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 Bra-sil, 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 públi-ca. O uso de dados de sensoriamento remoto, especialmente do sensor MODIS, possibi-lita 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 em-prega 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) regis-trados pelos sensores MODIS/Terra e Aqua entre 2020 e 2024 (INPE, 2024). Como va-riáveis 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), mé-trica 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 sazo-nalidade 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 esta-ção seca, com redução em junho e setembro, embora ainda em patamar significativo. O Random Forest apresentou estimativas ligeiramente mais elevadas nas bordas da esta-ção, enquanto o XGBoost se mostrou mais conservador, mas em julho os valores con-vergiram (0,894). O Índice de Willmott indicou concordância satisfatória para ambos (Random Forest = 0,804; XGBoost = 0,805), confirmando a robustez preditiva dos mo-delos. Apesar disso, a análise mensal evidenciou menor desempenho em agosto, suge-rindo comportamento mais extremo ou variável do risco de fogo nesse período. A apli-cação 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 varia-ção, 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 ex-tremo 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 críti-cos 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 Pro-ceedings, 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 sys-tem 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 meteorológi-cos 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 de-tecção 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 algo-ritmos 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 wea-ther and climate events. Geneva: WMO, 2017.WMO – World Meteorological Organiza-tion. Guidelines on definitions of extreme weather and climate events. Geneva: WMO, 2017.