

Estudo de uma estratégia de aprendizado de máquina baseada na Taxonomia de Kittler para detectar anomalias e reconhecer desmatamento no meio ambiente

LEONARDO DOS SANTOS CORADELI, FCT-UNESP, PRESIDENTE PRUDENTE, leonardo.coradeli@unesp.br

Apresentado no XXXVI Congresso de Iniciação Científica da Unesp – CIC 2024

“Ciência em tempos de crise climática e social”

INTRODUÇÃO: A preservação da flora desempenha um papel vital no equilíbrio ecológico e na mitigação de desastres ambientais. Com o aumento das atividades humanas que contribuem para o desmatamento, torna-se crucial o desenvolvimento de métodos eficazes de monitoramento. O monitoramento remoto, por meio de imagens de satélite e outras tecnologias, permite a detecção de anomalias, como áreas de desmatamento, em larga escala e em tempo real. A Taxonomia de Kittler [1-5], uma abordagem auxiliar ao aprendizado de máquina usada com sucesso na detecção de poluição aquática, surge como uma alternativa promissora para aplicação no monitoramento de desmatamento. Este projeto visa expandir o uso dessa técnica para a identificação de áreas desmatadas, buscando fornecer dados precisos e relevantes que possam contribuir para a conservação ambiental.

MATERIAL E MÉTODOS: O estudo teve início com uma ampla revisão da literatura para estabelecer um entendimento sólido sobre os desafios e métodos de monitoramento do desmatamento na Amazônia. Foram selecionadas imagens de satélite no formato .tiff, obtidas por meio da plataforma Google Earth Engine, focando em regiões com desmatamento crescente. As imagens passaram por um processo de pré-processamento usando o software QGIS, que incluiu a correção geométrica e ajustes para melhorar a qualidade visual e precisão dos dados. A análise envolveu a coleta de 100 amostras, divididas igualmente entre áreas desmatadas e áreas de floresta intacta. Usou-se a Orfeo Toolbox para aplicar os classificadores K-Nearest Neighbors (KNN) e Boost. A Taxonomia de Kittler norteou a segmentação e classificação das imagens, permitindo a comparação de desempenho entre os classificadores usados no reconhecimento de padrões de desmatamento.

RESULTADOS E DISCUSSÃO: Os resultados indicaram uma alta taxa de acurácia dos classificadores KNN e Boost na detecção de áreas desmatadas, ambos superando 85% de acurácia [6]. Essa consistência sugere que os padrões de desmatamento são suficientemente distintos para serem captados por diferentes técnicas de aprendizado de máquina. A aplicação da metodologia facilitou a distinção clara entre áreas de floresta e desmatamento, reforçando a robustez da abordagem para monitoramento ambiental. Contudo, foram identificadas áreas de incerteza, principalmente em zonas de transição entre floresta e áreas desmatadas, apontando para a necessidade de ajustes nos algoritmos para aumentar a sensibilidade e acurácia em mudanças sutis de vegetação.

CONCLUSÕES: A implementação da metodologia para identificar áreas de desmatamento em imagens de sensoriamento remoto demonstrou ser eficaz, proporcionando alta acurácia e concordância entre os classificadores KNN e Boost. Esses resultados sublinham o potencial dessa abordagem para aplicações em monitoramento ambiental em larga escala, permitindo a detecção precoce de desmatamento. Apesar dos resultados promissores, a identificação de áreas de incerteza sugere que mais refinamentos são necessários. Melhorias nos métodos de classificação e a integração de dados adicionais poderão aumentar a sensibilidade e a acurácia das detecções, contribuindo para estratégias mais eficazes de conservação e gestão ambiental. Estudos futuros deverão focar na otimização desses algoritmos e na ampliação do banco de dados para melhorar ainda mais a acurácia das detecções.

AGRADECIMENTOS: Gostaria de expressar minha profunda gratidão ao Dr. Prof. Mauricio Araujo Dias pelo valioso direcionamento e orientação ao longo deste projeto. Agradeço também à Pró-Reitoria de Pesquisa da UNESP (PROPE) pelo suporte financeiro e pela concessão da bolsa de pesquisa, que foram essenciais para a realização deste estudo. Minha sincera apreciação vai à UNESP pela oportunidade de desenvolvimento acadêmico e científico.

REFERÊNCIAS:

1. DIAS, Mauricio Araujo; MARINHO, Giovanna Carreira; NEGRI, Rogério Galante; WALLACE, Casaca; MUÑOZ, I. Bravo; ELER, D. Medeiros. A Machine Learning Strategy Based on Kittler's Taxonomy to Detect Anomalies and Recognize Contexts Applied to Monitor Water Bodies in Environments. *Remote Sensing*, v. 14, n. 9, p. 2222, 2022. <https://doi.org/10.3390/rs14092222>
2. DIAS, Mauricio Araujo; SILVA, E. A.; DE AZEVEDO, S. C.; WALLACE, Casaca; STATELLA, T.; NEGRI, R. G.. An incongruence-based anomaly detection strategy for analyzing water pollution in images from remote sensing. *Remote Sensing*, v. 12, n. 1, p. 43, 2019. <https://doi.org/10.3390/rs12010043>
3. MARINHO, G. Carreira et al. Associating Anomaly Detection Strategy Based on Kittler's Taxonomy with Image Editing to Extend the Mapping of Polluted Water Bodies. *Remote Sensing*, v. 15, n. 24, p. 5760, 2023. <https://doi.org/10.3390/rs15245760>
4. RODRIGUES, J.; DIAS, M. Araujo; WALLACE, Casaca. A Robust Dual-Mode Machine Learning Framework for Classifying Deforestation Patterns in Amazon Native Lands. *Land*, v. 13, n. 9, p. 1427, 2024. <https://doi.org/10.3390/land13091427>
5. MARINHO, G. Carreira et al. Dimensionality Reduction and Anomaly Detection Based on Kittler's Taxonomy: Analyzing Water Bodies in Two Dimensional Spaces. *Remote Sensing*, v. 15, n. 16, p. 4085, 2023. <https://doi.org/10.3390/rs15164085>
6. CARDIM, Guilherme Pina; SILVA, E. A.; DIAS, Mauricio Araújo. Algorithm development for analysis of statistical accuracy of the extraction of cartographic features in digital images. *Transactions on Machine Learning and Artificial Intelligence*, v. 2, n. 2, p. 32-47, 2014. <https://doi.org/10.14738/tmlai.22.123>