

USO DE DEEP LEARNING E MACHINE LEARNING PARA O MAPEAMENTO DE SISTEMAS AGROFLORESTAIS

Victória Beatriz Soares ¹, Taya Cristo Parreiras ², Gustavo Bayma ³, Danielle Elis Garcia Furuya ⁴
Édson Luis Bolfe ⁵, Victória H. Matusevicius e de Castro ⁶

¹Pontifícia Universidade Católica de Campinas, Graduação em Geografia, Campinas, SP, Brasil, victoria.leandro@colaborador.embrapa.br; ²Universidade Estadual de Campinas, Pós-Graduação em Geografia, Campinas, SP, Brasil, taya.parreiras@colaborador.embrapa.br; ³Embrapa Meio Ambiente, Jaguariúna, SP, Brasil, gustavo.bayma@embrapa.br; ⁴Embrapa Agricultura Digital, Pós-Doutorado, Campinas, SP, Brasil, danielle.furuya@colaborador.embrapa.br; ⁵Embrapa Agricultura Digital, Campinas, SP, Brasil, edson.bolfe@embrapa.br; ⁶Universidade Estadual de Campinas, Graduação em Engenharia Agrícola, Campinas, SP, Brasil, victoria.castro@colaborador.embrapa.br

RESUMO

Sistemas Agroflorestais (SAFs) são técnicas agrícolas que podem associar culturas florestais, frutíferas e agrícolas, além de animais, visando a sustentabilidade ambiental, especialmente em regiões tropicais como o Brasil. Entretanto, é um desafio mapear esses sistemas com técnicas de sensoriamento remoto, devido principalmente à sua complexidade estrutural e heterogeneidade de espécies. O objetivo deste estudo foi revisar a literatura disponível sobre o uso de *deep learning* e *machine learning* no mapeamento de ambientes agrícolas complexos, com foco para os SAFs. Embora existam avanços no mapeamento de culturas em SAFs, a literatura ainda carece de técnicas visando a detecção desses sistemas produtivos. Os resultados indicam que entre os principais desafios observados estão a similaridade das assinaturas espectrais das áreas e a necessidade de maior resolução espacial e temporal dos sensores utilizados.

Palavras-chave — inteligência artificial, aprendizado de máquina, sensoriamento remoto, SAF's.

ABSTRACT

Agroforestry systems (SAFs) are assertive techniques aimed at environmental sustainability, especially in tropical regions such as Brazil. However, it is a challenge to map these systems using remote sensing techniques, mainly due to their complexity and structural heterogeneity. The aim of this study was to review the available literature on the use of deep learning in mapping complex agricultural environments, with a focus on SAFs. Although there have been advances in mapping crops in SAFs, the literature still lacks techniques for detecting them on a large scale. Among the main challenges observed are the similarity of spectral signatures and the need for greater spatial and temporal resolution.

Key words — artificial intelligence, machine learning, remote sensing, SAF's

1. INTRODUÇÃO

Os Sistemas Agroflorestais (SAFs) são arranjos de espécies organizados de maneira sequencial, associando culturas agrícolas com espécies arbóreas e/ou animais. Esses sistemas buscam, ao longo do tempo, simular as condições da dinâmica natural e, com isso, auxiliar na construção de um modo de vida sustentável à população local [1,2]. No Brasil, os SAFs se assemelham com as características das florestas tropicais, onde melhor se adaptam. Estudos baseados em imagens como o LiDAR (*Light Detection and Ranging*) e índices de vegetação, a exemplo de NDVI (*Normalized Difference Vegetation Index*), EVI (*Enhanced Vegetation Index*), e SAVI (*Soil Adjusted Vegetation Index*), derivados de imagens de satélite de resolução espacial média ou moderada, têm sido realizados com foco no mapeamento e estimativas de biomassa de carbono [3]. Entretanto, o mapeamento e monitoramento desses tipos de sistemas enfrentam desafios significativos, uma vez que técnicas tradicionais de sensoriamento remoto possuem limitações para elevar a precisão em algumas regiões.

Na última década, o uso de algoritmos baseados em *deep learning* (DL) têm se destacado como uma alternativa promissora para superar essas barreiras metodológicas. Esses ambientes são caracterizados por elementos como a diversidade ecológica e padrões espaciais heterogêneos, o que dificulta a utilização de técnicas tradicionais de mapeamento, e as redes neurais profundas conseguem capturar padrões complexos em grandes volumes de dados, além de segmentar, detectar e classificar espécies de plantas com muito alta precisão [4].

Apesar disso, a literatura ainda carece de iniciativas que consigam detectar SAFs em grandes territórios de forma abrangente. A maioria dos trabalhos foca no mapeamento de SAFs já conhecidos em locais específicos, como para identificar as culturas presentes nessas áreas. Nesse sentido, esse trabalho visa contribuir para esse campo por meio de uma análise bibliográfica sobre a utilização de DL e *machine learning* (ML) em SAFs, identificando as principais metodologias utilizadas nos artigos já publicados e quais as limitações indicadas pelos autores.

2. MATERIAL E MÉTODOS

2.1. Sistemas Agroflorestais

Na Figura 1 são apresentadas três imagens de satélite com sistemas agroflorestais no município de Tomé-Açu, PA. Observa-se a grande heterogeneidade produtiva e diversidade florística de áreas conduzidas com SAF's, além da disparidade na visualização em diferentes resoluções.




Figura 1. Área conduzida com SAF's no município de Tomé-Açu, PA. Imagem em cor verdadeira do Google Satélite (A), CBERS 4A pancromática em 2 m (B), obtida junto Brazil Data Cube (<https://data.inpe.br/bdc/web/>) e Planet Scope em 4.77 m (C), obtido via Google Earth Engine.

2.2. Bases de Dados Analisada

Para visualizar a distribuição dos artigos já publicados acerca do uso de ML e DL em ambientes agrícolas complexos, foi realizada uma busca no Web of Science (WoS) utilizando as seguintes palavras-chave: TS= ((intercropping OR agroforestry) AND (deep learning OR machine learning OR artificial intelligence) AND (remote sensing)). Visando a análise dos resultados da busca, foram aplicadas métricas bibliográficas relacionadas à origem, à quantidade, aos tipos de métodos utilizados e às principais características de cada artigo.

3. RESULTADOS E DISCUSSÃO

3.1. Evolução das publicações com *deep learning* em SAFs

Os resultados da busca na WoS¹¹ demonstraram a distribuição das áreas de estudo na configuração exibida na Figura 2. A busca retornou 14 artigos, sendo um artigo publicado no ano de 2019, três artigos em 2020, cinco em 2023 e quatro em 2024, indicando crescimento linear do número de estudos ao longo dos últimos 5 anos. Nota-se a maior concentração de estudos em áreas tropicais, como no Brasil, nos países do

continente africano e na Índia, principalmente devido à melhor adaptação dos SAFs às condições ambientais e socioeconômicas do mundo tropical [5].

De acordo com os estudos analisados, o *Deep Learning* (DL) tem sido usado, principalmente, para a melhor classificação e extração de informações sobre culturas e coberturas do solo em SAFs [12,13]. Além disso, destacam-se outros usos, como a detecção de necessidade de intervenção, a detecção de áreas de SAFs e a utilização de índices de vegetação (IV) para a estimativa de biomassa [3]. Em dez artigos foram utilizados algoritmos de *Machine Learning* (ML), com foco para o *Random Forest* (RF) e o *Support Vector Machine* (SVM), enquanto o DL foi a principal ferramenta em apenas três artigos, com ênfase às redes neurais convolucionais (CNN), redes neurais profundas (DNN) e redes de memória de longo prazo (LSTM). Dois artigos adotaram uma abordagem conjunta, integrando DL e ML.




Figura 2. Distribuição das áreas de estudo dos artigos resultantes da busca na Web of Science.

3.2. Principais aplicações do *Deep Learning* em ambientes agrícolas complexos

De forma geral, os artigos que utilizaram o ML, tiveram como principal fonte de imagens aquelas advindas de satélites orbitais, como o Sentinel-2, o MODIS e o Pléiades. As abordagens com o DL ou a integração de ML e DL, utilizaram imagens de resolução submétrica capturadas por Aeronaves Remotamente Pilotada (ARP), em alguns casos equipadas com sensores imageadores para maior resolução espectral e sistemas mais precisos de geolocalização e alta precisão.

Uma nuvem de palavras foi criada com as palavras-chave dos 14 artigos (Figura 3). A distribuição de palavras mostra que, apesar de os artigos utilizarem diferentes metodologias, dados e sensores, algumas palavras ainda são comuns a eles, como *remote sensing*, *machine learning*, *neural*, *classification* e *systems*.

¹ Informações sobre os artigos resultantes da busca realizada na plataforma Web of Science podem ser acessadas no link: <https://abrir.link/YQZwu>

3.3. Principais desafios para o mapeamento de SAFs

O uso de SAFs para produção de alimentos é difundido em diversos países há pelo menos duas décadas, mas é nas regiões tropicais que esses sistemas encontram seus melhores resultados. Um exemplo prático no Brasil é a Amazônia, onde os SAFs se assemelham às características naturais das florestas primárias da região, com condições microclimáticas semelhantes [6,7].

O uso multifuncional da terra possibilitado pelos SAFs, marcado pela diversificação de espécies e culturas, oferece diversas soluções pautadas na natureza para problemas socioeconômicos e ambientais [8]. Entretanto, do ponto de vista técnico, os fatores de complexidade espacial e heterogeneidade dificultam os processos de mapeamento e monitoramento dos SAFs por meio de técnicas tradicionais de geoprocessamento e sensoriamento remoto [9].




Figura 3. Nuvem de palavras com as palavras-chave dos artigos

Dessa forma, estratégias mais tradicionais de mapeamento, como por meio de classificação de séries temporais assinaturas espectrais são insuficientes nestes casos [4]. Estes desafios justificam, em parte, a razão deste tipo de sistema de produção ser dificilmente abordado em estudos com monitoramento remoto, uma vez que a variabilidade intra-campo, em escala infra-métrica, é extremamente elevada [4]. Nesse sentido, autores destacam a importância de métodos baseados em aprendizado de máquina, principalmente em aprendizado profundo, capazes de identificar e monitorar com maior precisão biomassa acima do solo, tipos de espécies, interações e configurações para lidar com a complexidade dos SAFs [10].

A coleta de informações em ambientes agrícolas complexos costuma acontecer por meio de visitas de campo, entrevistas com os agricultores e cooperativas participantes. Esse tipo de técnica, vista como custosa e demorada, limita a eficiência necessária à obtenção de dados precisos e que estejam em constante disponibilidade e atualização. Dessa forma, há a necessidade de novas metodologias que consigam fazer esse tipo de mapeamento e coleta de dados de forma mais automatizada e eficiente [11]. Além disso, foi indicada a existência de erros de classificação entre florestas naturais e plantações de culturas em ambientes de SAFs, evidenciando a

necessidade de novas metodologias que consigam auxiliar nesse sentido [12,13]

Ambientes como os SAFs exigem a constante criação de técnicas mais avançadas de detecção visando seu mapeamento. De modo geral, na última década, as CNN têm demonstrado melhores resultados quando comparadas às técnicas tradicionais de aprendizado de máquina superficial (*shallow learning*). Exemplo disso foi mostrado em análise comparativa entre o desempenho de CNN, RF e SVM em uma classificação de uso e cobertura da terra nos EUA e na Coreia do Sul, utilizando imagens do *Landsat 8* (30 m), e do *Geostationary Ocean Color Imager*, com resolução de 500 m. A técnica de CNN utilizada foi pautada na utilização de gráficos de curvas espectrais bidimensionais, que podem adicionar ciclos fenológicos às variáveis de análise. Os resultados mostraram que o modelo de CNNs foi superior em acurácia em ambas as localidades e enfatizaram a nova técnica de utilizar bandas espectrais no formato 2D para aplicações em CNN [14].

Pesquisadores utilizaram técnicas de DL para classificar SAFs nos distritos de Tamil Nadu, Kanyakumari, Tirunelveli e Tenkasi, na Índia, visando resolver problemas de detecção e monitoramento, que dificultavam o objetivo de expansão de agroflorestas no país. A metodologia envolveu uma técnica híbrida de DL que combinou CNNs, DNNs e LSTMs na classificação com imagens *Landsat* 8. Nesse caso, foram classificados SAFs com diferentes tipos de cultura, como banana, borracha, coco e áreas agrícolas temporárias. Os resultados indicaram um índice kappa de 0,88 e acurácia de 98,23%, demonstrando que o método proposto estabeleceu uma boa metodologia no mapeamento das espécies dos SAFs [15].

Entretanto, os artigos analisados não indicaram uma metodologia específica para a detecção de SAFs no território, mas sim para classificações dentro dos limites das agroflorestas identificadas. Isso evidencia uma escassez bibliográfica na literatura no que diz respeito ao desenvolvimento de metodologias para a detecção inicial de SAFs, ou seja, na identificação do sistema de modo abrangente e sistemático no território. Entre os principais desafios mostrados pelos autores estão a dificuldade de coleta de amostras de campo, a similaridade das assinaturas espectrais entre os diferentes tipos de vegetação presentes, a resolução espacial e temporal necessárias, e o grande volume de dados necessários para geração dos modelos [4,9,11].

Ainda assim, já existem esforços buscando indicar quais metodologias poderiam alcançar bons resultados em ambientes complexos, muitas vezes trazidas de outros campos do conhecimento, como técnicas de aprendizado ativo, aprendizado por transferência e aumento de dados [16].

Assim, os estudos analisados indicaram que uma arquitetura fechada de ponta a ponta pode não ser a melhor opção para o mapeamento dessas áreas e, por isso, há a importância do aprendizado ativo, que permite a intervenção humana para refinar os resultados na segmentação e na classificação. Além disso, outra característica dos SAFs é a dificuldade na coleta de dados, por exemplo em áreas como a

amazônica. O aprendizado por transferência poderia auxiliar nesse sentido, uma vez que, por utilizar modelos pré-treinados, consegue reduzir a necessidade de grandes volumes de dados rotulados. Por fim, atrelado ao aprendizado por transferência, está a técnica de aumento de dados, conhecida na área de *machine learning* por gerar novos dados de treinamento com base nos dados existentes para melhorar o desempenho do modelo [16].

4. CONCLUSÕES

- Algoritmos baseados em redes neurais profundas superam aqueles baseados em aprendizado de máquina superficial na identificação de espécies florestais.
- Embora iniciativas de caracterização de SAFs tenham sido bem-sucedidas, a detecção automatizada de produção sob esses sistemas em escala regional permanece inexplorada.
- Os principais desafios indicados pelos autores na aplicação de técnicas de sensoriamento remoto em sistemas agroflorestais são: a complexidade estrutural dos SAFs, a diversidade de espécies, a variabilidade sazonal e a limitação de dados multiespectrais e multitemporais.
- O uso de aprendizado ativo pode ser uma abordagem promissora ao melhoramento de rotulação de amostras em ambientes heterogêneos, como os SAFs.

5. AGRADECIMENTOS

À Embrapa Agricultura Digital e à Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP) pelo financiamento dos projetos 2022/09319-9, 2024/05205-4 e 2024/13150-5; ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), pela bolsa de iniciação científica.

6. REFERÊNCIAS

[1] E. L. Bolfe. Desenvolvimento de uma metodologia para a estimativa de biomassa e de carbono em sistemas agroflorestais por meio de imagens orbitais, 2010. (Doutorado em Geografia) Universidade Estadual de Campinas.

[2] J. L. Vivan. Diversificação e manejo de Sistemas Agroflorestais, III Congresso Brasileiro de Sistemas Agroflorestais, 2000.

[3] E. L. Bolfe, M. Batistella, and M. C. Ferreira. Correlação de variáveis espectrais e estoque de carbono biomassa aérea de sistemas agroflorestais, *Pesquisa Agropecuária Brasileira*, 47 (9), 2012.

[4] A. Begué, D. Arvor, B. Bellon, J. Betbeder, D. Abelleira and R. P. Ferraz, Remote sensing and cropping practices: a review, *Remote Sensing*, 10(1), 99 pp., 2018.

[5] V. L. Engel. Sistemas Agroflorestais: Conceitos e Aplicações, *FEPAP*, Botucatu, 1999.

[6] E. Salati. Possible climatological impacts. In: T. E. DOWNING, S. B. HECHT, H. A. PEARSON; e. GARCIA-DOWNING (eds.), *Development of destruction: the conversion of tropical forest to pasture in Latin América*, Oxford, Westview Press. p. 173-189, 1992.

[7] T. D. A. Sá. Aspectos climáticos associados a sistemas agroflorestais: implicações no planejamento e manejo em regiões tropicais, *Congresso Brasileiro sobre Sistemas Agroflorestais*, 1, 1994.

[8] A. C. Gama-Rodrigues, N. F. Barros, E. F. Gama-Rodrigues, M. S. M. Freitas, P. A. Viana, M. J. Jasmin, R. C. Marcian, and A. G. J. Carneiro. Sistemas agroflorestais: bases científicas para o desenvolvimento sustentável, Universidade Estadual do Norte Fluminense Darcy Ribeiro, Rio de Janeiro, 86 pp., 2006.

[9] N. Guimarães, L. Pádua, P. Marques, N. Silva, E. Peres, and J. J. Sousa. Forestry Remote Sensing from Unmanned Aerial Vehicles: A Review Focusing on the Data, Processing and Potentialities, *Remote Sensing*, 12, 1046 pp., 2020.

[10] B. Thapa, S. Lovell, and J. Wilson. Remote sensing and machine learning applications for aboveground biomass estimation in agroforestry systems: a review. *Agroforest Syst* 97, 2023.

[11] P. Kuchler, M. Simoes, R. Ferraz, and D. Arvor. Monitoring complex integrated crop-livestock systems at regional scale in Brazil: a big earth observation data approach, *Remote Sensing*, 14(7), 2022.

[12] J. Abramowitz, E. Cherrington, R. Griffin, R. Muench, and F. Mensah. Differentiating oil palm plantations from natural forest to improve land cover mapping in Ghana, science direct, remote sensing applications: society and environment, *Elsevier*, 30, 2023.

[13] I. L. Sari, C. J. Weston, G. J. Newnham, and L. Volkova. Developing multi-source indices to discriminate between native tropical forests, *Remote Sensing*, 14, 2023.

[14] K. Miae, L. Junghee, H. Daehyeon, S. Minso, I. Jungho, L. Junghye, J. Q. Lindi, and G. Convolutional Neural Network-Based Land Cover Classification Using 2-D Spectral Reflectance Curve Graphs With Multitemporal Satellite Imagery, *IEEE J*, 11, 2018.

[15] M. J. Vincent, P. Varalakshmi. Agroforestry mapping using multi temporal hybrid CNN+LSTM framework with landsat 8 satellite imagery and google earth engine, *Environ. Res. Commun*, 6, 2024.

[16] B. Chehreh, A. Moutinho, and C. Viegas. Latest Trends on Tree Classification and Segmentation Using UAV Data—A Review of Agroforestry Applications. *Remote Sensing*, 15, 2263, 2023.