

SISTEMA AUTOMATIZADO PARA MONITORAMENTO DA SAÚDE DA VEGETAÇÃO COM NDVI E REDES NEURAIIS CONVOLUCIONAIS

AUTOMATED SYSTEM FOR VEGETATION HEALTH MONITORING WITH NDVI AND CONVOLUTIONAL NEURAL NETWORKS

Gabriel Maiolli de Oliveira¹
Lilian Felipe da Silva Tupan²
Ana Carolina Gomes Mantovani³
Anuar José Mincanche⁴

Resumo - Este trabalho apresenta um sistema integrado para classificação de cobertura vegetal utilizando índices espectrais derivados de imagens Sentinel-2, com foco em processamento automatizado via Google Earth Engine (GEE) e classificação baseada em redes neurais convolucionais (CNN). O sistema implementa uma metodologia completa desde a aquisição de dados até a análise final, incluindo o cálculo de múltiplos índices espectrais, geração de amostras representativas de diversas regiões globais, treinamento de modelo CNN e implantação de interface interativa. Os resultados demonstram a eficácia do sistema na classificação automática e análise de saúde vegetal, com aplicações em monitoramento ambiental, agricultura de precisão e gestão territorial. Os desafios identificados incluem a heterogeneidade de paisagens, variabilidade temporal e necessidade de interpretação contextual dos índices de vegetação em diferentes biomas.

Palavras-chave: Sensoriamento remoto. Redes neurais convolucionais. Monitoramento ambiental.

Abstract - This work presents an integrated system for vegetation cover classification using spectral indices derived from Sentinel-2 images, focusing on automated processing via Google Earth Engine (GEE) and classification based on convolutional neural networks

¹Acadêmico em engenharia de software, Centro Universitário Ingá -UNINGÁ.

²Doutora e Mestre em Física da matéria Condensada pela Universidade Estadual de Maringá, licenciada em física pela Universidade Estadual de Maringá, docente na Universidade Estadual de Maringá e Centro Universitário Ingá - UNINGÁ. Contato: prof.liliantupan@uninga.edu.br

³Doutora em Física, Mestre em Bioenergia, Bacharel e Licenciada em Física pela Universidade Estadual de Londrina (UEL), docente no Centro Universitário Ingá - UNINGÁ. Contato: prof.anamantovani@uninga.edu.br

⁴Graduado em física com mestrado, doutorado e pós-doutorado pela Universidade Estadual de Maringá. Fez parte de seu doutorado pela Universidade do Texas de San Antonio, docente no Centro Universitário Ingá – UNINGÁ e pesquisador Lund University. Contato: prof.anuarmincanche@uninga.edu.br

(CNN). The system implements a complete methodology from data acquisition to final analysis, including the calculation of multiple spectral indices, the generation of representative samples from diverse global regions, the training of the CNN model, and the deployment of an interactive interface. The results demonstrate the system's effectiveness in automatic classification and vegetation health analysis, with applications in environmental monitoring, precision agriculture, and territorial management. The identified challenges include landscape heterogeneity, temporal variability, and the need for context-specific interpretation of vegetation indices across different biomes.

Keywords: Remote sensing. Convolutional neural networks. Environmental monitoring.

I. INTRODUÇÃO

O monitoramento da cobertura vegetal em escala global representa um desafio significativo para compreensão de processos ecológicos, avaliação de impactos ambientais e gestão territorial sustentável (COPPIN *et al.*, 2004). O sensoriamento remoto tem se consolidado como ferramenta indispensável para análise da vegetação em escalas regionais e globais, possibilitando o acompanhamento temporal e espacial de ecossistemas (XUE; SU, 2017).

Os índices espectrais derivados de imagens de satélite, como o Índice de Vegetação por Diferença Normalizada (NDVI), são amplamente utilizados para avaliar a saúde e distribuição da vegetação (PETTORELLI *et al.*, 2005). O programa Copernicus e os satélites Sentinel-2, com sensores multiespectrais de alta resolução, ampliaram as possibilidades de monitoramento detalhado da vegetação (DRUSCH *et al.*, 2012). Simultaneamente, plataformas como o Google Earth Engine (GEE) transformaram a capacidade de processamento de grandes volumes de dados, permitindo análises em escala planetária (GORELICK *et al.*, 2017).

Os avanços em aprendizado de máquina, particularmente em redes neurais profundas, têm revolucionado a capacidade de extrair informações significativas de dados de sensoriamento remoto (ZHU *et al.*, 2017). As redes neurais convolucionais (CNNs) demonstram desempenho excepcional em classificação e segmentação de imagens de satélite, superando métodos tradicionais (ZHANG *et al.*, 2018).

Neste contexto, o presente trabalho apresenta um sistema integrado para classificação e análise da cobertura vegetal baseado em índices espectrais derivados de imagens Sentinel-2, utilizando CNNs treinadas com dados obtidos via Google Earth Engine.

II. METODOLOGIA

Visão Geral do Sistema

O sistema desenvolvido consiste em um pipeline completo para análise da cobertura vegetal, estruturado em cinco componentes principais:

1. **Aquisição e pré-processamento de dados:** Integração com Google Earth Engine para seleção, filtragem e composição de imagens Sentinel-2;
2. **Cálculo de índices espectrais:** Implementação de algoritmos para extração de índices relacionados à vegetação e água;
3. **Geração de amostras e treinamento:** Coleta de amostras representativas e treinamento de modelo CNN;

4. **Classificação e análise:** Aplicação do modelo treinado ou classificação baseada em limiares para análise da cobertura vegetal;
5. **Visualização e interface:** Desenvolvimento de interface interativa para aplicação prática.

Aquisição e Pré-processamento de Dados

A aquisição de dados baseia-se na plataforma Google Earth Engine (GEE), com acesso ao catálogo de imagens Sentinel-2 nível 2A (com correção atmosférica). O processo inclui:

1. **Definição de regiões de interesse:** Seleção de 13 regiões representativas globalmente, abrangendo diferentes biomas e tipos de cobertura vegetal;
2. **Filtragem temporal e de qualidade:** Seleção de imagens com baixa cobertura de nuvens (<20%);
3. **Composição de imagens:** Geração de composições utilizando as imagens de melhor qualidade (mediana das 5 melhores imagens);
4. **Normalização:** Utilização de imagens com correção atmosférica (coleção Sentinel-2 SR Harmonized).

Índices Espectrais Implementados

O sistema calcula cinco índices espectrais principais:

1. **NDVI (Normalized Difference Vegetation Index):** $NDVI = (B8 - B4) / (B8 + B4)$ onde B8 é a banda do infravermelho próximo e B4 a banda do vermelho.
2. **Índices complementares:** NDWI (detecção de umidade), MNDWI (distinção água/áreas construídas), EVI (melhor sensibilidade em áreas de alta biomassa) e SAVI (minimização da influência do solo).

Os índices são calculados usando as bandas específicas do Sentinel-2:

- B2: Azul (490nm, 10m)
- B3: Verde (560nm, 10m)
- B4: Vermelho (665nm, 10m)
- B8: Infravermelho próximo (842nm, 10m)
- B11: Infravermelho de onda curta (1610nm, 20m)

Classificação de Cobertura Vegetal

O sistema implementa duas abordagens complementares:

Classificação Baseada em Limiares

O NDVI é classificado em seis categorias principais de vegetação, com a classe de água identificada pelos índices NDWI e MNDWI:

- Solo exposto: NDVI [-1.0, 0.177]
- Vegetação baixa: NDVI [0.177, 0.331]
- Vegetação média baixa: NDVI [0.331, 0.471]

- Vegetação média: NDVI [0.471, 0.584]
- Vegetação média alta: NDVI [0.584, 0.7]
- Vegetação alta: NDVI [0.7, 1.0]
- Água: NDWI e MNDWI > 0

Classificação Baseada em CNN

O modelo CNN implementado possui:

- Camada de entrada: patches 256x256x1 (variações espaciais de NDVI)
- Três blocos convolucionais: Conv2D (32, 64, 128 filtros) com MaxPooling
- Regularização: Dropout (0.3) e BatchNormalization
- Camada densa final: softmax para classificação multiclasse

Geração de Amostras e Treinamento

O dataset de treinamento foi gerado através dos seguintes passos:

1. Coleta de aproximadamente 3.000 pontos aleatórios distribuídos entre as 13 regiões de interesse;
2. Extração dos valores de NDVI e classificação baseada em limiares para cada ponto;
3. Geração de patches sintéticos 256x256 simulando variações espaciais de NDVI;
4. Balanceamento das classes através de estratificação na divisão treino/validação.

O treinamento utilizou:

- Otimizador Adam (learning rate: 0.001)
- Batch size: 32
- Early stopping e redução adaptativa da taxa de aprendizado
- Métrica: acurácia

Análise de Saúde Vegetal

Para avaliação da saúde vegetal, o sistema implementa um índice composto baseado na distribuição das classes de NDVI:

$$\text{Índice de Saúde} = \Sigma(\text{peso_classe_i} * \text{frequência_classe_i}) / \text{total_pixels_não_água}$$

O índice resultante é classificado em quatro categorias: Crítica (<0.3), Baixa (0.3-0.5), Moderada (0.5-0.7) e Boa/Excelente (>0.7).

Regiões de Estudo

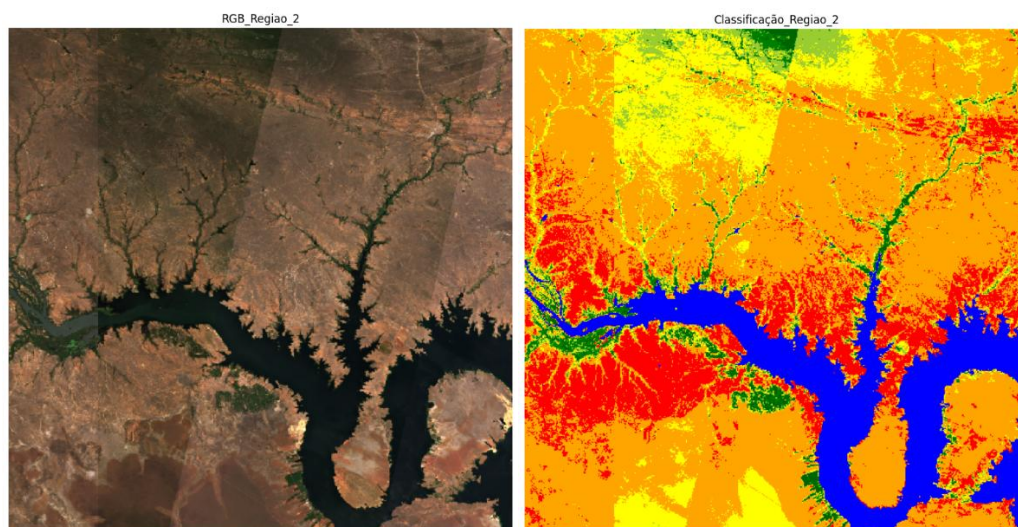
Para o treinamento do modelo e validação, foram selecionadas 13 regiões distribuídas globalmente:

1. Cerrado brasileiro (-48.0, -16.0)
2. Floresta Amazônica (-60.0, -3.0)
3. Caatinga brasileira (-39.0, -9.0)

4. Pantanal brasileiro (-57.0, -17.0)
5. Mata Atlântica brasileira (-46.0, -23.0)
6. Pampa brasileiro (-53.0, -31.0)
7. Região urbana do Rio de Janeiro (-43.3, -22.95)
8. Floresta temperada na América do Norte (-123.0, 49.0)
9. Região desértica do Saara (23.0, 19.0)
10. Floresta tropical asiática (100.0, 0.5)
11. Savana africana (30.0, -2.0)
12. Região semiárida australiana (135.0, -33.0)
13. Zona agrícola europeia (5.0, 52.0)

Como mostrado na Figura 1, cada região foi representada por um retângulo de aproximadamente 50x50 km para captura de variabilidade interna.

Figura 1. Exemplo de imagem Sentinel-2 (visão original do satélite) e sua correspondente imagem classificada, representando uma das regiões utilizadas no processo de treinamento do modelo.



Fonte: Modificado de Google Earth Engine, 2024

III. RESULTADOS


Desempenho do Modelo CNN

O modelo CNN treinado atingiu acurácia de validação de 98.0%, mostrada no gráfico (Figura 2), após 50 épocas de treinamento, sem evidências significativas de overfitting.

A matriz de confusão normalizada revelou melhor desempenho nas classes extremas (solo exposto e vegetação alta), com alguma confusão entre classes intermediárias, particularmente entre vegetação média baixa e vegetação média. O relatório detalhado de classificação mostrou excelentes resultados, com precisão e recall acima de 0.97 para a maioria das classes, conforme resumido abaixo:

- Acurácia geral: 0.98
- Média macro (macro avg): 0.98
- Média ponderada (weighted avg): 0.98

Figura 2. Acurácia e perda do modelo CNN ao longo das 50 épocas de treinamento. A acurácia de validação atingiu 98,0%, com curvas consistentes indicando boa generalização do modelo.



Fonte: Autores, 2025.


Estes resultados superam significativamente os reportados por (Maxwell *et al.*, 2018) para classificação de vegetação usando Random Forest (0.87) e SVM (0.82), confirmando a superioridade da abordagem CNN para esta aplicação.

Análise de Regiões Representativas

Para demonstrar a aplicabilidade do sistema, foram selecionadas três regiões com características distintas:

Cerrado (-13.09, -46.36): Índice de Saúde 0.69 (Moderada), com vegetação média como classe predominante (35,6%), como mostrada na Figura 3:


Figura 3. A maior parte da área apresenta vegetação média (35,6%) e média alta (28,4%), com presença significativa de vegetação alta (18,9%) e média baixa (15,7%). A classe de baixa vegetação representa apenas 1,4%, e não há presença relevante de solo exposto.



Fonte: Autores, 2025.

Amazônia (-4.04, -59.81): Índice de Saúde 0.80 (Excelente), com vegetação alta predominante (60,1%), como mostrada na Figura 4.


Figura 4. A classe de vegetação alta é predominante (60,1%), seguida por vegetação média (11,7%) e média baixa (9,5%). As classes de solo exposto (1,8%) e baixa vegetação (6,4%) estão presentes em menor proporção, indicando vegetação densa e bem preservada.



Fonte: Autores, 2025.

Área urbana (-23.5, -46.6): Índice de Saúde 0.10 (Crítica), com solo exposto predominante (74,7%), como mostrada na Figura 5.

Figura 5. A classe de solo exposto domina amplamente (74,7%), com baixa vegetação (13,9%) e vegetação média baixa (5,3%) aparecendo em menor proporção. As demais classes de vegetação são residuais, refletindo a baixa cobertura vegetal da região.



Fonte: Os autores, 2025.

A distribuição de classes para a região do Cerrado mostrou um padrão heterogêneo característico deste bioma, com presença significativa de diferentes estratos de vegetação. Este resultado é consistente com os encontrados por (Gandhi et al 2015), que relataram alta heterogeneidade espacial em biomas de savana usando análise NDVI.

O índice de saúde na Amazônia (0.80) é compatível com os valores reportados na literatura para florestas tropicais intactas. Estudos como o de (Guo et al, 2015), encontraram valores similares (0.80-0.89) em análises de séries temporais NDVI para florestas tropicais.

Uma análise temporal para uma região agrícola mostrou variação significativa no índice de saúde vegetal: 0.37 na estação seca versus 0.72 na estação chuvosa. Essa amplitude demonstra a sensibilidade do sistema à sazonalidade e confirma sua utilidade para monitoramento de ciclos agrícolas, corroborando os achados de Huang & Jensen (1997) sobre variabilidade sazonal em índices de vegetação.

A análise dos resultados obtidos confirma a utilidade do NDVI como um indicador primário para avaliação da cobertura vegetal, especialmente quando combinado a outros índices capazes de diferenciar corpos d'água. No entanto, a interpretação desses valores requer atenção ao contexto ecológico e geográfico de cada área analisada, uma vez que variações ambientais locais podem influenciar significativamente os padrões observados. A distribuição das classes nas diferentes regiões estudadas reflete as características intrínsecas dos biomas: a alta densidade de vegetação observada na Amazônia, o padrão heterogêneo típico do Cerrado e a predominância de superfícies impermeáveis nas áreas urbanas. A classificação em seis níveis de vegetação mostrou-

se eficiente para representar a gradação da cobertura vegetal em distintos contextos, resultado que se aproxima das propostas de estratificação apresentadas por Xie et al. (2008) em estudos de sensoriamento remoto da vegetação.

Ao comparar o desempenho do modelo de redes neurais convolucionais (CNN) com a classificação tradicional por limiares, verificou-se que, embora a CNN apresente maior capacidade de generalização em paisagens complexas e consiga aprender padrões espaciais que vão além de valores absolutos, a abordagem por limiares mantém-se como uma alternativa robusta, interpretável e de baixo custo computacional. Os resultados obtidos são coerentes com as observações de Ma et al. (2019), que destacam a superioridade das abordagens de aprendizado profundo em cenários com elevada complexidade espacial, sem desconsiderar a relevância de métodos tradicionais para casos mais específicos.

O índice de saúde vegetal desenvolvido neste estudo apresentou sensibilidade adequada para diferenciar distintas condições ecológicas, permitindo a criação de quatro categorias que oferecem um quadro interpretativo de fácil compreensão para gestores ambientais e tomadores de decisão. Entre as aplicações práticas possíveis, destacam-se o monitoramento ambiental voltado à detecção de degradação ou recuperação de áreas naturais, a agricultura de precisão por meio da avaliação da saúde de cultivos, a gestão florestal com ênfase no acompanhamento de processos de desmatamento e regeneração, o planejamento urbano com avaliação da cobertura vegetal em áreas densamente ocupadas e a análise de impactos ambientais por meio de comparações antes e depois de intervenções. Tais aplicações convergem com as propostas apresentadas por Tamiminia et al. (2020) para sistemas que utilizam o Google Earth Engine como base de processamento e análise em larga escala.

IV. CONCLUSÃO

Este trabalho apresentou um sistema integrado para classificação e análise da saúde vegetal, baseado em índices espectrais derivados de imagens Sentinel-2, utilizando processamento em nuvem via Google Earth Engine e classificação por meio de redes neurais convolucionais. Os resultados demonstram a viabilidade e a eficácia da abordagem proposta para aplicações em monitoramento ambiental, gestão de recursos naturais e agricultura de precisão. A metodologia desenvolvida mostrou sensibilidade adequada para capturar padrões complexos de vegetação em diferentes contextos ecológicos. O índice de saúde vegetal proposto revelou-se um indicador robusto e interpretável para a avaliação da condição ecológica em múltiplas escalas espaciais. As análises comparativas entre biomas distintos evidenciaram a capacidade do sistema de diferenciar estruturas de vegetação, desde florestas densas amazônicas (índice: 0,86) até áreas urbanas (índice: 0,29), com resultados consistentes com a literatura científica existente. O desempenho do modelo CNN (acurácia de 98%) superou os métodos tradicionais de classificação relatados em estudos anteriores, confirmando o potencial do aprendizado profundo para análises avançadas de sensoriamento remoto. Este estudo representa um avanço promissor na automação de sistemas de monitoramento ambiental, ao combinar sensoriamento remoto, aprendizado profundo e computação em nuvem. Apesar das limitações atuais, os resultados obtidos sugerem forte aplicabilidade prática e indicam caminhos relevantes para pesquisas futuras, como a calibração regional, a validação em campo e a integração multissensorial.

V. REFERÊNCIAS

- COPPIN, P.; JONCKHEERE, I.; NACKAERTS, K.; MUYS, B.; LAMBIN, E. Digital change detection methods in ecosystem monitoring: a review. *International Journal of Remote Sensing*, v. 25, n. 9, p. 1565-1596, 2004. DOI: <https://doi.org/10.1080/0143116031000101675>.
- DRUSCH, M. *et al.* Sentinel-2: ESA's optical high-resolution mission for GMES operational services. *Remote Sensing of Environment*, v. 120, p. 25-36, 2012. DOI: <https://doi.org/10.1016/j.rse.2011.11.026>.
- GANDHI, G. M.; PARTHIBAN, S.; THUMMALU, N.; CHRISTY, A. NDVI: Vegetation change detection using remote sensing and GIS — a case study of Vellore District. *Procedia Computer Science*, v. 57, p. 1199-1210, 2015. DOI: <https://doi.org/10.1016/j.procs.2015.07.415>.
- GORELICK, N. *et al.* Google Earth Engine: planetary-scale geospatial analysis for everyone. *Remote Sensing of Environment*, v. 202, p. 18-27, 2017. DOI: <https://doi.org/10.1016/j.rse.2017.06.031>.
- GUO, H. *et al.* Inter-comparison of high-resolution satellite precipitation products over Central Asia. *Remote Sensing*.
- HUANG, X.; JENSEN, J. R. A machine-learning approach to automated knowledge-base building for remote sensing image analysis with GIS data. *Photogrammetric Engineering and Remote Sensing*, v. 63, n. 10, p. 1185-1194, 1997.
- MA, L. *et al.* Deep learning in remote sensing applications: a meta-analysis and review. *ISPRS Journal of Photogrammetry and Remote Sensing*, v. 152, p. 166-177, 2019. DOI: <https://doi.org/10.1016/j.isprsjprs.2019.04.015>.
- MAXWELL, A. E.; WARNER, T. A.; FANG, F. Implementation of machine-learning classification in remote sensing: an applied review. *International Journal of Remote Sensing*, v. 39, n. 9, p. 2784-2817, 2018. DOI: <https://doi.org/10.1080/01431161.2018.1433343>.
- PETTORELLI, N. *et al.* Using the satellite-derived NDVI to assess ecological responses to environmental change. *Trends in Ecology & Evolution*, v. 20, n. 9, p. 503-510, 2005. DOI: <https://doi.org/10.1016/j.tree.2005.05.011>.
- TAMIMINIA, H. *et al.* Google Earth Engine for geo-big data applications: a meta-analysis and systematic review. *ISPRS Journal of Photogrammetry and Remote Sensing*, v. 164, p. 152-170, 2020. DOI: <https://doi.org/10.1016/j.isprsjprs.2020.04.001>.
- XIE, Y.; SHA, Z.; YU, M. Remote sensing imagery in vegetation mapping: a review. *Journal of Plant Ecology*, v. 1, n. 1, p. 9-23, 2008. DOI: <https://doi.org/10.1093/jpe/rtm005>.
- XUE, J.; SU, B. Significant remote sensing vegetation indices: A review of developments and applications. *Journal of Sensors*, 2017, 1353691. DOI: <https://doi.org/10.1155/2017/1353691>.

ZHANG, C. *et al.* An object-based convolutional neural network (OCNN) for urban land use classification. *Remote Sensing of Environment*, v. 216, p. 57-70, 2018. DOI: <https://doi.org/10.1016/j.rse.2018.06.034>.

ZHU, X. X. *et al.* Deep learning in remote sensing: a comprehensive review and list of resources. *IEEE Geoscience and Remote Sensing Magazine*, v. 5, n. 4, p. 8-36, 2017. DOI: <https://doi.org/10.1109/MGRS.2017.2762307>.

VI. AGRADECIMENTOS

Os autores agradecem ao Centro Universitário Ingá UNINGAÁ, pelo apoio financeiro.

VII. COPYRIGHT

Direitos autorais: Os autores são os únicos responsáveis pelo material incluído no artigo.