

CLASSIFICAÇÃO DE ÁREAS DE FLORESTAS USANDO CNN

Julio Gaspar¹

José Alberto Quintanilha²

RESUMO

É fundamental que sejam cumpridas as metas dos objetivos de desenvolvimento sustentável (ODS), para que se possa ter uma vida sustentável para as próximas gerações. Então ter técnicas que auxiliam no monitoramento das metas é de extrema importância. Assim é possível fiscalizar e avaliar se medidas que estão sendo tomadas estão tendo efeitos. O uso de sensoriamento remoto com o auxílio de redes neurais profundas são técnicas valiosas para realizar tal tarefa. O presente estudo propôs usar técnicas de rede neural convolucional para classificar as regiões de florestas das imagens do LANDSAT, com base nos dados do MAPBIOMAS. Os resultados mostraram que a área de vegetação florestal, objeto principal do estudo, foi calculada em 67% da área de estudo, enquanto na área classificada pela CNN foi de 63,3%. A diferença entre os dados foi de menos de 4% em termos de área total analisada. A matriz de confusão também mostrou uma boa concordância, com poucos erros de omissão e comissão. O método mostra-se promissor para tal classe conseguindo realizar a classificação das áreas florestais com o intuito de monitorar o avanço ou retrocesso da sua degradação.

Palavras-chave: Sensoriamento Remoto, Rede Neural Convolutional, Classificação de imagens de satélite

CLASSIFICATION OF FOREST AREAS USING CNN

ABSTRACT

It is essential to achieve the goals of the Sustainable Development Goals (SDGs) in order to ensure a sustainable life for future generations. Therefore, having techniques that assist in monitoring these goals is extremely important. This allows supervision and evaluation if the measures being taken are producing results. The use of remote sensing combined with deep neural networks is a valuable approach for carrying out this task. The present study proposed the use of convolutional neural network techniques to classify forest regions in LANDSAT images, based on data from MAPBIOMAS. The results showed that the area of forest vegetation, the main subject of the study, was calculated at 67% of the study area, while the area classified by the CNN was 63.3%. The difference between the datasets was less than 4% in terms of total analyzed area. The confusion matrix also showed good agreement, as both

¹Bacharel em Engenharia Agronômica (ESALQ/USP), Mestrando PROCAM USP, Universidade de São Paulo - USP, Email: julio.gaspar@alumni.usp.br

²Prof. Associado Senior IEE/USP, Universidade de São Paulo - USP, Email: jaquinta@usp.br

omission and commission errors were low. The method proves to be promising for this class, as it is capable of classifying forest areas with the aim of monitoring the progress or regression of their degradation.

Keywords: Remote Sensing, Convolutional Neural Network, Satellite Image Classification

CLASIFICACIÓN DE ÁREAS FORESTALES USANDO CNN

RESUMEN

Es fundamental que se cumplan las metas de los Objetivos de Desarrollo Sostenible (ODS), para que se pueda tener una vida sostenible para las próximas generaciones. Por lo tanto, contar con técnicas que ayuden en el monitoreo de las metas es de suma importancia. Así, es posible fiscalizar y evaluar si las medidas que se están tomando están teniendo efectos. El uso de teledetección con el apoyo de redes neuronales profundas son técnicas valiosas para llevar a cabo esta tarea. El presente estudio propuso utilizar técnicas de redes neuronales convolucionales para clasificar las regiones de bosques en las imágenes del LANDSAT, basándose en los datos del MAPBIOMAS. Los resultados mostraron que el área de vegetación forestal, objeto principal del estudio, fue calculada en un 67% del área de estudio, mientras que el área clasificada por la CNN fue del 63,3%. La diferencia entre los datos fue de menos del 4% en términos del área total analizada. La matriz de confusión también mostró una buena concordancia, ya que tanto los errores de omisión como de comisión fueron bajos. El método se muestra prometedor para tal clase, logrando realizar la clasificación de las áreas forestales con el objetivo de monitorear el avance o retroceso de su degradación.

Keywords: Teledetección, Red Neuronal Convolucional, Clasificación de imágenes de satélite

INTRODUÇÃO

É fundamental que sejam cumpridas as metas dos objetivos de desenvolvimento sustentável. Só assim poderemos garantir uma qualidade de vida e a existência de vida no planeta (ORGANIZAÇÃO DAS NAÇÕES UNIDAS - ONU, 2015). Porém essas metas exigem grandes mudanças na forma de pensar e envolvem aspectos sociais, ambientais e econômicos (DEL-AGUILA- ARCENTALES et al., 2022).

Porém essas metas não serão fáceis de atingir e apresentam alguns desafios, sendo o maior deles a disponibilidade de dados. A falta de dados considerados confiáveis e a dificuldade em monitorar o progresso dos objetivos são obstáculos significativos, principalmente em economias emergentes (MARTINS et al., 2022; KRONEMBERGER, 2019).

Técnicas de sensoriamento remoto são de grande importância para o monitoramento de alguns desses objetivos. Com elas é possível monitorar, em larga escala, alguns objetivos de interesse e em algumas situações, fazer a mensuração para correção de alguma medida de política protetiva (FERREIRA, 2025; PIMENTEL; FRIGO, 2024; SILVA, 2023; ESTOQUE, 2020).

Somado a isso, é possível se aproveitar da utilização de artifícios do aprendizado de máquinas. A integração do aprendizado de máquina com o sensoriamento remoto pode contribuir para a melhoria da sustentabilidade urbana, ao promover uma gestão mais eficiente, ajudando na tomada de decisões baseadas em dados e no planejamento e formulação de políticas públicas eficientes (LI et al., 2023; EKMEN; KOCAMAN, 2023). No trabalho de Pan *et al.* (2022) mostrou que a técnica combinada de aprendizado de máquina e rede neural convolucional profunda conseguiu monitorar de forma efetiva a utilização da floresta em direção aos Objetivos de Desenvolvimento Sustentável em regiões com escassez de dados, alcançando uma alta precisão geral, no mapeamento florestal, e de espécies de árvores e classificação etária. O principal benefício de se usar a técnica de aprendizado de máquina é que, depois que o algoritmo aprende a usar os dados fornecidos, ele pode executar a tarefa de forma autônoma (JARRALLAH; KHODHER, 2022; MAHESH, 2020).

Dentre as técnicas de aprendizado de máquinas, uma que tem se destacado são as redes neurais convolucionais (em inglês, Convolutional Neural Network - CNN). Os algoritmos que utilizam a CNN podem categorizar efetivamente outras classes em imagens de satélite, tornando a classificação de imagens de satélite simples e eficiente (CHOWDHURY et al., 2024; PRATIWI; FU'ADAH; EDWAR, 2021; JARRALLAH; KHODHER, 2022; MAGGIORI et al., 2017). Essas redes são eficazes no processamento de dados matriciais, como imagens, e são amplamente aplicadas em tarefas de visão computacional, incluindo classificação em imagens, detecção de objetos e segmentação semântica (LECUN; BENGIO; HINTON, 2015). A estrutura da rede é composta por uma sequência de camadas, das quais as

mais fundamentais são: camadas de convolução ou convolucionais, camadas de ativação, camadas de pooling e camadas totalmente conectadas (BAFFA; COELHO; CONCI, 2021; RONNEBERGER; FISCHER; BROX, 2015).

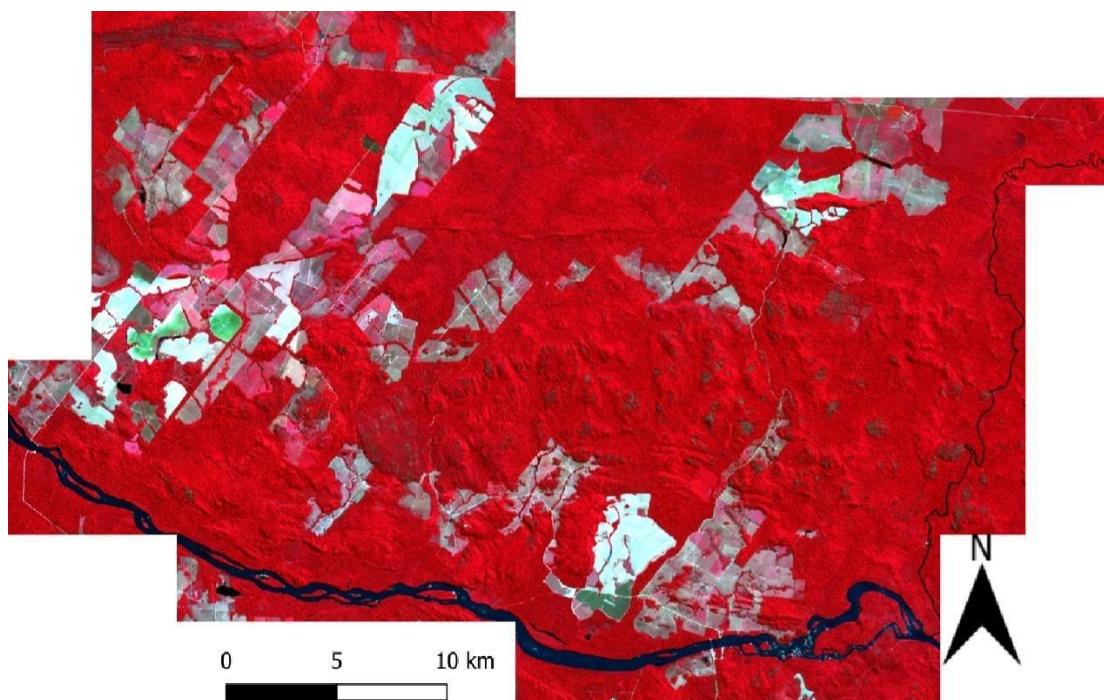
O presente estudo tem o intuito de analisar uma classificação feita com Rede Neural Convolucional e comparar, por meio da matriz de confusão, a sua eficiência com relação ao seu rótulo/classe de treinamento baseado no MAPBIOMAS.

MATERIAIS E MÉTODOS

Área de estudo

A área de estudo compreende o norte do município de Alta Floresta, Mato Grosso, Brasil (Figura 1), entre os limites do município e o rio. Foi escolhida essa área porque representa uma fronteira agrícola e também pela diversidade de alvos, como florestas, agricultura, solo exposto, rios, etc.

Figura 1 – Área de estudo. O dado é uma imagem de satélite LANDSAT 9, datada de 11/07/2023, falsa cor.



Fonte: Autor, 2025.

Dados de treinamento e rótulos

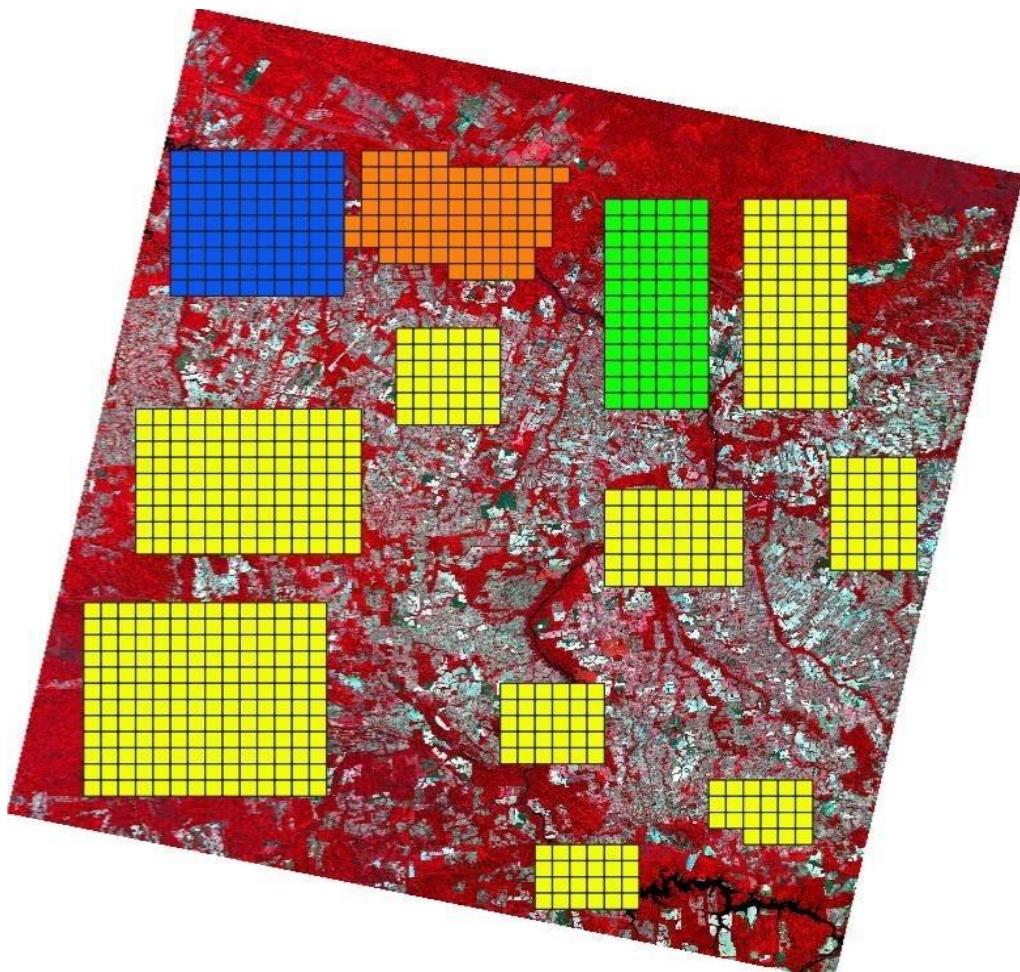
Para treinar o modelo de CNN é necessário ter um grupo de dados de treinamento, composto por partes, ou subimagens, da imagem de satélite, e os rótulos utilizados nas seções.

Como treinamento, foram utilizados partes da imagem do satélite LANDSAT, produtos do catálogo 9, coleção 2 nível 2, fornecidos pelo United States Geological Survey (USGS) (U.S. GEOLOGICAL SURVEY, 2024) (Figura 2). Foi feito o empilhamento das bandas 1 a 7 e em seguida recortadas em quadrados de 128 * 128 pixels.

Como rótulos, foram utilizados partes da imagem da Rede MAPBIOMAS, coleção 9 (MAPBIOMAS, 2024). A imagem foi reprojetada e ajustada para compatibilizar com as subimagens do LANDSAT.

As imagens foram processadas com o intuito de aumentar os dados para o treinamento. Para isso essas imagens, tanto treinamento quanto rótulos, foram rotacionadas 3 vezes, nos ângulos de 90, 180 e 270 graus. Desse modo foi possível quadruplicar a quantidade de dados (ALOMAR; AYSEL; CAI, 2023). Os dados pareados foram separados em 4 grupos: dados de treinamento, dados de validação, dados de teste e área de estudo (Figura 2).

Figura 2 – Imagem de satélite LANDSAT de 11/07/2023, falsa cor (bandas 4,3,2) da órbita ponto 227-067. Os quadrados representam as subimagens. Em amarelo as amostras de treinamento. Em azul as amostras de validação. Em verde as amostras de teste. Em laranja as amostras da área de estudo.



.Fonte: Autor, 2025.

Rede, arquitetura e parâmetros principais

O modelo utilizado para este estudo é uma arquitetura do tipo U-Net personalizada, projetada para realizar a segmentação semântica em imagens orbitais multiespectrais (como as do projeto LANDSAT). A rede é composta por uma série de camadas convolucionais organizadas em um caminho de contração (*encode*) e outro de

expansão (*decode*), permitindo a captura de informações espaciais e a recuperação da resolução original da imagem (RONNEBERGER; FISCHER; BROX, 2015).

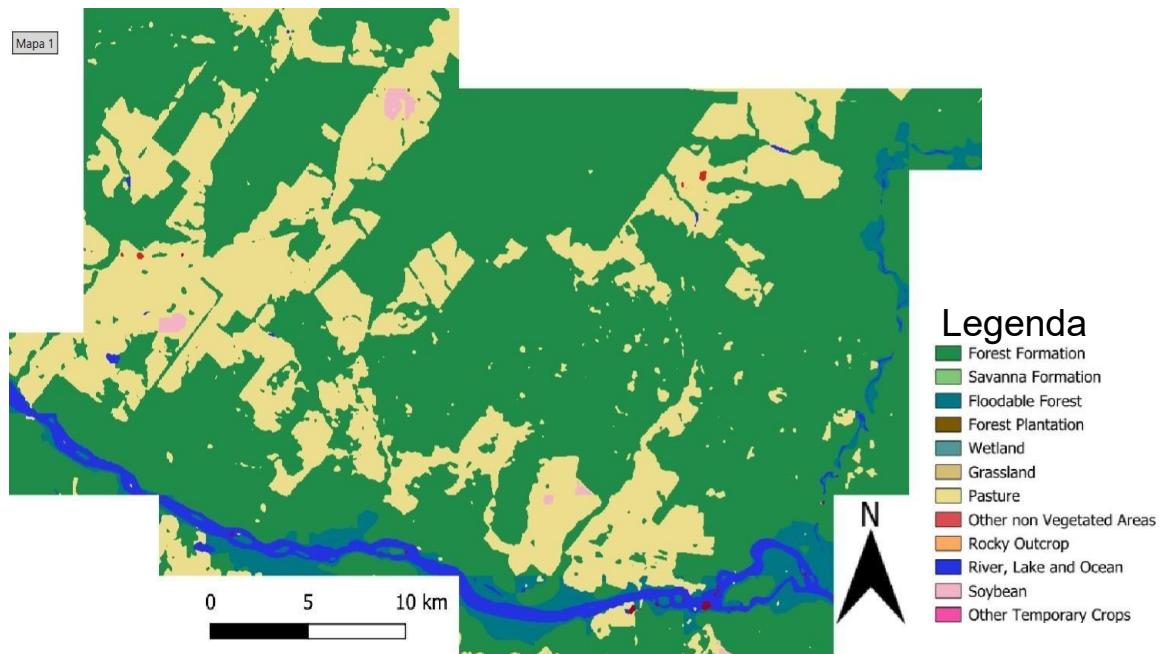
Para cada etapa da contração aplica-se convoluções seguidas de normalização em lote e a função de ativação do tipo *Rectified Linear Unit* (ReLU), além das camadas de *pooling* (para "redução de dimensionalidade" ou "agregação") para reduzir a dimensionalidade dos dados. No caminho da expansão, as camadas aplicam *upsampling* ("aumento de resolução" ou "reconstrução") nas ativações e utilizam operações de concatenação com os mapas de ativação correspondentes da contração, preservando informações espaciais importantes. Como as dimensões das imagens podem variar após cada etapa, são utilizadas funções auxiliares para realizar cortes e preenchimentos, garantindo que os mapas estejam corretamente alinhados para a concatenação. A função de ativação usada é definida como parâmetro, permitindo maior flexibilidade no uso da rede (RONNEBERGER; FISCHER; BROX, 2015).

A saída do modelo é gerada com uma camada convolucional de kernel 1x1 com ativação *softmax*, produzindo um mapa de classes por pixel (KOURETAS; PALIOURAS, 2019). A função de perda utilizada é baseada no coeficiente de Dice, que mede a similaridade entre os rótulos previstos e os verdadeiros, sendo apropriada para tarefas de segmentação com classes desbalanceadas (SEALE et al., 2022; WEN et al., 2020)

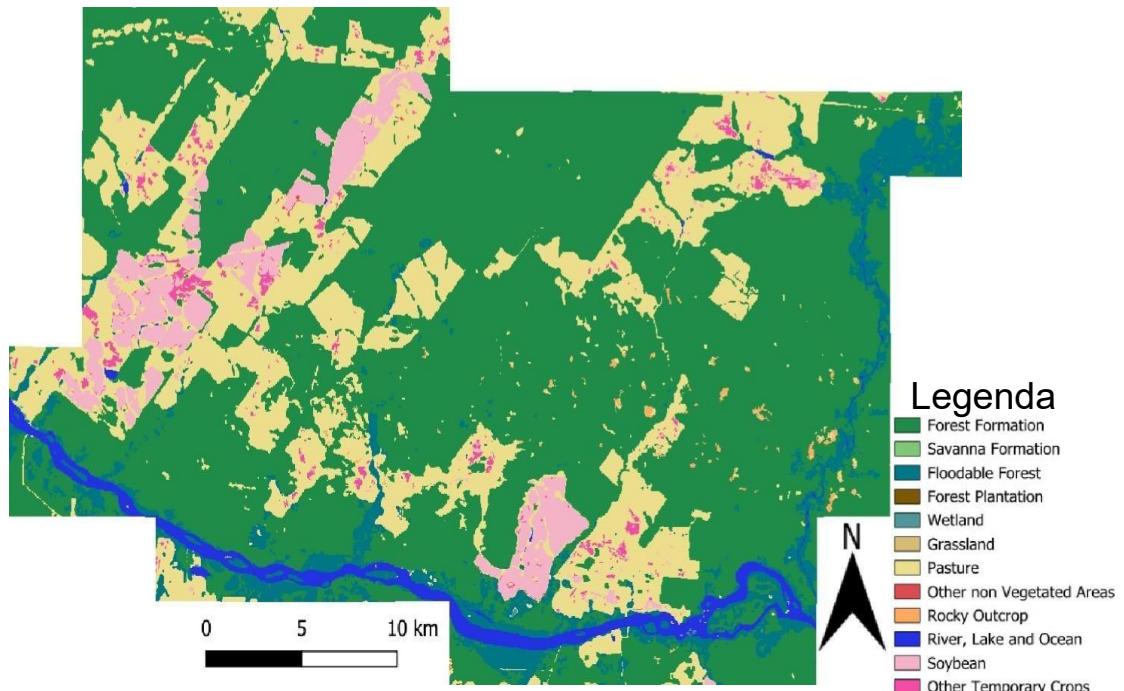
Como outros parâmetros para o modelo, foram utilizados: o otimizador do tipo Adam; 40 neurônios de base (que aumentam exponencialmente a cada camada de convolução); tamanho do lote 8; 500 épocas para treinamento e, relação treinamento / validação do modelo de 15%.

RESULTADOS E DISCUSSÃO

Como resultados, foram obtidas as subimagens classificadas pela CNN (Figura 3). Quando comparamos com as classificações do MAPBIOMAS (Figura 4) podemos notar que a rede generalizou algumas classes. Como o intuito é focar nas áreas de florestas, então concentrarmos o estudo nessa parte. A legenda de cores dos mapas abaixo são as mesmas utilizadas no projeto MAPBIOMAS, 2023.

Figura 3 – Imagem classificada pela CNN da região norte de alta floresta

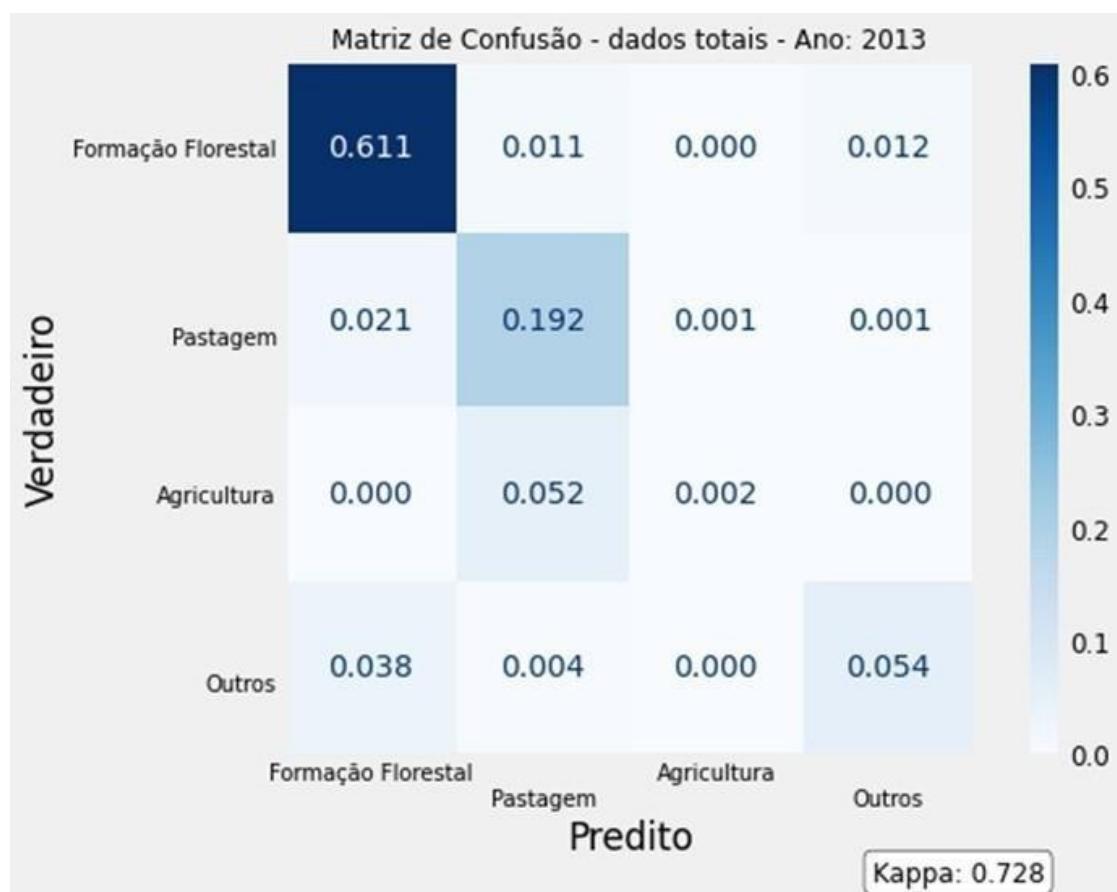
Fonte: Autor, 2025

Figura 4 – Imagem do MAPBIOMAS de 2023 da região norte de alta floresta

Fonte: MAPBIOMAS, 2023

Para validar o resultado foram geradas matrizes de confusão entre os dados preditos e os do MAPBIOMAS das regiões de teste, validação e a matriz da região de estudo (Figura 5). A matriz de confusão é uma ferramenta útil na comparação de dados com várias classes, permitindo olhar um todo e analisar os dados avaliando os falsos positivos e negativos (RIEHL; NEUNTEUFEL; HEMBERG, 2023; HEYDARIAN; DOYLE; SAMAVI, 2022; KOHAVI; PROVOST, 1998).

Figura 5 – Matriz de confusão dos dados totais com o valor do kappa no canto inferior direito



Fonte: Autor, 2025

Podemos ver pela matriz que a classe floresta (alvo da pesquisa) teve uma acurácia satisfatória. As outras classes já não foram tão favoráveis. Porém há considerações, conforme será citado mais a frente.

A área de vegetação florestal no dado base (MAPBIOMAS) foi calculada em 67% da área de estudo, enquanto da área classificada pela CNN foi de 63,3%. Ou seja, a diferença entre os dados foi de menos de 4% em termos de área total analisada.

Sobre as classes agricultura e pastagem, é importante lembrar que, devido a época (mês de Setembro), já não se encontra mais as culturas, pois as mesmas já foram colhidas, deixando o solo, ou exposto, ou com uma cobertura para proteção do solo. O período é o mais seco o que deixa as pastagens e plantas semelhantes com baixo vigor, confundindo todas essas categorias com o solo exposto (SILVA et al., 2024). A classe outros, é composta por outras classes com poucas amostras, apresentou baixo desempenho devido ao seu desbalanceamento, pois os classificadores de rede neural tendem a ser enviesados para o aprendizado da classe majoritária e ignoram as amostras da classe minoritária (SOLTANZADEH; FEIZI-DERAKHSHI; HASHEMZADEH, 2023). A época escolhida foi devido a baixa cobertura de nuvens, fundamental para o treinamento adequado.

A técnica se mostra eficaz para classificar o objeto floresta, permitindo usar esse dado para monitorar áreas ainda não desmatadas. Porém, tem uma limitação, neste caso, devido aos poucos dados (uma vez que foi utilizado apenas uma imagem orbital) e aos recursos computacionais, que limitam a expansão da rede. Mas à medida que o sistema computacional evoluir e mais dados forem disponibilizados, a técnica se torna mais valiosa.

CONSIDERAÇÕES FINAIS

O presente estudo demonstrou que a utilização de técnicas de redes neurais convolucionais (CNN), aliadas aos dados obtidos por meio de sensoriamento remoto, torna-se uma ferramenta promissora para a classificação de áreas de vegetação florestal. Mesmo com algumas limitações como o uso de uma única imagem orbital e restrições computacionais, a metodologia aplicada obteve um desempenho satisfatório na identificação da classe floresta, com uma diferença inferior a 4% em relação aos dados de referência (MAPBIOMAS) em termos de área total.

Apesar de algumas classes apresentarem baixo desempenho, fatores como o desbalanceamento dos dados e a época de aquisição da imagem explicam parte desse problema. Ainda assim, a capacidade da rede em generalizar e classificar áreas do tipo florestal com boa acurácia indica que este tipo de abordagem é válido e pode ser utilizada como apoio para monitorar o ambiente, especialmente em regiões com histórico de pressão antrópica.

A continuidade e aprimoramento desta linha de pesquisa pode-se incluir a utilização de séries temporais de imagens orbitais, o aumento da base de treinamento, bem como o uso de redes mais profundas e/ou arquiteturas mais avançadas. Portanto, espera-se ampliar a capacidade preditiva do modelo e contribuir para o alcance das metas e/ou monitoramento dos Objetivos de Desenvolvimento Sustentável (ODS), promovendo uma gestão eficiente e baseada em dados sobre os recursos naturais.

AGRADECIMENTOS

Os Autores agradecem ao Programa de Ciência Ambiental - PROCAM - da universidade de São Paulo e ao CNPQ Processo 312796-2023/2024.

REFERÊNCIAS

ALOMAR, K.; AYSEL, H. I.; CAI, X.. Data Augmentation in Classification and Segmentation: A Survey and New Strategies. *Journal of Imaging*, v. 9, 2023.

BAFFA, M. de F. O.; COELHO, A. M.; CONCI, Aura. Segmentação de imagens infravermelhas para detecção do câncer de mama utilizando u-net cnn. In: SBC. Simpósio Brasileiro de Computação Aplicada à Saúde (SBCAS). [S.l.: s.n.], 2021. P. 119–128.

CHOWDHURY, M. T.; RAHMAN, H.; SUMON, M.I.; Talha A. Classification of satellite images with VGG19 and Convolutional Neural Network (CNN). In: IEEE. 2024 2nd International Conference on Advancement in Computation & Computer Technologies (InCACCT). [S.l.: s.n.], 2024. P. 397–402.

DEL-AGUILA-ARCENTALES, S.; ALVAREZ-RISCO, A.; JARAMILLO-ARÉVALO, M.; DE-LA-CRUZ-DIAZ, M.; DE LAS MERCEDES ANDERSON-SEMINARIO, M. Influence of Social, Environmental and Economic Sustainable Development Goals (SDGs) over Continuation of Entrepreneurship and Competitiveness. **Journal of Open Innovation: Technology, Market, and Complexity**, 2022.

EKMEN, O.; KOCAMAN, S. From Pixels to Sustainability: Trends and Collaborations in Remote Sensing for Advancing Sustainable Cities and Communities (SDG 11). **Sustainability**, 2023. DOI: 10.3390/su152216094.

ESTOQUE, R. C. A review of the sustainability concept and the state of SDG monitoring using remote sensing. **Remote Sensing**, MDPI, v. 12, n. 11, p. 1770, 2020.

FERREIRA, M. Y. F. **Avaliação do indicador de desenvolvimento sustentável associado à degradação do solo no estado do Paraná**. 2025. B.S. thesis – Universidade Tecnológica Federal do Paraná.

HEYDARIAN, M.; DOYLE, T. E.; SAMAVI, R.. MLCM: Multi-Label Confusion Matrix. **IEEE Access**, v. 10, p. 19083–19095, 2022. DOI: 10.1109/access.2022.3151048.

JARRALLAH, Zainab H; KHODHER, Maisa'a Abid Ali. Satellite images classification using cnn: A survey. In: IEEE. 2022 International Conference on Data Science and Intelligent Computing (ICDSIC). [S.l.: s.n.], 2022. P. 111–116.

PHAN, A.; TAKEJIMA, K.; HIRAKAWA, T.; FUKUI, H. Monitoramento de questões de ODS relacionadas a florestas para regiões com escassez de dados empregando aprendizado de máquina e sensoriamento remoto - Um estudo de caso para a cidade de Ena, Japão. **IGARSS 2022 - 2022 IEEE International Geoscience and Remote Sensing Symposium**, p. 4343–4346, 2022. DOI: 10.1109/IGARSS46834.2022.9883037.

KOHAVI, R.; PROVOST, F. Confusion matrix. **Machine learning**, v. 30, n. 2-3, p. 271–274, 1998.

KOURETAS, I.; PALIOURAS, V.. Simplified hardware implementation of the softmax activation function. In: IEEE. 2019 8th international conference on modern circuits and systems technologies (MOCAST). [S.l.: s.n.], 2019. P. 1–4.

KRONEMBERGER, D. M. P.. Os desafios da construção dos indicadores ODS globais. **Ciência e cultura**, Sociedade Brasileira para o Progresso da Ciência, v. 71, n. 1, p. 40–45, 2019.

LECUN, Y.; BENGIO, Y.; HINTON, G.. Deep learning. **Nature**, Nature Publishing Group UK London, v. 521, n. 7553, p. 436–444, 2015.

LI, F.; YIGITCANLAR, T.; NEPAL, M.; NGUYEN, K.; DUR, F. Machine Learning and Remote Sensing Integration for Leveraging Urban Sustainability: A Review and Framework. **Sustainable Cities and Society**, 2023. DOI: 10.1016/j.scs.2023.104653.

MAHESH, B. Machine learning algorithms-a review. **International Journal of Science and Research (IJSR). [Internet]**, v. 9, n. 1, p. 381–386, 2020.

MAPBIOMAS. **Projeto MapBiomass: Coleção 9 da Série Anual de Mapas de Cobertura e Uso da Terra do Brasil, período de 1985 a 2023**. [S.l.: s.n.], 2024. <https://brasil.mapbiomas.org/2025/03/13/mapbiomas-publica-segunda-colecao-de-mapas-anuais-de-cobertura-e-uso-da-terra-do-brasil-com-resolucao-espacial-de-10-metros/>. Acesso em: 11 abr.

2025.

MARTINS, A. L. J.; SILVEIRA F.; DE SOUZA, A. A.; PAES-SOUZA, R. Potencialidades e desafios do monitoramento da saúde na Agenda 2030 no Brasil. **Ciência & Saúde Coletiva**, SciELO Brasil, v. 27, p. 2519–2529, 2022.

ORGANIZAÇÃO DAS NAÇÕES UNIDAS. **Objetivos de Desenvolvimento Sustentável**. [S.l.: s.n.], 2015. <https://brasil.un.org/pt-br/sdgs>. Acessado em abril de 2025. Disponível em: <<https://brasil.un.org/pt-br/sdgs>>.

PIMENTEL, J. de O. C.; FRIGO, J. P.. Sensoriamento remoto aplicado na sustentabilidade ambiental e sua relação com os ODS visando a gestão dos resíduos sólidos: uma revisão. **Revista do Departamento de Geografia**, v. 44, e217530–e217530, 2024.

PRATIWI, N. K. C.; FU'ADAH, Y. N.; EDWAR, E.. Early detection of deforestation through satellite land geospatial images based on CNN architecture. **Jurnal Infotel**, v. 13, n. 2, p. 54–62, 2021.

RIEHL, K.; NEUNTEUFEL, M.; HEMBERG, M. Hierarchical confusion matrix for classification performance evaluation. *ArXiv*, abs/2306.09461, 2023. DOI: 10.1109/jrssc/qlad057.

RONNEBERGER, O.; FISCHER, P.; BROX, T.. U-net: Convolutional networks for biomedical image segmentation. In: SPRINGER. MEDICAL image computing and computer-assisted intervention–MICCAI 2015: 18th International Conference, Munich, Germany, October 5-9, 2015, **Proceedings**, part III 18. [S.l.: s.n.], 2015. P. 234–241.

SEALE, C.; REDFERN T.; CHATFIELD P.; LUO C.; DEMPSEY K. Coastline detection in satellite imagery: A deep learning approach on new benchmark data. **Remote Sensing of Environment**, Elsevier, v. 278, p. 113044, 2022.

SILVA, A. G. P.; GALVÃO, L. S.; FERREIRA JÚNIOR, L. G.; TELES, N.M.; MESQUITA V.V.; HADDAD, I. Discrimination of Degraded Pastures in the Brazilian Cerrado Using the PlanetScope SuperDove Satellite Constellation. **Remote. Sens.**, v. 16, p. 2256, 2024. DOI: 10.3390/rs16132256.

SILVA, J. C. da. Monitoramento e Avaliação para o Planejamento Urbano Ecológico com o Uso do Sensoriamento Remoto e dos Sistemas de Informação Geográfica. 2023. Diss. (Mestrado) – Universidade NOVA de Lisboa (Portugal).

SOLTANZADEH, P.; FEIZI-DERAKHSHI, M.; HASHEMZADEH, M.. Addressing the class-imbalance and class-overlap problems by a metaheuristic-based under-sampling approach. **Pattern Recognit.**, v. 143, p. 109721, 2023. DOI: 10.1016/j.patcog.2023.109721.

U.S. GEOLOGICAL SURVEY. **Landsat Missions: Remote Sensing of the Earth**. [S.l.: s.n.], 2024. <https://www.usgs.gov/landsat-missions>. Acesso em: 11 abr. 2025.

WEN, K. Y.; LIU, T. J.; LIU, K. H.; CHAO, D.Y. Identifying poultry farms from satellite images with residual dense u-net. In: IEEE. 2020 IEEE International Conference on Systems, Man, and Cybernetics (SMC). **Proceedings** [S.l.: s.n.], 2020. P. 102–107.

MAGGIORI, E.; TARABALKA, Y.; CHARPIAT, G.; ALLIEZ, P. Convolutional Neural Networks for Large-Scale Remote-Sensing Image Classification, in **IEEE Transactions on Geoscience and Remote Sensing**, vol. 55, no. 2, pp. 645-657, Feb. 2017, doi: 10.1109/TGRS.2016.2612821.