MAPEAMENTO DA SUSCEPTIBILIDADE À INCÊNDIOS EM REGIÕES DE FLORESTA ATRAVÉS DA APLICAÇÃO DE REGRESSÃO LOGÍSTICA EM SÉRIES TEMPORAIS DE IMAGENS

Felipe Nascimento Souza[1], *José Victor Orlandi Simões*[1], *Vinícius Luiz Silva Gino*[1] *e Rogério Galante Negri*[1]

[1]Instituto de Ciência e Tecnologia – ICT
Universidade Estadual Paulista "Júlio de Mesquita Filho" – UNESP
12247-004 – São José dos Campos – SP, Brasil
{fn.souza,jose.orlandi,vinicius.gino,rogerio.negri}@unesp.br

RESUMO

O aumento no número de focos de queimada no Brasil tem a realização de estudos a fim de monitorar e mapear a susceptibilidade de diferentes áreas de serem afetadas por estes eventos, ou de recorrência em áreas já afetadas, além de avaliar os riscos em diferentes esferas destes eventos. Nesse contexto, a aplicação de técnicas de Sensoriamento Remoto, aliadas ao Aprendizado de Máquina, surgem como alternativas viáveis para o estudo de queimadas em regiões de floresta. Tendo isso em vista, o presente trabalho tem como objetivo mapear a susceptibilidade à incêndios em regiões de floresta por meio da aplicação de um modelo de Regressão Logística treinado com descritores estatísticos obtidos a partir de índices espectrais.

Palavras-chave – series temporais, regressão logistica, queimadas, floresta, desastres.

ABSTRACT

The increase in the number of fires in Brazil requires studies to be carried out in order to monitor and map the susceptibility of different areas to be affected by these events, or of recurrence in areas already affected, in addition to assessing the risks in different spheres of these events. In this context, the application of Remote Sensing techniques, allied to Machine Learning, emerge as viable alternatives for the study forest fires. With this in mind, the present work aims to map the susceptibility to fires in forest regions through the application of a Logistic Regression model trained with statistical descriptors obtained from spectral indices.

Key words – *time series, logistic regression, fires, forest, disaster.*

1. INTRODUÇÃO

Em regiões de floresta, os eventos de queimada ocasionam diversos impactos associados ao meio ambiente na esfera ecológica e socioeconômica. A perda da biodiversidade, remoção da cobertura vegetal e a emissão de poluentes gasosos são alguns dos potenciais impactos negativos causados por eventos de queimada e que afetam também, de forma direta, a saúde das comunidades que os circundam [1]. Apesar do fogo ser um fator importante para a manutenção das dinâmicas ecológicas de diversos ecossistemas florestais, porém eventos de queimada de origem antrópica, alterando abruptamente as dinâmicas ecológicas em diferentes ecossistemas, são de extremo prejuízo para a manutenção da biodiversidade [2].

Na região da Amazônia, registrou-se um aumento no número de eventos de queimada entre os anos de 2003 e 2020, sendo o Brasil responsável por cerca de 70% do aumento anual do número de eventos registrado e cerca de 50% do aumento total de área queimada na Amazônia. A principal causa atribuída à esse aumento expressivo é o uso descontrolado do fogo em atividades pecuárias, para a manutenção de largas áreas de pastagens e "grilagem"de terras [3] [4].

A região do Pantanal Mato-grossense possui uma das maiores planícies de inundação do mundo, porém, é caracterizada por um período de estiagem muito forte entre os meses de junho a agosto. Nesse período, uma prática comum por parte dos fazendeiros locais compreende o uso do fogo para ampliar as zonas de pasto e possibilitar o crescimento acelerado da produção pecuária [1] [5]. Nos últimos anos, a região do Pantanal viveu um período de estiagem intenso que, aliado com o efeito do uso do fogo, foi responsável pela ocorrência de diversos eventos de queimada no local [6].

Nesse contexto, o Sensoriamento Remoto surge como uma alternativa para a o estudo destes eventos, possibilitando a sua observação de forma multitemporal, em escala expressiva e em regiões de pouca facilidade de acesso [7]. Aliado ao Sensoriamento Remoto, a aplicação de técnicas de Aprendizado de Máquina peremitem a construção de modelos capazes de inferir a respeito da susceptibilidade à ocorrência ou não de diferentes eventos de acordo com as características observadas no local. Deve-se considerar que, a eficácia desses modelos estará associada à qualidade dos dados obtidos através do Sensoriamento Remoto e a coerência das técnicas aplicadas em função do objetivo proposto [8] [7].

Tendo isso em vista, o presente trabalho propõe o mapeamento da susceptibilidade à incêndios na região do município de Vila Bela da Santissima Trindade, Mato Grosso e no Parque Nacional de Noel Kempff Mercado, localizado no departamento de Santa Cruz, Bolívia através da aplicação de um modelo de Regressão Logística construído com base em descritores estatísticos obtidos por meio de dados de Sensoriamento Remoto.

2. MATERIAL E MÉTODOS

2.1. Área de Estudo

A área de estudo (Figura 1) compreende parte do município de Vila Bela da Santíssima Trindade, inserido no estado do Mato-Grosso e parte do Parque Nacional de Noel Kempff Mercado, localizado no departamento de Santa Cruz, Bolívia. O município mencionado possui uma extensão de aproximadamente 13,4 mil quilômetros quadrados [9], sendo ocupado predominantemente pelos biomas Amazônia e Cerrado. O bioma Amazônia ocupa cerca de 94% de toda a extensão do município e somente 4% é ocupada pelo bioma Cerrado

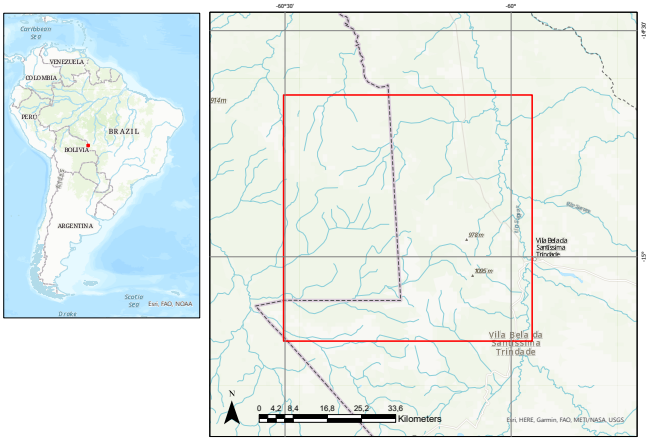

Figura 1: Região do município de Vila Bela da Santíssima Trindade, estado do Mato-Grosso.

2.2. Aquisição de dados

A coleção de imagens utilizada no estudo foi obtida através do sensor *Operational Land Imager* (OLI), acoplado ao satélite Landsat-8. Para a obtenção das amostras de regiões afetadas por fogo, utilizou-se o produto *Modis Burned Area Monthly L3 Global 500m*(MCD64A1) [10]. A coleção de imagens foi obtida através da API do *Google Earth Engine* e manipulada por meio da linguagem de programação *Python 3* através das bibliotecas *Pandas*, *Numpy*, *Scikit-Learn*, *SciPy*, *Geopandas*, *GDAL*, *Matplotlib* e *Rasterio*.

2.3. Mapeamento da Susceptibilidade à Incêndios

O mapeamento proposto parte da obtenção de todas as amostras de regiões afetadas por fogo dentro da área de estudo, através do produto MCD64A1, entre os anos de 2013 e 2020. Em seguida, com base no conjunto de amostras de fogo obtido, montou-se uma coleção de imagens sob a área de estudo, considerando cobertura de nuvens inferior à 5%, com todas as imagens disponíveis pelo sensor OLI em um período $Q = 30$ dias anterior a cada um dos eventos de fogo registrados. No total, a coleção construída possui 42 imagens considerando o período Q anterior aos eventos de fogo estipulado anteriormente.

Em seguida, a fim de caracterizar o uso do solo na área, definir a respeito da sua dinâmica e a influência desses fatores na ocorrência de fogo, extraiu-se os seguintes índices expectrais sob cada uma das imagens da coleção: Índice de Vegetação por Diferença Normalizada (NDVI) [11]; Índice de Água por Diferença Normalizada (NDWI) [12]; Índice de Queimada por Razão Normalizada (NBR) [13].

Em posse dos índices expectrais supracitados, obteve-se um conjunto de dados rotulado, em relação à ocorrência ou não de fogo, com a média de cada um dos índices extraídos. O conjunto de dados obtido foi utilizado para treinar um modelo de Regressão Logística que, quando aplicado à um conjunto de dados, não rotulado, com os mesmos atributos, é capaz de inferir a respeito da susceptibilidade à incêndios no local.

Para avaliar a eficácia do modelo proposto construiu-se dois histogramas da susceptibilidade à incêndios definida pelo modelo em regiões afetadas por fogo e em regiões não afetadas por fogo, tomando como referência o produto MCD64A1. Empregou-se também o teste estatístico de Mann-Whitney [14] entre as duas amostras (i.e. regiões afetadas por fogo e regiões não afetadas por fogo) a fim de verificar se as duas amostras diferem ou não estatísticamente.

3. RESULTADOS

O resultado obtido através da aplicação do modelo de regressão logística é expresso em valores dentro do intervalo $[0, 1]$, portanto definiu-se as classes de susceptibilidade à incêndios de acordo com a Tabela 1. Pode-se observar o mapeamento da susceptibilidade à incêndios obtido sob a área de estudo na Figura 2.

Tabela 1: Classes de suscetibilidade.

Susceptibilidade à incêndios	Classes de susceptibilidade
$[0, 0.2)$	Muito baixo
$[0.2, 0.4)$	Baixo
$[0.4, 0.6)$	Média
$[0.6, 0.8)$	Alto
$[0.8, 1]$	Muito alto

A fim de avaliar o resultado obtido construiu-se os histogramas apresentados na Figura 3 que definem a respeito da susceptibilidade à incêndios registradas em regiões afetadas e não afetadas por fogo de acordo com o produto MCD64A1.

A aplicação do teste de Mann-Whitney, nos conjuntos de dados obtido em regiões afetadas e não afetadas por fogo, retornou p-valor $< 10^{-6}$, ou seja, as amostras testadas diferem estatisticamente entre si.

4. CONCLUSÕES

Através dos resultados obtidos pode-se concluir que o método proposto apresentou efetividade na definição da susceptibilidade à incêndios na área de estudo. A avaliação do resultado obtido pelo modelo de regressão logística se mostrou satisfatória por meio da observação dos histogramas construídos e do teste estatístico de Mann-Whitney.

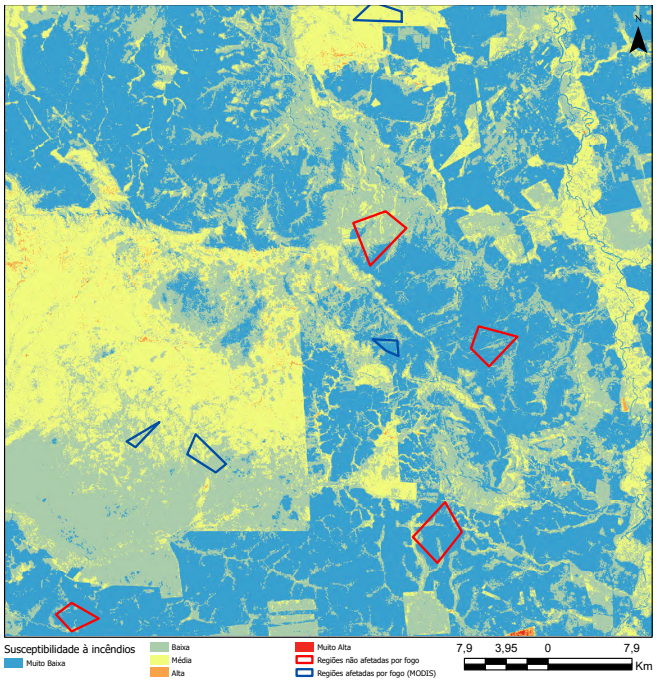

Figura 2: Mapeamento da Susceptibilidade à Incêndios na área de estudo e amostras de fogo utilizadas para avaliação

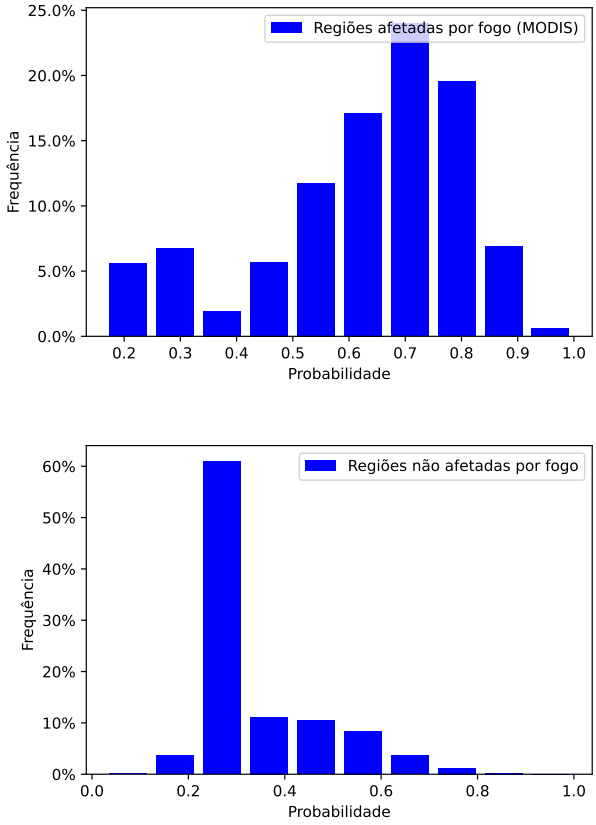

Figura 3: Histogramas da susceptibilidade à incêndios em regiões afetadas e não afetadas por fogo

Visualmente o mapeamento obtido também apresenta resultado satisfatório, tendo em vista que regiões que de fato foram afetadas por fogo apresentaram alta susceptibilidade a incêndios, porém observou-se alguns pixels isolados no mapa construído que apresentaram valores muito elevados como resposta do modelo construído, dificultando parte da interpretação visual do mapa e confundindo a classificação das classes de susceptibilidade à incêndios apresentada na Tabela 1.

Espera-se também integrar o resultado obtido através do modelo de regressão ao algoritimo *Iterated Conditional Modes* (ICM) [15] que possibilitará a obtenção de modelos de regressão mais aderentes, definindo com maior assertividade a susceptibilidade à incêndios na área proposta.

5. REFERÊNCIAS

[1] Fernando Moreira De Araújo and Laerte G. Ferreira. Satellite-based automated burned area detection: A performance assessment of the modis mcd45a1 in the brazilian savanna. *International Journal of Applied Earth Observation and Geoinformation*, 36:94–102, 2015.

[2] Danielle Blazys Correa, Enner Alcântara, Renata Libonati, Klécia Gili Massi, and Edward Park. Increased burned area in the pantanal over the past two decades. *Science of The Total Environment*, 835:155386, 2022.

[3] Marcus V. F. Silveira, Celso H. L. Silva-Junior, Liana O. Anderson, and Luiz E. O. C. Aragão. Amazon fires in the 21st century: The year of 2020 in evidence. *Global Ecology and Biogeography*, 31(10):2026–2040, 2022.

[4] Lucas Ferrante, Maryane BT Andrade, and Philip M Fearnside. Land grabbing on brazil's highway br-319 as a spearhead for amazonian deforestation. *Land use policy*, 108:105559, 2021.

[5] E. C. Moraes, G. A. Mataveli, P. R. Santos, and B. S. Oliveira. Estudo da dinâmica de queimada no bioma pantanal no período de 2002 a 2015. In *Simpósio Brasileiro de Sensoriamento Remoto*, Santos, 2017.

[6] Flavia Katarine da Silva. Análise espaço-temporal do fogo no bioma pantanal utilizando dados de sensoriamento remoto. 2021.

[7] Matthew G. Gale, Geoffrey J. Cary, Albert I.J.M. Van Dijk, and Marta Yebra. Forest fire fuel through the lens of remote sensing: Review of approaches, challenges and future directions in the remote sensing of biotic determinants of fire behaviour. *Remote Sensing of Environment*, 255:112282, 2021.

[8] M. Herold, N. C. Goldstein, and K. C. Clarke. The spatiotemporal form of urban growth: measurement, analysis and modeling. *Remote Sensing of Environment*, 86:286–302, 2002.

[9] IBGE. Instituto brasileiro de geografia e estatística, 2020.

[10] Justice C. Boschetti L. Roy D. Giglio, L. Mcd64a1 modis/terra+aqua burned area monthly l3 global 500m sin grid v006. *NASA EOSDIS Land Processes DAAC*, 2015.

[11] JW Rouse, Rüdiger H Haas, John A Schell, Donald W Deering, et al. Monitoring vegetation systems in the great plains with erts. *NASA special publication*, 351(1974):309, 1974.

[12] Bo-Cai Gao. Ndwi?a normalized difference water index for remote sensing of vegetation liquid water from space. *Remote sensing of environment*, 58(3):257–266, 1996.

[13] D.P. Roy, L. Boschetti, and S.N. Trigg. Remote sensing of fire severity: assessing the performance of the normalized burn ratio. *IEEE Geoscience and Remote Sensing Letters*, 3(1):112–116, 2006.

[14] Eiiti Kasuya. Mann–whitney u test when variances are unequal. *Animal Behaviour*, 61(6):1247–1249, 2001.

[15] Jerod Weinman. A brief introduction to icm, 2008.