também a biblioteca RSGISLib, a partir do *Random Forests*, algoritmo caracterizado como um tipo de *ensemble learning*, método que gera várias árvores de decisões e combina seu resultado [12]. Os principais parâmetros do algoritmo são: *n-estimators* (número de árvores de decisões) e *max-features* (número de atributos considerados pelo algoritmo para a criação de cada árvore de decisão). Para a realização do trabalho foram estimadas 500 árvores de decisões e 3 atributos.

Por fim, para avaliar a acurácia de cada uma das classificações foi calculado a matriz de erro, a acurácia geral da classificação e o índice Kappa a partir do pacote “rsacc”, desenvolvido para a linguagem R.

A matriz de erro é uma matriz quadrada estabelecida em linhas e colunas, em que as linhas representam os dados gerados pela classificação e as colunas representam os dados de referência (validação) [13]. A acurácia geral é calculada a partir da divisão entre a soma total da diagonal principal da matriz e o número total de pixels na matriz de erro. O índice Kappa é uma medida de concordância que considera o fato de que mesmo se as classes fossem atribuídas aleatoriamente, algum grau de concordância seria esperado, e varia de 0 a 1.

3. RESULTADOS

Para o mapa de classificação do mês mais seco (Figura 2) pode-se obter uma acurácia geral de 76% e um índice Kappa de 0,704. Já para o mapa de classificação do mês mais úmido (Figura 3) pode-se obter uma acurácia de 82% e um índice Kappa de 0,769.

| | AR | CA | CP | CS | CU | A | MC | RE | SE |
|----|-------------|--------------|-------------|-------------|-------------|-------------|--------------|-------------|-------------|
| AR | 5.78 | 0.32 | 0.38 | 0.62 | 0 | 0.01 | 0.60 | 0.15 | 0 |
| CA | 3.26 | 22.09 | 0.21 | 0.07 | 0.37 | 0.02 | 1.55 | 0 | 0 |
| CP | 0 | 0 | 0.71 | 0.06 | 0 | 0 | 0 | 0.01 | 0 |
| CS | 0.98 | 0.98 | 0.57 | 6.99 | 1.10 | 0 | 0.43 | 0.16 | 0 |
| CU | 0.06 | 0.07 | 0 | 0 | 6.93 | 0.19 | 0.33 | 0 | 0 |
| A | 0 | 0 | 0 | 0 | 0 | 2.19 | 0.10 | 0.11 | 0 |
| MC | 0.72 | 0.14 | 0.06 | 0.44 | 0.44 | 1.86 | 28.51 | 0.59 | 0.02 |
| RE | 0.14 | 0 | 0.09 | 0.05 | 0 | 0.73 | 0.17 | 5.28 | 0.10 |
| SE | 0.02 | 0.05 | 0 | 0.12 | 0 | 0 | 0 | 0 | 3.06 |

Tabela 2: Matriz de erro para a classificação do mês mais úmido (em %). Os dados em vermelho indicam os valores mais discrepantes. AR = Afloramento Rochoso; CA = Campo Arenoso; CP = Campo Pedregoso; CS = Campo Sujo; CU = Campo Úmido; A = Corpo d’água; MC = Mata Ciliar; RE = Rocha Exposta; SE = Solo Exposto.

| | AR | CA | CP | CS | CU | A | MC | RE | SE |
|----|-------------|--------------|-------------|------|-------------|------|-------------|------|------|
| AR | 8.20 | 1.50 | 0.35 | 0.62 | 1.31 | 0.05 | 0.06 | 0.05 | 0.09 |
| CA | 2.18 | 21.90 | 0.87 | 0.25 | 0.44 | 0 | 3.46 | 0 | 0 |

| CP | 0 | 0 | 0.47 | 0.03 | 0 | 0 | 0 | 0 | 0 |
|----|------|------|-------------|-------------|-------------|-------------|--------------|-------------|-------------|
| CS | 0.23 | 0.59 | 0.29 | 6.16 | 0.07 | 0 | 2.65 | 0.08 | 0 |
| CU | 0.36 | 0.13 | 0 | 0.70 | 6.31 | 0.16 | 0.15 | 0 | 0 |
| A | 0 | 0 | 0 | 0 | 0.69 | 0.12 | 0.04 | 0 | 0 |
| MC | 0.07 | 0.03 | 0.05 | 0.67 | 2.61 | 3.00 | 24.86 | 1.07 | 0 |
| RE | 0.25 | 0.05 | 0.07 | 0.11 | 0 | 0 | 0.34 | 5.32 | 0.16 |
| SE | 0 | 0.12 | 0 | 0.06 | 0 | 0 | 0 | 0 | 3.02 |

Tabela 3: Matriz de erro para a classificação do mês mais seco (em %). Os dados em vermelho indicam os valores mais discrepantes. AR = Afloramento Rochoso; CA = Campo Arenoso; CP = Campo Pedregoso; CS = Campo Sujo; CU = Campo Úmido; A = Corpo d’água; MC = Mata Ciliar; RE = Rocha Exposta; SE = Solo Exposto.

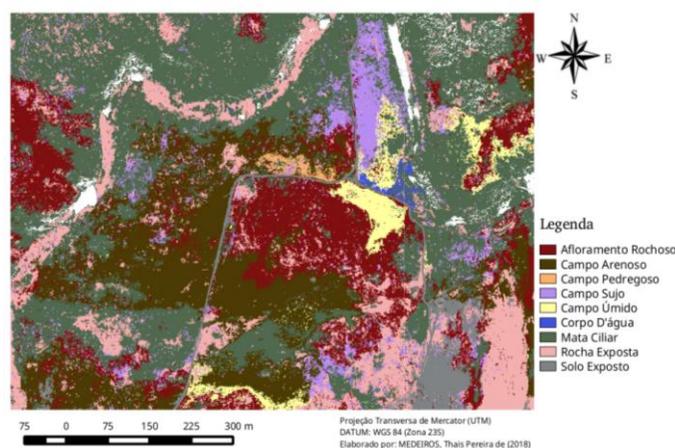


Figura 2: Mapa de classificação da vegetação da área CEDRO (Serra do Cipó – MG) para o mês mais seco (24 de julho de 2016).

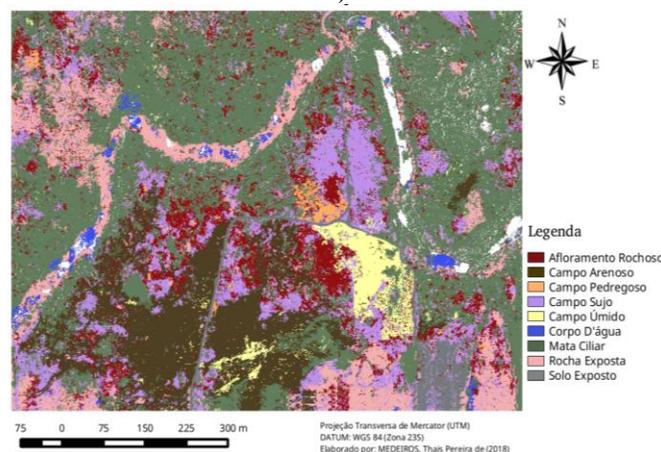


Figura 3: Mapa de classificação da vegetação da área CEDRO (Serra do Cipó – MG) para o mês mais úmido (01 de janeiro de 2017).

4. DISCUSSÃO

De uma maneira geral é possível perceber que a classificação para o mês mais seco apresenta maiores confusões entre as feições quando comparada à classificação do mês mais úmido. Tal fato pode ser explicado pela mudança nas colorações e nas texturas das feições de vegetação de acordo com a estação do ano.

O inverno, caracterizado por ser seco e frio, apresenta um índice pluviométrico baixo em torno dos 8 mm segundo a Agência Nacional de Águas (ANA). Este fato associado à temperaturas mais baixas e índices de umidade inferiores irão influenciar no comportamento das fitofisionomias de cerrado. Durante esta época do ano as plantas tendem a entrar no processo de perda de folhas e ressecamento por conta do déficit hídrico, resultando em uma resposta espectral mais homogênea e amarelada. Por conta destas características, a acurácia do mapa de classificação para o mês mais seco foi inferior e o padrão de confusão entre feições mais elevado. Por exemplo, um dos padrões de confusão predominante da estação seca é a caracterização errônea entre campo pedregoso e campo arenoso.

Já o verão, caracterizado por ser quente e úmido, apresenta um índice pluviométrico elevado em torno dos 232 mm segundo a ANA. Este fato associado à umidades altas e ao processo de rebrota e florescimento das plantas faz com que as fitofisionomias fiquem com as folhas mais verdes, facilitando o reconhecimento das feições, aumentando a acurácia geral do processo de classificação e diminuindo os padrões de confusão da vegetação.

5. CONCLUSÕES

Ao comparar o mapa de classificação da estação seca com o mapa de classificação da estação úmida foi possível evidenciar alguns padrões fenológicos e entender a influência que a variação climática e temporal apresenta nos mapeamentos da vegetação e como a mudança de temperatura, de pluviosidade e de umidade de acordo com as estações do ano interfere no comportamento das fitofisionomias de campo rupestre. Tal análise pode vir a auxiliar o monitoramento eficaz da área bem como a compreensão de seu funcionamento e vulnerabilidades.

6. REFERÊNCIAS

- [1] ROCHA, N. M. B.; CARSTENSEN, D. W.; FERNANDEZ, G. W.; MORELLATO, L. P. C. Phenology patterns across a rupestrian grassland altitudinal gradient. Ecology and conservation of mountain top grassland in Brazil. Springer, New York, 2016.
- [2] RAPINI, A. *et al.* A flora dos campos rupestres da Cadeia do Espinhaço. Megadiversidade, v. 4, p. 16–24, 2008.

[3] GIULIETTI, A. M. *et al.* Flora da Serra do Cipó, Minas Gerais: Caracterização e lista das espécies. Boletim de Botânica da Universidade de São Paulo, v. 9, n. May, p. 1–151, 1987.

[4] FERNANDES, G. W. *et al.* The deadly route to collapse and the uncertain fate of Brazilian rupestrian grasslands. Biodiversity and Conservation. Online first: <https://doi.org/10.1007/s10531-018-1556-4>, 2018.

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

[6] WHITEHEAD, K.; HUGENHOLTZ, C. H. Remote sensing of the environment with small Unmanned Aircraft System (UASs), part 1: a review of progress and challenges. NRC Research Press, v. 2, p. 69-85, 2014.

[7] ANDERSON, K.; GASTON, K. J. Lightweight unmanned aerial vehicles will revolutionize spatial ecology. Frontiers in Ecology and the Environment, v. 11, n. 3, p. 138–146, 2013.

[8] FERNANDES, G. W. Ecology and Conservation of Mountaintop grasslands in Brazil. Cham: Springer International Publishing, 2016.

[9] WESTOBY, M. J.; BRASINGTON, J.; GLASSER, N. F.; HAMBREY, M. J.; REYNOLDS, J. M. ‘Structure from Motion’ photogrammetry: A low cost, effective tool for geoscience applications. Geomorphology, v. 179, p. 300 – 314, 2012.

[10] MACQUEEN, J. Some methods for classification and analysis of multivariate observations. Western Management Science Institute, v. 233, n.º, 75, 1967.

[11] BUNTING, P. *et al.* The Remote Sensing and GIS Software Library (RSGISLib). Computers & Geosciences, v. 62, p. 216-226, 2014.

[12] BREIMAN, L. Random Forests. University of California, Berkeley, 2001.

[13] CONGALTON, R. G. A review of assessing the accuracy of classifications of remotely sensed data. Remote Sensing Environment, v. 37, p. 35 – 46, 1991.