



MODELOS DE MACHINE LEARNING PARA PREVISÃO DE RISCO DE QUEIMADAS EM MATO GROSSO

Autor(res)

Osvaldo Borges Pinto Junior
Higor Luiz Lourenço

Categoria do Trabalho

Pesquisa

Instituição

UNIVERSIDADE DE CUIABÁ - UNIC

Introdução

O estado de Mato Grosso concentra uma das maiores incidências de queimadas no Brasil, associadas à sazonalidade climática e à pressão antrópica oriunda da expansão agro-pecuária. Esses eventos acarretam impactos ambientais, sociais e econômicos, incluindo a degradação da biodiversidade, emissões de gases de efeito estufa e danos à saúde pública. O uso de dados de sensoriamento remoto, especialmente do sensor MODIS, possibilita acompanhar focos ativos e mensurar a intensidade do fogo por meio da Potência Radiativa do Fogo (FRP). Paralelamente, variáveis meteorológicas como precipitação e dias consecutivos sem chuva se mostram relevantes para índices de risco, como o IRF do INPE. No entanto, ainda existem lacunas quanto à aplicação integrada dessas variáveis em modelos preditivos regionais. O aprendizado de máquina tem se consolidado como alternativa promissora, destacando-se os algoritmos Random Forest e XGBoost, capazes de lidar com grandes volumes de dados e relações não lineares. Assim, este estudo emprega tais técnicas para prever o risco de fogo em Mato Grosso, com vistas a aprimorar os sistemas de monitoramento e apoiar a tomada de decisão em políticas públicas.

Objetivo

Investigar a dinâmica das queimadas em Mato Grosso, aplicando algoritmos de aprendizado de máquina para prever o risco de fogo, relacionando variáveis climáticas e de sensoriamento remoto e mapeando padrões espaço-temporais.

Material e Métodos

A base de dados desta pesquisa foi composta por informações do Programa Queimadas/INPE, abrangendo focos ativos e a Potência Radiativa do Fogo (FRP) registrados pelos sensores MODIS/Terra e Aqua entre 2020 e 2024 (INPE, 2024). Como variáveis explicativas, consideraram-se a precipitação acumulada mensal, o número de dias consecutivos sem chuva e o Índice de Risco de Fogo (IRF), enquanto o recorte espacial adotou os limites municipais do IBGE, permitindo análises regionalizadas. Os dados climáticos foram organizados em séries temporais mensais e definiu-se como dia seco aquele com precipitação inferior a 5 mm, critério consolidado em metodologias de risco de fogo (WMO, 2017; Soares; Batista, 2007; Santos et al., 2021). O processamento e a análise foram conduzidos em ambiente Python, com o uso das bibliotecas pandas, matplotlib, seaborn, scikit-learn



e xgboost. Para a modelagem preditiva, implementaram-se os algoritmos Random Forest, baseado em múltiplas árvores de decisão e amostragem bootstrap (Breiman, 2001; Ho, 1998), e XGBoost, método de gradient boosting com regularização e técnicas de shrinkage (Chen; Guestrin, 2016). A variável-alvo foi o risco de fogo normalizado (0–1), avaliado pelo Índice de Concordância de Willmott (d), métrica amplamente utilizada em hidrologia e climatologia para aferir a proximidade entre valores previstos e observados (Willmott, 1981; Legates; McCabe, 1999). A análise es-pacial das queimadas foi realizada por meio da Estimativa de Densidade por Kernel (KDE) ponderada pelo FRP, técnica não paramétrica que converte pontos em superfícies contínuas e permite identificar hotspots de maior intensidade energética do fogo (Sil-verman, 1986).

Resultados e Discussão

Os resultados demonstraram que ambos os modelos capturaram adequadamente a sazonalidade do risco de fogo em Mato Grosso. As previsões apontaram valores elevados de risco nos meses de julho e agosto de 2025 (0,87), período de maior severidade da estação seca, com redução em junho e setembro, embora ainda em patamar significativo. O Random Forest apresentou estimativas ligeiramente mais elevadas nas bordas da estação, enquanto o XGBoost se mostrou mais conservador, mas em julho os valores convergiram (0,894). O Índice de Willmott indicou concordância satisfatória para ambos (Random Forest = 0,804; XGBoost = 0,805), confirmando a robustez preditiva dos modelos. Apesar disso, a análise mensal evidenciou menor desempenho em agosto, sugerindo comportamento mais extremo ou variável do risco de fogo nesse período. A aplicação da KDE revelou a concentração espacial da intensidade energética no norte e no sul do estado, regiões associadas à expansão agropecuária e à maior pressão sobre os ecossistemas. Esses resultados reforçam o potencial do aprendizado de máquina para integrar variáveis climáticas e de sensoriamento remoto, fornecendo subsídios técnicos para estratégias de prevenção, alocação de brigadas e fortalecimento dos sistemas de alerta precoce. Portanto, é importante destacar que as previsões representam médias mensais agregadas ao nível estadual; portanto, não capturam a heterogeneidade espacial entre bacias/municípios nem eventos de curta duração. O mês de junho (0,341 / 0,365) obteve concordância baixa/moderada. Os modelos conseguem capturar parte da variação, mas erram bastante em alguns dias. O mês de julho (0,456 / 0,456) obteve melhor desempenho: previsões mais próximas da realidade. Possivelmente julho tem um padrão mais claro de risco de fogo, que os modelos conseguiram aprender. Agosto (0,188 / 0,257) mostrou desempenho fraco. Indica que agosto teve um comportamento mais extremo ou mais variável do risco de fogo, e os modelos não conseguiram acompanhar bem. Já setembro (0,365 / 0,318) indicou um índice moderado melhor que agosto, mas pior que julho.

Conclusão

A aplicação dos modelos Random Forest e XGBoost mostrou-se eficaz para prever o risco de fogo em Mato Grosso, com destaque para a captura dos padrões sazonais críticos no período seco. A análise espacial complementou a previsão, evidenciando hotspots relevantes para a priorização de políticas de prevenção. Embora limitações relacionadas à resolução espacial e à ausência de validação em campo persistam, os resultados reforçam o potencial da integração entre aprendizado de máquina e sensoriamento remoto como ferramenta estratégica para gestão de queimadas.

Referências

- BREIMAN, L. Random forests. Machine Learning, v. 45, p. 5–32, 2001.
- CHEN, T.; GUESTRIN, C. XGBoost: A scalable tree boosting system. KDD '16 Proceedings, p. 785–794, 2016.



INPE. Relatório de Monitoramento Climático – Brasil. Instituto Nacional de Pesquisas Espaciais, 2024.

KAISER, J. W. Biomass burning emissions estimated with a global fire assimilation system based on observed fire radiative power. *Biogeosciences*, v. 9, p. 527–554, 2012.

LEGATES, D. R.; MCCABE, G. J. Evaluating the use of “goodness-of-fit” measures in hydrologic and hydroclimatic model validation. *Water Resources Research*, v. 35, n. 1, p. 233–241, 1999.

PEREIRA, G. et al. Aplicação de machine learning na previsão de risco de fogo. *Revista Brasileira de Cartografia*, 2021.

SANTOS, J. F.; BATISTA, A. C.; SOARES, R. V. Avaliação de índices meteorológicos de perigo de incêndio florestal para o Brasil. *Revista Árvore*, v. 45, e4501, 2021.

SBRAVATTI, A.; FERREIRA, S.; LIMA, F. Utilização de dados MODIS para a detecção de queimadas na Amazônia. *Anais do XIII Simpósio Brasileiro de Sensoriamento Remoto*, 2008.

SHIMABUKURO, Y. Dinâmica das queimadas na Amazônia Legal. INPE, 2020.

SILVERMAN, B. W. *Density Estimation for Statistics and Data Analysis*. London: Chapman and Hall, 1986.

SOARES, R. V.; BATISTA, A. C. *Fórmula de Monte Alegre – FMA e FMA+*. Curitiba: UFPR, 2007.

VOLPATO, R. Modelagem de suscetibilidade a incêndios em Mato Grosso com algoritmos de aprendizado de máquina. *Dissertação (Mestrado) – IF Goiano*, 2022.

WILLMOTT, C. J. On the validation of models. *Physical Geography*, v. 2, p. 184–194, 1981.

WMO – World Meteorological Organization. Guidelines on definitions of extreme weather and climate events. Geneva: WMO, 2017.