

Modelagem de Risco de Queimadas em Goiás: Uma Aplicação de Regressão Logística

Paulo Vitor Rodrigues do Nascimento¹

Pedro Paulo Carvalho Vieira²

Rodrigo Santana Esperidião³

Gustavo Siqueira Vinhal⁴

INTRODUÇÃO.

A previsão de queimadas é um tema de grande relevância, sobretudo em regiões suscetíveis a incêndios florestais descontrolados, que representam riscos significativos ao meio ambiente, à fauna e à saúde pública. A utilização de modelos de aprendizado de máquina, como a regressão logística, tem se mostrado eficaz na previsão de eventos como queimadas (IBM, 2024; James et al., 2021), doenças (Kumar & Minz, 2014), e fraudes (Ngai et al., 2011), permitindo uma resposta rápida e estratégias de mitigação mais precisas. O objetivo deste projeto é utilizar dados históricos e meteorológicos para prever a probabilidade de ocorrência de queimadas em diferentes regiões de Goiás, com foco em um horizonte temporal de cinco dias.

MATERIAIS E MÉTODOS.

Para o desenvolvimento da análise de previsão das queimadas, foi desenvolvido um código em Python estruturado por diferentes componentes: coleta e tratamento de

¹paulovitorgn@gmail.com

²ppaulo030601@gmail.com.

²paulovitorgn@gmail.com

²ppaulo030601@gmail.com.

³se03rodrigo@gmail.com.

⁴<http://lattes.cnpq.br/5227400971565575>. gustavo.vinhal@ueg.br

dados, modelo de predição, consulta da API de previsão do tempo, interface gráfica e mapa interativo.

Os dados aplicados no projeto para o treinamento do modelo foram coletados do Instituto Nacional de Meteorologia (INMET) e do Instituto Nacional de Pesquisas Espaciais (INPE). Foram coletadas informações como níveis de precipitação, pressão atmosférica, temperatura do ar, umidade relativa, velocidade do vento, direção do vento e número de focos de incêndio. Como os dados das duas fontes eram apresentados de maneiras diferentes (intervalo de tempo, colunas etc.), foi necessário tratá-los através do código. Para o tratamento foi utilizada a biblioteca *Pandas*, comumente aplicada na manipulação de dados e tabelas.

Para construção do modelo preditivo foi utilizado a biblioteca *PyTorch*. O modelo é composto de uma função linear seguida de uma função sigmoide, com taxa de aprendizado de 0,01, função de perda do tipo *BCELoss*, otimizador *Adam* e foi configurado um *scheduler* do tipo *ReduceLROnPlateau*, para reduzir a taxa de aprendizado quando o modelo parar de aprender. Também foi configurado um treino de até 10.000 épocas com um *early stop*, caso o modelo parasse de aprender, que identificou a convergência do mesmo com 200 épocas. Os dados foram divididos em 2 partes, sendo 80% para treino e 20% para teste e validação.

Para validar o algoritmo, foi utilizado um modelo de regressão logística da biblioteca *Scikit-learn*, permitindo a comparação direta entre um modelo personalizado e uma implementação já consolidada, avaliando o desempenho e eficiência no contexto proposto.

Os dados fornecidos ao modelo para fazer a previsão dos próximos cinco dias são obtidos através da API da *OpenWeatherMap*, um serviço online que fornece dados meteorológicos globais atuais e de previsões. Para obter os dados, são enviadas as coordenadas do ponto selecionado pelo usuário e, após obtidas as informações, o modelo faz sua previsão de acordo com o treino realizado anteriormente para obter os resultados.

RESULTADOS

Na avaliação do modelo desenvolvido, foi encontrado um valor ideal de tolerância de 0,52, para o qual foram obtidos os seguintes valores de métricas: Acurácia: 87,7%; Precisão: 86,7%; *Recall*: 83,1%. Quando utilizado o modelo da biblioteca do *Scikit-learn* foram encontradas as seguintes métricas: Acurácia: 88,3%; Precisão: 86,2%; *Recall*: 85,7%.

Esses valores podem ser considerados como bons para a previsão de ocorrência de queimadas, com uma boa confiabilidade agregada. Os resultados da previsão são apresentados em uma tabela com as seguintes colunas: “Data”, “Haverá focos de incêndio”, “Razão de chance” e “Tolerância”. A coluna “Data” apresenta o dia (dd/mm/aa) e a hora (hh:mm:ss) da previsão, variando de três em três horas a cada linha. A coluna “Haverá focos de incêndio” exibe apenas as palavras “Sim” ou “Não”, definidas de acordo com a razão de chance calculada. A condição para ser “Sim” é o valor da razão de chance superar o valor da tolerância, que no caso estudado foi de 0,52. Esses resultados revelam que a aplicação do projeto é simples e eficaz, apresentando bons resultados com fácil interpretação.

CONSIDERAÇÕES FINAIS

Este trabalho fornece uma ferramenta prática e acessível para a previsão de queimadas. A capacidade de o usuário selecionar diferentes pontos geográficos do estado de Goiás por meio de um mapa torna o sistema flexível e útil para áreas propensas a incêndios florestais, ajudando na implementação de medidas preventivas e no monitoramento contínuo das condições ambientais. A integração de dados climáticos e geográficos no modelo de regressão logística, além de uma interface amigável para o usuário, contribui para o desenvolvimento de soluções mais eficazes e precisas no combate às queimadas. Esse sistema pode ser adaptado a diferentes regiões e contextos, dependendo das variáveis ambientais e das características locais de cada área monitorada.

PALAVRAS-CHAVE: Regressão logística, Previsão de Queimadas, Inteligência Artificial.

REFERÊNCIAS

IBM. O que é regressão logística? Disponível em: <https://www.ibm.com/br-pt/topics/logistic-regression>. Acesso em: 12 dez. 2024.

James, G., Witten, D., Hastie, T., Tibshirani, R. (2021). An Introduction to Statistical Learning. 2ª ed. Springer.

Pedregosa, F. et al. (2011). Scikit-learn: Machine Learning in Python. Journal of Machine Learning Research, 12, 2825–2830.

Kumar, R., Minz, S. (2014). Feature Selection: A Literature Review. SmartCR, 4(3), 211–229.

Ngai, E.W.T., Hu, Y., Wong, Y.H., Chen, Y., & Sun, X. (2011). The application of data mining techniques in financial fraud detection: A classification framework and an academic review of literature. Decision Support Systems, 50(3), 559–569.

OpenWeatherMap. API. Disponível em: <https://openweathermap.org/api>.