

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
ESCOLA DE ENGENHARIA
DEPARTAMENTO DE ENGENHARIA ELÉTRICA

LUCAS RAMALHO GUERRA

**CLASSIFICAÇÃO DE USO DO SOLO PARA AGRICULTURA COM IMAGENS DO
SENTINEL-2 E CNN VGG-16**

Porto Alegre - RS

2024

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
ESCOLA DE ENGENHARIA
DEPARTAMENTO DE ENGENHARIA ELÉTRICA

**CLASSIFICAÇÃO DE USO DO SOLO PARA AGRICULTURA COM IMAGENS DO
SENTINEL-2 E CNN VGG-16**

Projeto de Diplomação apresentado ao Departamento de Engenharia Elétrica da Universidade Federal do Rio Grande do Sul, como parte dos requisitos para Graduação em Engenharia Elétrica.

Orientador: Prof. Dr. Alexandre Balbinot

Porto Alegre-RS

2024

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
ESCOLA DE ENGENHARIA
DEPARTAMENTO DE ENGENHARIA ELÉTRICA

LUCAS RAMALHO GUERRA

**CLASSIFICAÇÃO DE USO DO SOLO PARA AGRICULTURA COM IMAGENS DO
SENTINEL-2 E CNN VGG-16**

Este projeto foi julgado adequado para fazer jus aos créditos da Disciplina de “Projeto de Diplomação”, do Departamento de Engenharia Elétrica e aprovado em sua forma final pelo Orientador e pela Banca Examinadora.

Orientador: _____

Prof. Dr. Alexandre Balbinot

Banca Examinadora:

Prof.^a Dr. Maurício Tosin

Prof.^a Dr. Tiago Weber

Porto Alegre – RS

2024

AGRADECIMENTOS

Agradeço, primeiramente, a UFRGS, pela oportunidade de acesso à educação gratuita, e de qualidade. Ao meu orientador, professor Dr. Alexandre Balbinot, pelo empenho despendido durante este trabalho e disciplinas cursadas ao decorrer da formação. Agradeço também à minha esposa Geovana e aos meus familiares que me deram todo o apoio necessário para finalizar esta jornada de aprendizado.

RESUMO

Este trabalho apresenta uma abordagem detalhada para a classificação de uso do solo em áreas agrícolas, utilizando imagens de satélite Sentinel-2 e um modelo de Rede Neural Convolutiva (CNN) VGG-16 (Arquitetura *Visual Geometry Group* com 16 camadas treináveis). A área de estudo é a região de Luís Eduardo Magalhães, BA, e os dados utilizados incluem um conjunto público de imagens ópticas e de radar, além de dados de campo coletados *in situ*. As imagens foram adquiridas durante o ano agrícola brasileiro de 2017-2018, capturando uma ampla diversidade de coberturas do solo, principalmente focadas em culturas agrícolas.

A preparação dos dados para o modelo de classificação é parte fundamental para obtenção dos resultados obtidos. Esta fase de pré-processamento tem como fator principal a adoção de uma técnica de janela deslizante sobre as imagens dos talhões a serem analisados, estes talhões são constituídos das culturas identificadas na geração do *dataset*, e são delimitados pelas geometrias criadas a partir das fronteiras destas áreas. Cada geometria recebe uma classe (cultivar identificado) que é anotada para cada período estruturado no *dataset*. A janela deslizante sobre as imagens dos talhões gera amostras de imagens menores no formato de entrada do modelo da CNN, que são capturadas sem nenhum tipo de redimensionamento, garantindo as características de textura de cada cultura identificada no solo da região.

O modelo VGG-16, inicialmente pré-treinado no conjunto de dados *ImageNet*, foi adaptado através de *fine-tuning* para melhorar sua adequação às características específicas dos dados de sensoriamento remoto. No cenário com *fine-tuning*, o modelo alcançou *categorical accuracy* de 88% no conjunto de treinamento e 85% no conjunto de teste. Já no cenário sem *fine-tuning*, os valores obtidos foram de 83% e 82%, respectivamente. A aplicação do *fine-tuning* permitiu ao modelo alcançar uma maior *categorical accuracy* na classificação do uso do solo no conjunto de dados analisado, apesar de demonstrar tendência maior ao *overfitting* quando comparado ao desempenho do treinamento da mesma arquitetura de CNN sem os pesos pré-treinados. Este estudo demonstra a eficácia da utilização de CNNs, como a VGG-16, na análise e interpretação de dados de sensoriamento remoto para aplicações agrícolas.

Palavras-chave: Sensoriamento Remoto, Classificação de Uso do Solo, Modelos Inteligentes, Redes Neurais, CNN, Aprendizado de Máquina, *Fine-tuning*.

ABSTRACT

This work presents a detailed approach to land use classification in agricultural areas using Sentinel-2 satellite imagery and a VGG-16 Convolutional Neural Network (CNN) model (Visual Geometry Group architecture with 16 trainable layers). The study area is the region of Luís Eduardo Magalhães, BA, Brazil, and the data used includes a public set of optical and radar images, as well as field data collected in situ. The images were acquired during the Brazilian agricultural year of 2017-2018, capturing a wide diversity of land covers, mainly focused on agricultural crops.

Data preparation for the classification model is a fundamental part of obtaining the results achieved. This pre-processing phase primarily involves adopting a sliding window technique over the images of the plots to be analyzed. These plots consist of the crops identified in the dataset generation and are delineated by geometries created from the boundaries of these areas. Each geometry is assigned a class (identified crop) that is annotated for each period structured in the dataset. The sliding window over the plot images generates smaller image samples in the input format of the CNN model, captured without any resizing, thereby preserving the texture characteristics of each crop identified in the region's soil.

The VGG-16 model, initially pre-trained on the ImageNet dataset, was adapted through fine-tuning to improve its suitability to the specific characteristics of remote sensing data. In the scenario with fine-tuning, the model achieved a categorical accuracy of 88% on the training set and 85% on the test set. In the scenario without fine-tuning, the values obtained were 83% and 82%, respectively. The application of fine-tuning allowed the model to achieve higher categorical accuracy in land use classification in the analyzed dataset, despite showing a greater tendency towards overfitting when compared to the performance of training the same CNN architecture without the pre-trained weights. This study demonstrates the effectiveness of using CNNs, such as VGG-16, in the analysis and interpretation of remote sensing data for agricultural applications.

Keywords: Remote Sensing, Land Use Classification, Intelligent Models, Neural Networks, CNN, Machine Learning, Fine-tuning.

SUMÁRIO

1	INTRODUÇÃO	7
1.1	Motivação.....	8
1.2	Apresentação do Problema.....	9
2	REVISÃO BIBLIOGRÁFICA.....	10
2.1	Princípios sobre Sensoriamento Remoto	10
2.2	Trabalhos Relacionados	13
2.2.1	Pesquisa bibliométrica	13
2.2.2	LEM benchmark.....	20
3	METODOLOGIA PROPOSTA.....	24
3.1	Descrição da Base de Dados	25
3.2	Preparação da Base para o Algoritmo de Classificação.....	29
3.3	Classificação das imagens com a CNN VGG-16.....	43
4	RESULTADOS E DISCUSSÕES	48
4.1	Treinamento sem pesos do <i>ImageNet Dataset</i>	49
4.1.1	Comparação dos resultados obtidos com CNN e <i>Random Forest</i>	52
5	CONCLUSÕES	54
6	PROPOSTA PARA TRABALHOS FUTUROS.....	56
7	REFERÊNCIAS	58

1 INTRODUÇÃO

Nos últimos anos, o sensoriamento remoto tem se destacado como uma área essencial para a obtenção de informações detalhadas sobre o uso e cobertura do solo. A classificação de uso do solo, por meio de imagens de satélite, permite a identificação e monitoramento de diferentes tipos da cobertura terrestre, como florestas, pastagens, cultivos e áreas urbanas. As informações obtidas a partir da aplicação das soluções de sensoriamento remoto são cruciais para a tomada de decisões em diversos setores, incluindo gestão ambiental, planejamento urbano, agricultura e pesquisa científica (Calicioglu *et al.*, 2019).

Estas soluções relacionam tecnologias que utilizam satélites, aeronaves e veículos aéreos não tripulados (VANTs), fornecendo uma visão abrangente dos ambientes agrícolas e naturais (Silva *et al.*, 2020). A integração de dados ópticos e de radar de abertura sintética (SAR) de alta resolução espacial e temporal, como os fornecidos pelos satélites Sentinel-1 e Sentinel-2 do projeto Copernicus, tem sido fundamental para a implementação de soluções de detecção e mapeamento de tipos de culturas, uma vez que proporciona uma maneira eficiente e não destrutiva de coletar dados sobre grandes áreas geográficas, permitindo uma análise contínua e detalhada dos ecossistemas (Ji *et al.*, 2018; Chaves *et al.*, 2023).

Entre as técnicas de processamento de dados gerados com o uso destes sensores, a aplicação dos algoritmos de aprendizado de máquina têm permitido avanços significativos na análise de múltiplas fontes de dados (Talukdar *et al.*, 2020). Modelos de aprendizado profundo, como *convolutional neural network* (CNN) e *recurrent neural network* (RNN), têm demonstrado um desempenho crescente na extração de características temporais e espaciais de imagens de satélite (Niharika *et al.*, 2023). Por exemplo, a previsão do rendimento de colheitas, utilizando características do solo e do ambiente, pode ser realizada através de modelos adaptados de RNN (Kosaraju *et al.*, 2023).

Estudos comparativos mostraram que métodos baseados em redes neurais apresentam superioridade significativa em relação aos métodos estatísticos tradicionais na classificação de dados de sensoriamento remoto de múltiplas fontes (HEYDARI *et al.*, 2019) como demonstrado também por Benediktsson *et al.*, 1990. Isto se torna mais significativo quando consideramos os avanços no poder computacional conquistado nas últimas décadas aliado à capacidade escalável de processamento paralelizado (Chembian *et al.*, 2022). Pode-se observar a aplicação de redes neurais artificiais (RNA) para mapeamento do uso e ocupação do solo no Bioma Cerrado, destacando-se em comparação com classificadores tradicionais como o Maxima Verossimilhança (Silva *et al.*, 2020).

1.1 MOTIVAÇÃO

A agricultura é uma das atividades mais importantes da humanidade, responsável pela produção de alimentos para a população mundial. No entanto, a demanda por alimentos está aumentando a cada ano, tornando necessário o desenvolvimento de tecnologias para melhorar a eficiência e a produtividade na produção agrícola (Calicioglu *et al.*, 2019). Um dos principais desafios é a gestão dos recursos naturais, como a terra, a água e os nutrientes, para garantir a sustentabilidade da produção.

Neste contexto, o Brasil se destaca como um importante produtor e exportador global de commodities, incluindo soja, algodão, café e milho, sendo alvo das soluções que otimizam a gestão de recursos e a produção agrícola.

O sensoriamento é uma área que estuda tecnologias habilitadoras de ferramentas poderosas para monitorar e gerenciar estes recursos de maneira eficiente (Silva *et al.*, 2020). Com a integração de dados de alta resolução de satélites como Sentinel-1 e Sentinel-2, é possível obter informações detalhadas e atualizadas sobre o uso do solo, o que é crucial para a agricultura de precisão e para políticas de preservação ambiental (ESA, 2015; Immitzer *et al.*, 2016).

Soluções relacionadas ao monitoramento de áreas são importantes também do ponto de vista ambiental, quando considera-se a expansão das áreas agrícolas observadas nas últimas décadas que, em alguns casos, ocorre sobre áreas de vegetação natural, levando ao desmatamento ilegal (Chaves *et al.*, 2023). Identificar a variabilidade da cobertura vegetal em regiões tropicais contribui para a gestão sustentável dos recursos naturais (Ji *et al.*, 2018; Sanches *et al.*, 2018).

O MATOPIBA, uma área no bioma Cerrado que abrange partes dos estados do Maranhão, Tocantins, Piauí e Bahia, está na linha de frente da expansão agrícola, contribuindo com 25% da produção de soja do bioma sendo uma região produtora significativa (Soterroni *et al.*, 2019). Zalles *et al.*, 2021 mostra que a expansão das monoculturas nesta região tem impactado negativamente as áreas de vegetação natural e ameaçado a biodiversidade local. Portanto, informações precisas sobre uso e cobertura da terra nessa região agrícola são essenciais para apoiar a tomada de decisões em relação à dinâmica da agricultura, desmatamento e segurança alimentar.

1.2 APRESENTAÇÃO DO PROBLEMA

A classificação de uso do solo é uma das principais aplicações do sensoriamento remoto, pois permite a identificação dos diferentes tipos de cultivos e a avaliação de sua distribuição em uma determinada região. Essa informação é essencial para a tomada de decisões estratégicas no agronegócio, como o planejamento de recursos, a gestão de estoques e a definição de políticas ambientais (Deng *et al.*, 2019).

No entanto, a classificação de uso do solo é uma tarefa desafiadora, especialmente em regiões tropicais, onde a diversidade de cultivos e a complexidade dos ecossistemas são maiores. A disponibilidade de dados de sensoriamento remoto de alta qualidade é fundamental para uma classificação adequada, mas poucos dados públicos estão disponíveis para a comunidade de pesquisa.

Estudos anteriores sobre mudanças de LULC (*Land Use and Land Cover*) no Cerrado, implicam em uma análise sob homogeneidade espacial, relatam taxas amplamente variáveis de conversão de terras, utilizam categorias de LULC ambíguas e geralmente não tentam validar os resultados. Estudos de LULC no Brasil para grandes áreas e períodos são baseados em técnicas tradicionais, como Máxima Verossimilhança (Silva *et al.*, 2020).

Para contribuir com a solução deste problema, foi criado o *benchmark database* “LEM Benchmark Database For Tropical Agricultural Remote Sensing Application” (Sanches *et al.*, 2018), que é um banco de dados público disponível para a comunidade de pesquisa. O banco de dados inclui informações sobre os limites de campos de cultivo, dados de referência de uso do solo e imagens pré-processadas de sensores ativos e passivos, correspondentes à região do município de Luís Eduardo Magalhães (LEM), no Brasil.

Portanto, considerando-se as colocações anteriores, este trabalho tem por objetivo principal implementar um algoritmo de classificação de uso do solo a partir de uma Rede Neural Convolucional, utilizando o banco de dados “*LEM Benchmark Database For Tropical Agricultural Remote Sensing Application*” (Sanches *et al.*, 2018), para a comparação dos resultados obtidos na publicação deste *dataset*, que foram obtidos a partir de um algoritmo *Random Forest*.

2 REVISÃO BIBLIOGRÁFICA

2.1 PRINCÍPIOS SOBRE SENSORIAMENTO REMOTO

O sensoriamento remoto é uma área onde são estudadas técnicas que permitem a coleta de dados sobre objetos ou fenômenos sem a necessidade de contato físico direto (Vadrevu, K. P., 2013). Através do uso de sensores instalados em plataformas aéreas ou espaciais, é possível obter informações precisas e atualizadas sobre a condição dos ecossistemas, ajudando a orientar as políticas públicas, ações de conservação e produtividade no setor do agronegócio.

Uma das principais aplicações do sensoriamento remoto está na monitoração da vegetação. Através do uso de imagens multiespectrais, torna-se possível identificar diferentes tipos de vegetação e avaliar características biofísicas que podem ser identificadas por suas assinaturas espectrais (Thenkabail *et al.*, 2012). Essa tecnologia tem sido amplamente utilizada em diversos setores, como agricultura, meio ambiente, recursos hídricos, entre outros, possibilitando a identificação de diferentes tipos de uso do solo, como áreas urbanas, agrícolas e florestais (Lu & Weng, 2007). Essas informações podem ser usadas para avaliar a expansão urbana, a desertificação e a degradação do solo, além de fornecer informações importantes para a gestão dos recursos de pastagem e produtividade agrícola, fornecendo informações precisas e atualizadas sobre a saúde das plantações, o uso e cobertura do solo, a irrigação e outros fatores relevantes. Além disso, essa tecnologia pode ajudar a monitorar áreas propícias à infestação de pragas e doenças.

Aprofundando o tema sobre a atividade no setor agrícola, segundo Sishodia, Ray e Singh (2020), as tecnologias de Agricultura de Precisão (PA) baseadas em sensoriamento remoto, como a tecnologia de aplicação de taxa de fertilizante variável no *Green Seeker* e *Crop Circle*, já foram incorporadas na agricultura comercial. Além disso, o uso de VANTs (veículos aéreos não tripulados) tem aumentado devido à sua relação custo-benefício e flexibilidade na obtenção de imagens de alta resolução necessárias para as aplicações de agricultura de precisão.

No meio ambiente, o sensoriamento remoto tem sido utilizado para monitorar principalmente recursos naturais. Por exemplo, essa tecnologia pode ajudar a identificar áreas de interesse para conservação, a monitorar a degradação do solo e a desertificação, bem como avaliar a qualidade do ar e do solo.

De acordo com Silva *et al.* (2020), o mapeamento do uso e cobertura do solo (LULC) no Bioma Cerrado brasileiro pode ser efetivamente realizado utilizando imagens do satélite Sentinel-2 em conjunto com redes neurais artificiais. Dentre as classes de uso e ocupação examinadas, consideraram-se características relacionadas à gestão de recursos naturais, corpos d'água, cerrado, floresta e formação de campo, bem como 4 classes antrópicas, pastagem, áreas urbanas, silvicultura e cultura sazonal. Este avanço metodológico para identificação da variabilidade no meio ambiente é significativo para o planejamento e a tomada de decisões relacionadas à conservação e ao uso sustentável dos ecossistemas do Cerrado.

Conforme Wang, *et al.*, (2020) as áreas protegidas têm se tornado cada vez mais importantes como indicadores do status e funções do ecossistema. Com os impactos intensificados das mudanças climáticas e ambientais, o desenvolvimento de plataformas de sensoriamento remoto e a melhoria na ciência e tecnologia fornecem suporte crucial para o monitoramento e gerenciamento de áreas protegidas. Os autores revisaram pesquisas que usam tecnologias de sensoriamento remoto de última geração e trazem discussão sobre os desafios das aplicações relacionadas, cobrindo monitoramento, gerenciamento e governança de áreas protegidas, bem como resumem os destaques dos artigos publicados sobre o tema.

Pode-se observar também que análises relacionadas à qualidade do ar podem ser absorvidas pela área de sensoriamento remoto. O estudo “*Global monitoring of air pollution over land from the Earth Observing System-Terra Moderate Resolution Imaging Spectroradiometer (MODIS)*” de Chu *et al.* (2003) é um exemplo notável da aplicação do sensoriamento remoto no monitoramento da poluição do ar. Neste estudo, os autores utilizaram o MODIS (*Moderate Resolution Imaging Spectroradiometer*), um instrumento a bordo do satélite Terra da NASA, para monitorar a poluição do ar em escala global, regional e local. O MODIS coleta dados em 36 bandas espectrais, que são usadas para criar uma variedade de produtos derivados, incluindo informações sobre a cobertura de nuvens, temperatura da superfície do mar, qualidade do ar, efeitos das mudanças climáticas e muito mais. Os autores realizaram três estudos de caso em diferentes locais, incluindo o norte da Itália, Los Angeles e Pequim. Eles aplicaram profundidades ópticas de aerossol derivadas do MODIS para recuperar dados sobre aerossóis atmosféricos. Este estudo é apenas um exemplo de como o sensoriamento remoto pode fornecer informações valiosas e precisas que são cruciais para entender e mitigar os impactos da poluição.

Outra importante aplicação do sensoriamento remoto está no monitoramento da qualidade da água. Através do uso de sensores ativos, é possível avaliar a claridade, a temperatura e a salinidade da água, além de detectar a presença de poluentes. De acordo com

Yang *et al.* (2022) a utilização de sensores hiperespectrais embarcados em veículos aéreos, pode auxiliar a análise sobre variáveis relacionadas à recuperação da qualidade da água, os autores discutem principalmente o progresso da pesquisa em termos de dados que podem ser capturados com sensoriamento remoto, incluindo matéria suspensa total (TSM), clorofila-a (Chl $-a$), matéria orgânica dissolvida colorida (CDOM), demanda química de oxigênio (COD), nitrogênio total (TN) e fósforo total (TP). Eles também discutem os desafios significativos para a correção atmosférica, a resolução dos dados de sensoriamento remoto e a aplicabilidade do modelo de caracterização das variáveis nos domínios da complexidade espacial e temporal.

Outra aplicação do sensoriamento remoto é no monitoramento das mudanças climáticas. Com o uso de sensores instalados em satélites, é possível avaliar a temperatura da superfície terrestre, a cobertura de gelo e a altura da neve, além de detectar a presença de gases de efeito estufa. O estudo “*Use of remote sensing in climate change adaptation*” Climate-ADAPT (2018) destaca a importância do sensoriamento remoto na adaptação às mudanças climáticas. De acordo com o autor, o sensoriamento remoto tem sido usado para melhorar a compreensão do sistema climático e suas mudanças, pois permite monitorar a superfície da Terra, o oceano e a atmosfera em várias escalas espaciais e temporais, permitindo observações do sistema climático, bem como investigar processos relacionados ao clima ou fenômenos de longo e curto prazo, como por exemplo, desmatamento ou tendências do El Niño. Essas informações são fundamentais para a compreensão dos processos climáticos e para a previsão dos seus impactos.

O sensoriamento remoto tem se mostrado uma ferramenta valiosa na agricultura e no meio ambiente, fornecendo informações precisas e atualizadas sobre a superfície terrestre. No entanto, existem desafios e limitações associadas ao seu uso, como por exemplo, a disponibilidade de dados de alta qualidade com resolução espacial e temporal adequadas. Além disso, existe a necessidade de conhecimentos especializados em processamento de imagens e análise de dados, assim como a necessidade de integração de dados de diferentes fontes e escalas. Portanto, é possível afirmar que o sensoriamento remoto é uma tecnologia poderosa que tem sido amplamente utilizada no monitoramento ambiental. Através do uso de sensores instalados em plataformas aéreas ou espaciais, é possível obter informações precisas e atualizadas sobre a condição dos ecossistemas, ajudando a orientar as políticas públicas e as ações de conservação.

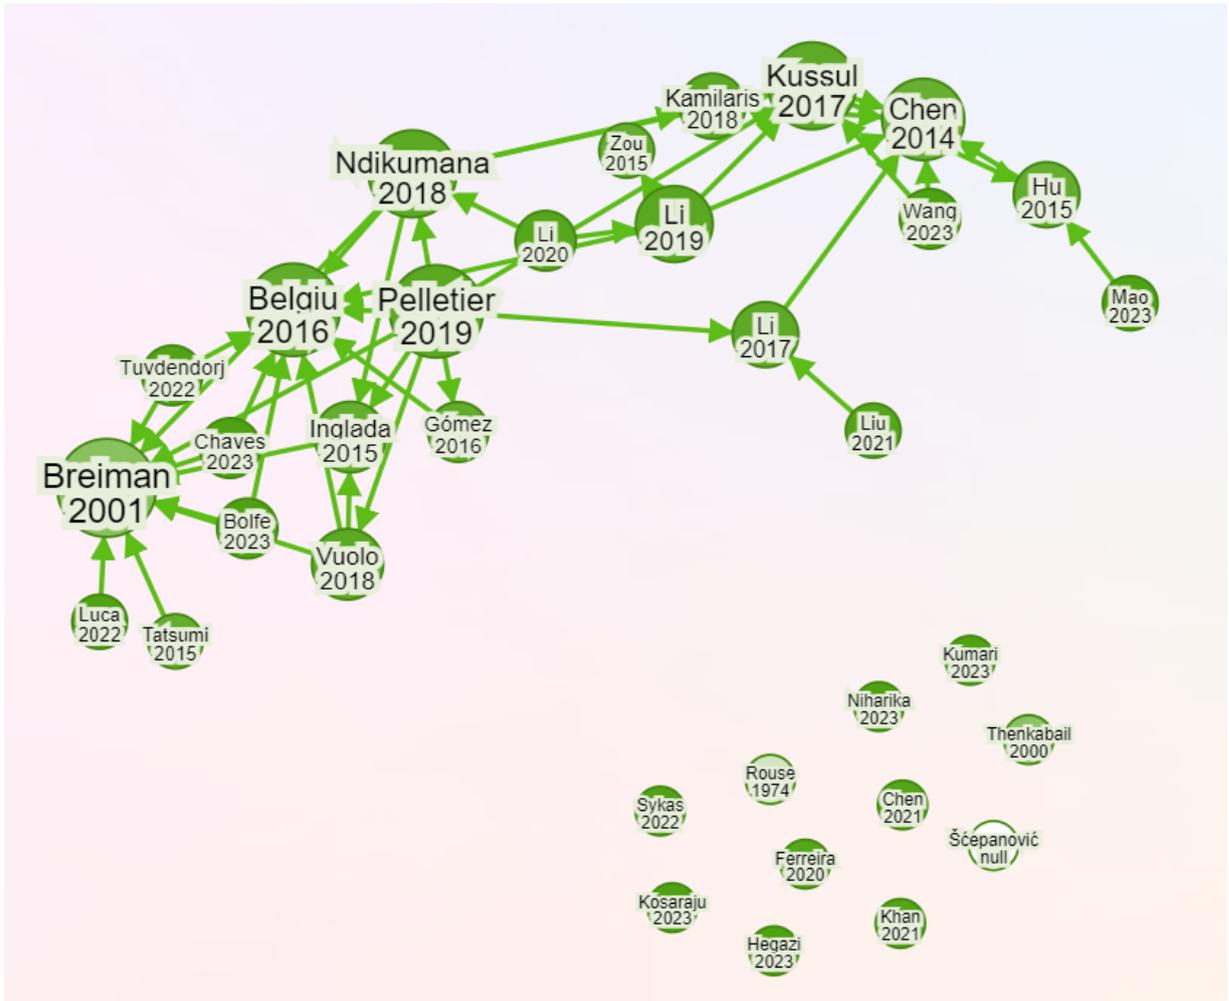
2.2 TRABALHOS RELACIONADOS

O problema apresentado a ser explorado, sobre classificação de uso do solo, é uma atividade fundamental que visa identificar diferentes tipos de cobertura terrestre a partir de imagens obtidas por satélites ou aeronaves. Diversas técnicas de classificação têm sido propostas e aplicadas ao longo dos anos, incluindo redes neurais artificiais, árvores de decisão, máquinas de vetores de suporte e algoritmos de agrupamento (Talukdar *et al.*, 2020; Khan *et al.*, 2021; Mao *et al.*, 2023). Neste capítulo, serão discutidos alguns trabalhos relacionados à classificação de uso do solo utilizando diferentes abordagens e tecnologias, considerando-se uma pesquisa sobre os trabalhos relevantes na área.

2.2.1 Pesquisa bibliométrica

Para a realização da pesquisa bibliométrica, deste trabalho, foi utilizado a ferramenta *Research Rabbit* (2024). As palavras-chave utilizadas foram: "*Remote Sensing*", "*CNN*", "*RNN*", "*Random Forest*", "*Deep Learning*", "*LULC*", "*Land Use*", "*Land Cover*", "*Sentinel-1*", "*Sentinel-2*", entre outras. A ferramenta, então, gerou uma lista de artigos semente relacionados a esses termos. A partir desses artigos semente, o *Research Rabbit* foi capaz de mapear e sugerir outros artigos relevantes para o tópico de interesse. Pode-se observar na Figura 1, que o trabalho de Breiman, 2001, recebe destaque no diagrama, sendo um trabalho relevante relacionado a *Random Forest* que é uma das principais técnicas utilizadas na área de sensoriamento remoto.

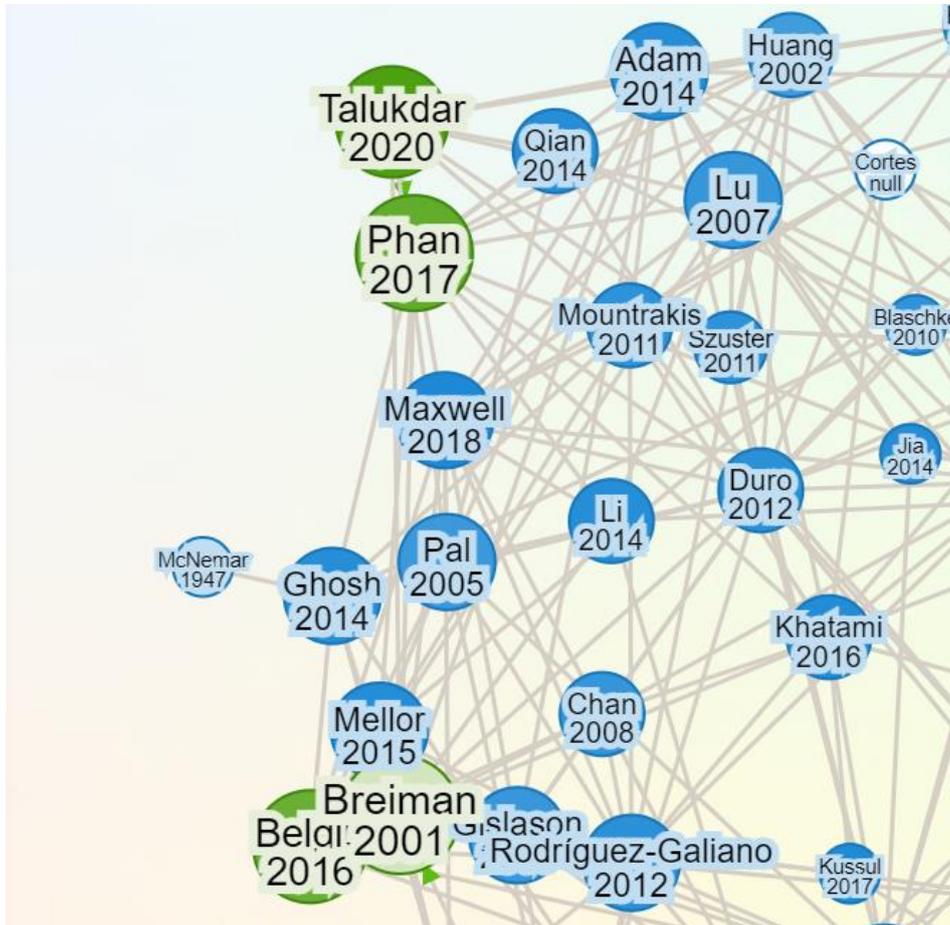
Figura 1- Relação entre os trabalhos capturados como referência para este estudo. A dimensão dos nós está relacionada à relevância em citações.



Fonte: Adaptado de Research Rabbit (2024).

O trabalho de Leo Breiman (2001) propõe o uso de florestas aleatórias como uma abordagem robusta para a classificação e regressão. Esta técnica combina múltiplas árvores de decisão, onde cada árvore depende dos valores de um vetor aleatório, amostrado independentemente para todas as árvores. O objetivo principal do estudo é avaliar a eficácia das florestas aleatórias em comparação com outros métodos, como *Adaboost*, particularmente em termos de *accuracy*, robustez ao ruído e capacidade de generalização. Alguns trabalhos relacionados buscam demonstrar as diferenças nos resultados obtidos com uso desta metodologia frente a outras abordagens, como mostra a Figura 2.

Figura 2 - Trabalhos relacionados ao tema *Random Forest* e Sensoriamento Remoto encontrados a partir do trabalho de Breiman, (2001).



Fonte: Adaptado de Research Rabbit (2024).

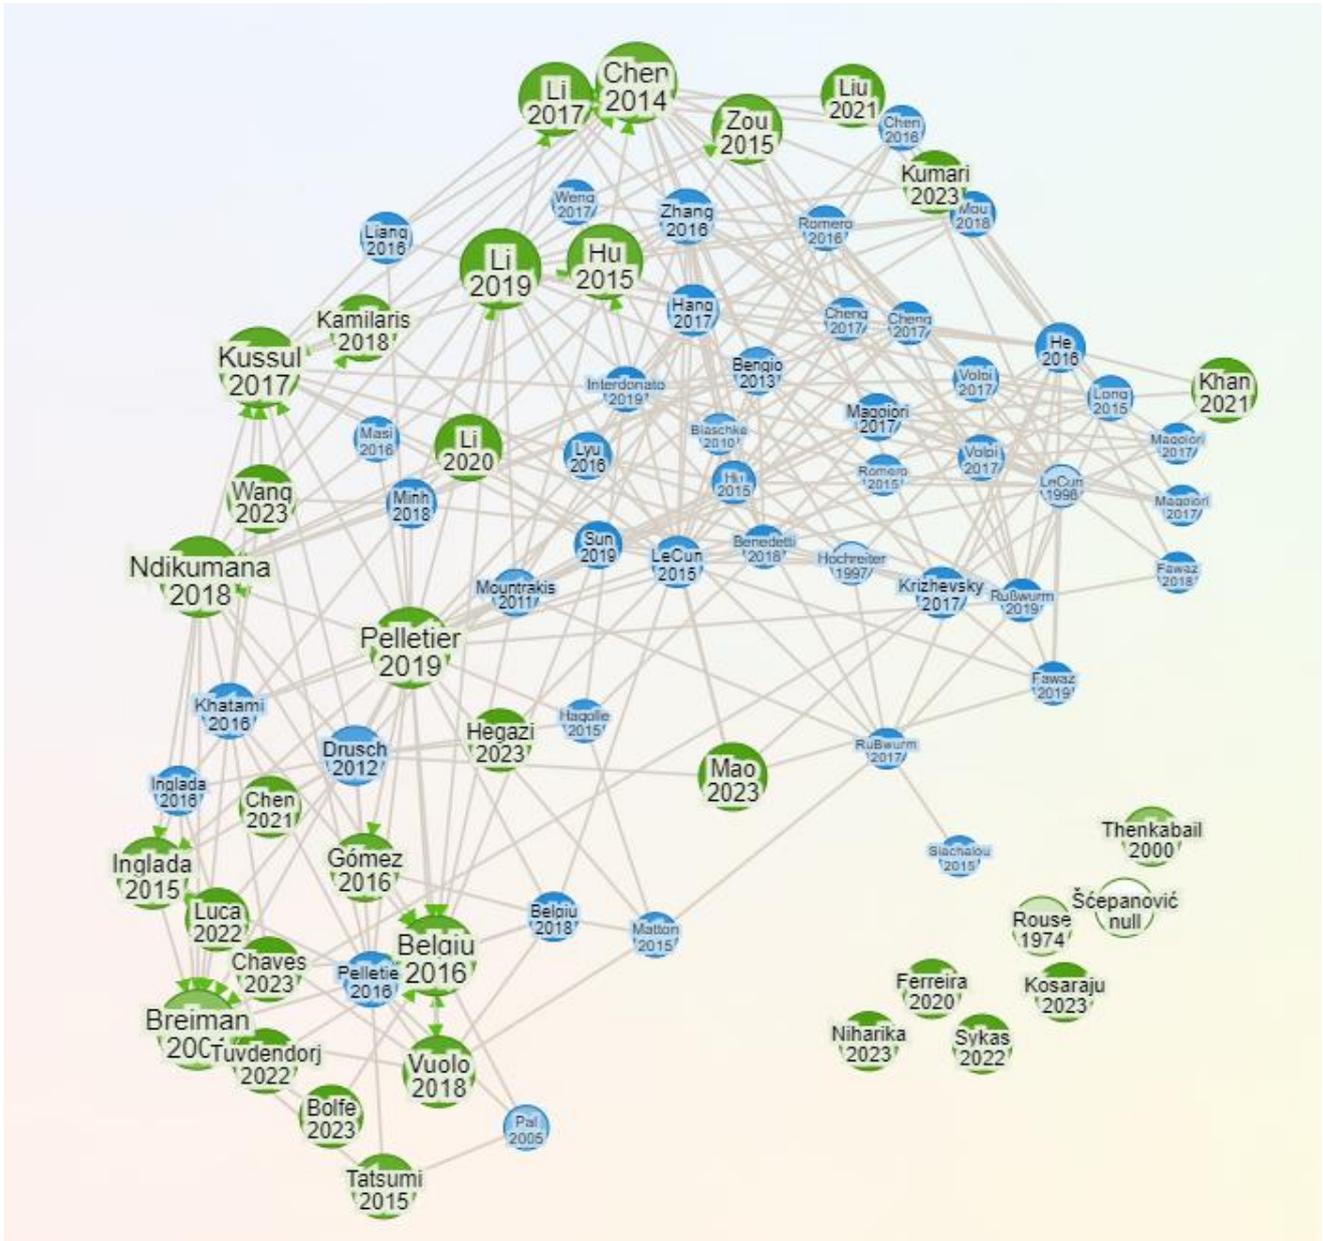
Explorando os trabalhos relacionados ao de Breiman, um estudo realizado por Phan e Kappas (2017) apresentou três classificadores não paramétricos, *Random Forest* (RF), *k-Nearest Neighbor* (kNN) e *Support Vector Machine* (SVM). Estes modelos foram examinados e comparados em relação ao seu desempenho na classificação de cobertura do solo usando dados de imagens do Sentinel-2. Foi analisada uma área de $30 \times 30 \text{ km}^2$ dentro do Delta do Rio Vermelho no Vietnã, com seis tipos de cobertura do solo, utilizando 14 tamanhos de amostra de treinamento diferentes, variando de 50 a mais de 1250 pixels/classe. Todos os resultados de classificação mostraram uma alta *overall accuracy* (OA), variando de 90% a 95%. Entre os três classificadores e 14 subconjuntos de dados, a SVM produziu a maior OA com a menor sensibilidade aos tamanhos das amostras de treinamento, seguido consecutivamente por RF e kNN. Em relação ao tamanho da amostra, todos os três classificadores mostraram uma OA similar (acima de 93,85%) quando o tamanho da amostra

de treinamento era grande o suficiente, ou seja, maior que 750 pixels/classe ou representando uma área de aproximadamente 0,25% da área total do estudo. O classificador SVM apresentou em média a maior OA com a menor sensibilidade ao tamanho da amostra de treinamento, seguido pelos classificadores RF e kNN. A diferença na entre kNN e RF foi grande quando o tamanho da amostra de treinamento aumentou.

Pode-se observar ainda outras análises comparativas, como a de Talukdar *et al.* (2020), que examinou *Random Forest* (RF), *Support Vector Machine* (SVM), *Artificial Neural Network* (ANN), *Fuzzy ARTMAP*, *Spectral Angle Mapper* (SAM) e *Mahalanobis Distance* (MD), na classificação de uso e cobertura do solo (LULC). O estudo foi motivado pelo rápido crescimento populacional e desenvolvimento econômico e industrial, especialmente em países em desenvolvimento, que aumentaram a taxa de mudança de LULC. A validação cruzada mostrou que o algoritmo RF tem o maior nível de *accuracy* em comparação com os outros classificadores adotados. O autor destaca que é necessário testar ainda mais o algoritmo RF em diferentes condições morfoclimáticas, destaca o autor.

Através do uso de palavras-chave específicas como "*Remote Sensing*", "*CNN*", "*RNN*", "*Random Forest*", "*Deep Learning*", "*LULC*", "*Land Use*", "*Land Cover*", "*Sentinel-1*", "*Sentinel-2*", entre outras, e da exploração de redes de citações e coautoria, foi possível realizar uma revisão de literatura abrangente e direcionada sobre o tema geral de sensoriamento remoto e modelos inteligentes para classificação de uso do solo, como indica a Figura 3, que mostra os trabalho de Pelletier (2019) e de Ndikumana (2018) em destaque. Estes trabalhos abordam a classificação de imagens de satélite por meio de modelos de Redes Neurais Convolucionais (CNN) e de Redes Neurais Recorrentes (RNN), métodos amplamente utilizados na área.

Figura 3 - Relação entre os trabalhos capturados (verde) e relacionados (azul) sugeridos pela ferramenta. A dimensão dos nós está relacionada à relevância em citações.



Fonte: Adaptado de Research Rabbit (2024).

O trabalho de Pelletier (2019), propõe o uso de Redes Neurais Convolucionais Temporais (TempCNNs) para a classificação de séries temporais de imagens de satélite. Utilizando dados do satélite Formosat-2. Os autores demonstraram que as TempCNNs superam métodos tradicionais como *Random Forest* (RF) e Redes Neurais Recorrentes (RNNs) em termos de *overall accuracy* na classificação. A arquitetura TempCNN foi avaliada em relação a parâmetros como regularização e tamanho do lote, mostrando resultados

superiores na extração de características temporais e espaciais das imagens. O estudo concluiu que as TempCNNs são adequadas para a classificação de séries temporais de imagens de satélite, oferecendo qualidade superior nos mapas de cobertura do solo.

Ainda explorando o aspecto temporal, o trabalho de Ndikumana (2018), investiga o uso de Redes Neurais Recorrentes Profundas para a classificação de cobertura agrícola utilizando dados multitemporais de radar SAR do Sentinel-1 na região de Camargue, França. A pesquisa comparou a performance de classificadores baseados em RNNs com métodos tradicionais como *K-nearest neighbors* (KNN), *Random Forest* (RF) e *Support Vector Machine* (SVM). Os resultados mostraram que os classificadores baseados em RNNs, especialmente aqueles utilizando LSTM (*Long Short-Term Memory*) e GRU (*Gated Recurrent Unit*), superaram significativamente os métodos tradicionais, alcançando na métrica de *accuracy* classificação superior a 96% para a classe de arroz, a cultura dominante na região. O estudo destaca o potencial das técnicas baseadas em RNNs para melhorar a análise de séries temporais de sensoriamento remoto, especialmente em áreas agrícolas complexas.

A partir destes trabalhos, encontram-se várias soluções que mesclam modelos CNN e RNN para soluções de sensoriamento remoto. Mao, *et al.*, (2023) exploram o potencial de integrar diferentes fontes de dados, construindo um algoritmo Dual-1DCNN baseado no modelo CNN. Além disso, um método de treinamento incremental foi usado para treinar a rede em cada data de aquisição de dados e obter a melhor data de detecção para cada tipo de cultura na estação inicial. Os autores utilizaram um estudo de caso para a cidade de Hengshui na China, que foi conduzido usando séries temporais do Sentinel-1A (S1A) e Sentinel-2 (S2) obtidas em 2019. Como comparação, os autores utilizaram os seguintes métodos: *support vector machine* (SVM), *Random Forest* (RF) e Mono-1DCNN. Os resultados demonstraram que o Dual-1DCNN alcançou *overall accuracy* acima de 85% com menos iterações.

Hegazi *et al.* (2023), propõem uma abordagem para prever a umidade do solo em áreas cobertas por vegetação a partir de imagens do Sentinel-2, baseada em uma rede neural convolucional (CNN). A arquitetura da CNN, composta por seis camadas convolucionais, uma camada de pooling e duas camadas totalmente conectadas. Três critérios bem conhecidos, incluindo o coeficiente de determinação (R^2), o *Mean Absolut Error* (MAE) e o *Root Mean Squared Error* (RMSE), foram utilizados para medir a qualidade do algoritmo proposto. Os autores descobriram que as bandas *Red Edge 3*, NIR (*Near Infrared*) e SWIR 1 (*Shortwave Infrared 1*) do Sentinel-2 são as mais adequadas para recuperar a umidade do solo em áreas cobertas por vegetação.

Kukreja *et al.* (2023), propõem um método para categorizar a intensidade da doença

do trigo em seis estágios, combinando redes neurais recorrentes (RNN) e redes neurais convolucionais (CNN). O objetivo foi criar um modelo confiável e compreensível que apoie as decisões de gerenciamento de doenças e aumente a produção de culturas. Para capturar relações espaciais e temporais no desenvolvimento da doença, o modelo híbrido proposto aproveita os pontos fortes das CNNs e RNNs. Enquanto o componente RNN detecta padrões sequenciais, o componente CNN extrai características da imagem. Diversas métricas de desempenho foram usadas para avaliar o modelo, como por exemplo, precisão, *accuracy*, revocação e *F1-score*. A métrica de *overall accuracy* do modelo no conjunto de testes foi determinada como 0.9225, o que significa que foi bem-sucedido em categorizar as fotos da doença do trigo em todas as intensidades. Um estudo comparativo mostrou que o modelo híbrido proposto é superior, os resultados superaram os modelos atuais, demonstrando seu potencial para aplicação útil na categorização da doença do trigo.

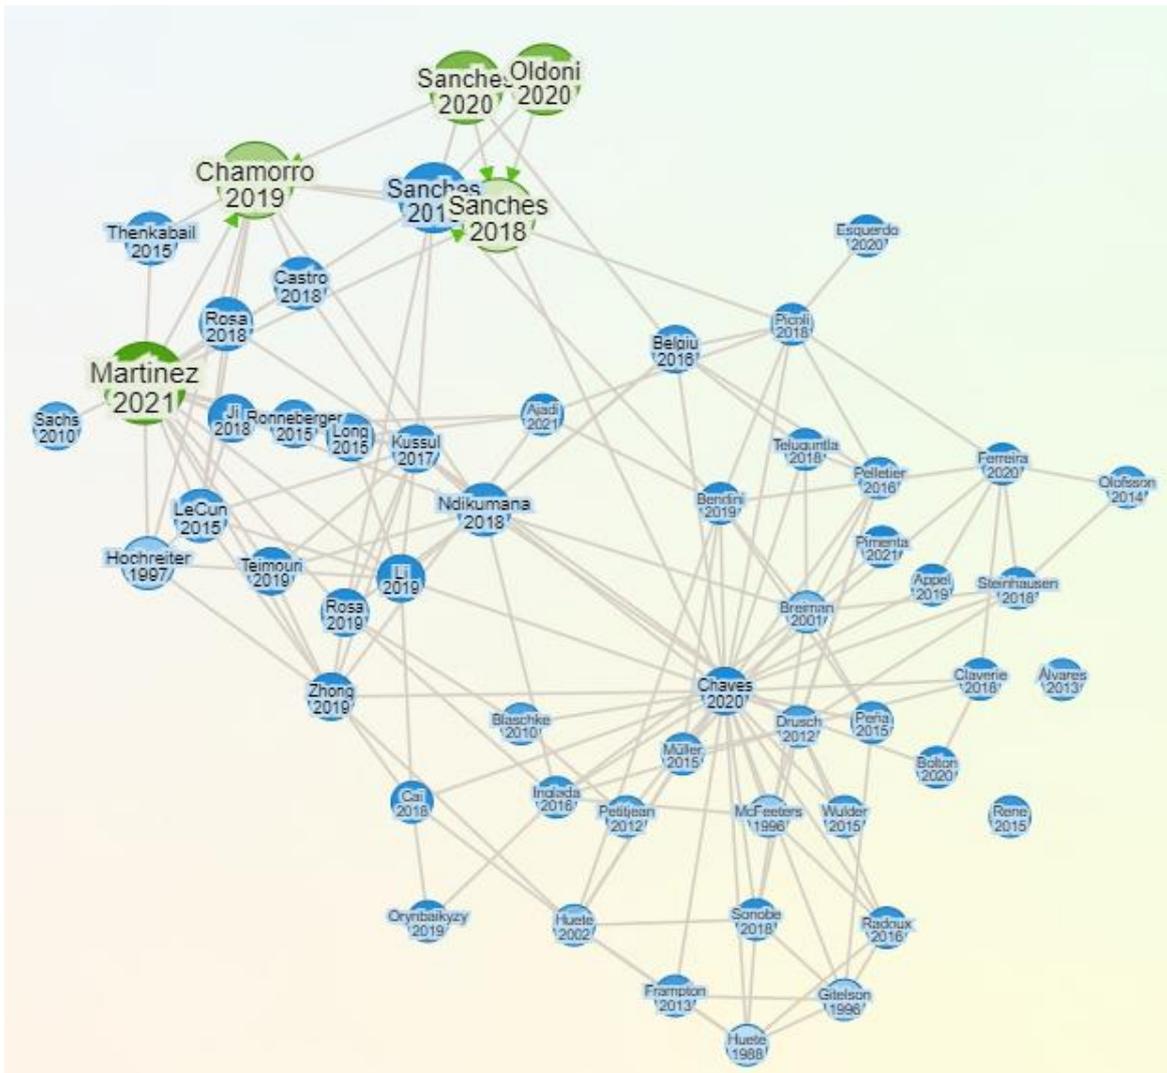
Fan *et al.* (2021), introduzem uma nova rede neural recorrente baseada em gráficos para a previsão de rendimento de culturas, para incorporar tanto o conhecimento geográfico quanto o temporal no modelo e aumentar ainda mais o poder preditivo. O método é treinado, validado e testado em mais de 2000 condados de 41 estados no continente dos EUA, cobrindo os anos de 1981 a 2019. Até onde se sabe, este é o primeiro método de aprendizado de máquina que incorpora conhecimento geográfico na previsão de rendimento de culturas e prevê rendimentos de culturas em nível de condado em todo o país. Os experimentos mostram que o método proposto supera consistentemente os métodos de estado da arte existentes em várias métricas, validando a eficácia das informações geoespaciais e temporais.

Alguns trabalhos são apresentados como soluções híbridas, buscando alinhar o melhor de cada técnica. Por exemplo, o trabalho de Khan *et al.* (2021), propôs um modelo de aprendizado profundo que combina os benefícios de dois modelos, DenseNet e U-Net. Isso é realizado para se obter uma classificação pixel a pixel da cobertura do solo. Segundo o autor o caminho de contração do U-Net é substituído pelo DenseNet para extrair características de múltiplas escalas, enquanto as conexões de longo alcance do U-Net concatenam-se em preservar características de baixo nível. A partir dos resultados experimentais, demonstrou-se que a rede híbrida proposta exibe um desempenho relevante e supera outros modelos existentes por uma margem considerável.

A partir da pesquisa bibliométrica, obtiveram-se resultados também sobre os trabalhos relevantes direcionados ao tema específico sobre a utilização da base de dados explorada neste trabalho, LEM Benchmark. Estes trabalhos apresentam técnicas de sensoriamento remoto já empregadas no problema e serão discutidos na Seção 2.2.2. O diagrama com o

relacionamento das citações pode ser visto na Figura 4.

Figura 4 - Relacionamento entre os trabalhos referentes ao LEM Benchmark.



Fonte: Adaptado de Research Rabbit (2024).

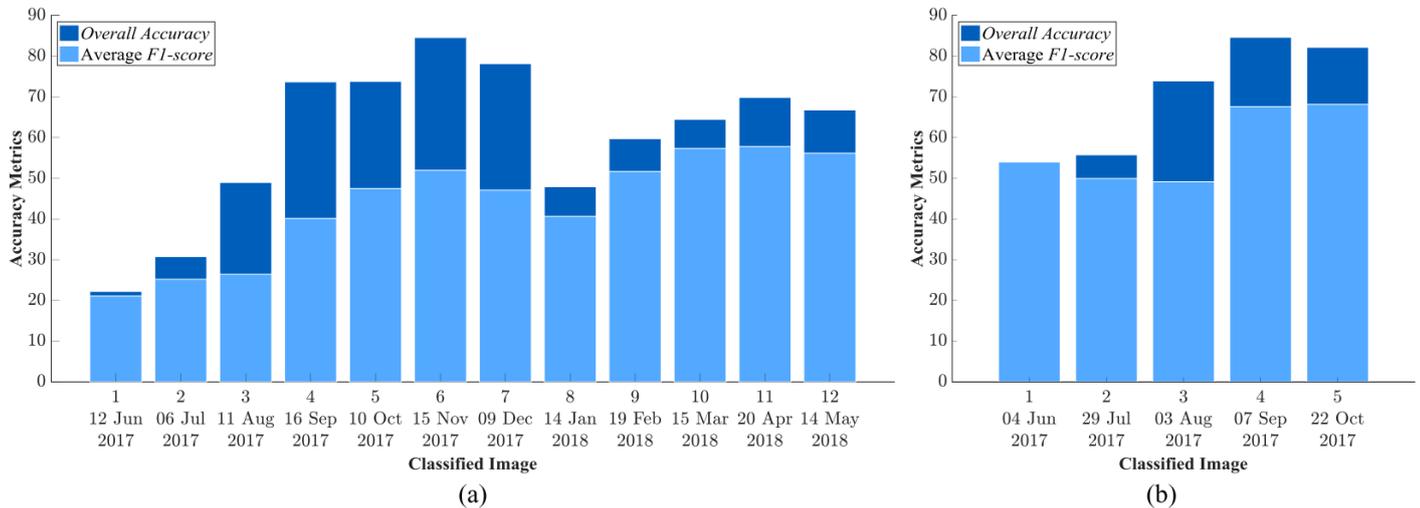
2.2.2 LEM benchmark

A base de dados LEM (Luís Eduardo Magalhães) de Sanches *et al.* (2018), foi usada para avaliar o desempenho de diferentes arquiteturas de redes neurais recorrentes para o reconhecimento de culturas. A base contém um conjunto de imagens de satélite multitemporais pré-processadas (Landsat-8/OLI (*Operational Land Imager*), Sentinel-2/MSI (*MultiSpectral Instrument*) e SAR (*Synthetic Aperture Radar*) band-C Sentinel-1) e *shapefiles* de campos agrícolas com suas respectivas classes de uso da terra mensais, cobrindo o período de um ano agrícola brasileiro (2017–2018).

Este trabalho é considerado um dos primeiros no uso do LEM *benchmark database*

para aplicação de sensoriamento remoto agrícola em áreas tropicais. Realizaram-se dois experimentos usando parte do banco de dados, um com imagens Sentinel-2/MSI e outro com imagens SAR band-C Sentinel-1, classificando-se o uso do solo ao longo do desenvolvimento das culturas. A Figura 5 mostra os resultados de classificação para diferentes períodos, observa-se que a *overall accuracy* aumentou à medida que mais imagens foram adicionadas à sequência. No entanto, notavelmente, a métrica de *overall accuracy* diminuiu quando a 8ª imagem foi adicionada nos experimentos do Sentinel-1.

Figura 5 – *Overall accuracy* (barras azuis escuras) e pontuação F1 média (barras azuis claras) para diferentes sequências (barra), formadas tomando a primeira imagem e empilhando as seguintes para classificar a última. Sequência de (a) imagens SAR Sentinel-1 de banda C e (b) imagens MSI/Sentinel-2 (direita).



Fonte: Adaptado de Sanches *et al.* (2018)

Isso ocorreu devido à transição entre os ciclos de cultivo que ocorreu exatamente da 7ª para a 8ª época. No entanto, a métrica de *overall accuracy* aumentou novamente a partir da 9ª época, à medida que imagens do novo ciclo de cultivo foram adicionadas à sequência. Observa-se uma clara superioridade do Sentinel-2 sobre os dados do Sentinel-1 em termos de *overall accuracy* de classificação para o mesmo comprimento de sequência.

Em Sanches (2020), diversos trabalhos são apresentados com os resultados seguintes da utilização da base LEM. O trabalho de Achanccaray (2019) apresenta uma abordagem promissora para o reconhecimento de culturas em várias datas usando sensoriamento remoto. O autor utilizou sequências de imagens SAR Sentinel-1 e Optical Landsat-8 de dezembro de 2017 a junho de 2018 para reconhecer todas as diferentes culturas presentes na base de dados

LEM. Para isso, propôs uma abordagem de *Conditional Random Field* (CRF) multitemporal e multirresolução que explora informações em ambos os domínios, espacial e temporal. A abordagem CRF consiste em três termos principais chamados potenciais de associação, interação espacial e interação temporal. O potencial de associação dependia das probabilidades posteriores locais obtidas pela última camada de uma Rede Neural Convolutiva treinada sobre o conjunto de características extraídas das sequências de imagens SAR (polarizações VV e VH) e *Optical* (bandas de 1 a 5 e 7). O potencial de interação espacial foi representado por um modelo de que depende dos dados de pixels espacialmente vizinhos. Finalmente, o potencial de interação temporal introduziu conhecimento especializado sobre transições possíveis e não possíveis entre culturas ao longo do tempo. O modelo proposto alcançou um *overall accuracy* de até 92%, e 83% em termos de *F1-score* para o período selecionado de dezembro de 2017 a junho de 2018.

O estudo de Prudente *et al.* (2019) apresenta uma abordagem para mapear tipos de culturas e outras classes de uso da terra usando séries temporais de imagens SAR Sentinel-1. Os autores analisaram o conjunto de imagens do LEM para o período da segunda colheita de 2017 e para a primeira colheita de 2018, usando o classificador *Random Forest* e a máquina virtual *RUS Machine* da Agência Espacial Europeia. As classificações foram feitas separadamente para as duas colheitas, usando pilhas de imagens SAR de diferentes polarizações. Os autores concluem que as melhores acurácias de classificação foram obtidas para algodão e soja. Em geral, as acurácias de classificação dos alvos das culturas foram maiores para a primeira colheita, o que pode ser explicado pelo fato de que uma maior variedade de culturas é cultivada em LEM durante a segunda colheita, enquanto a soja é a cultura dominante na primeira. Como trabalhos futuros, recomendaram explorar métricas como desvio padrão e amplitude das séries de imagens SAR; e para melhorar a classificação de classes perenes (por exemplo, café), usar séries temporais de imagem mais longas.

Chamorro *et al.* (2019) apresenta uma abordagem inovadora para o reconhecimento de culturas em várias datas usando sensoriamento remoto. Os autores adaptaram duas redes neurais recorrentes, originalmente concebidas para uma única colheita por estação, para o reconhecimento de culturas em várias datas. Além disso, propuseram uma nova abordagem *multidata* baseada em redes neurais recorrentes totalmente convolucionais bidirecionais. Essas três arquiteturas foram avaliadas em conjuntos de dados públicos do Sentinel-1 de duas regiões tropicais no Brasil. Em seus experimentos, todos os métodos alcançaram *overall accuracy* de estado da arte com uma clara superioridade da arquitetura proposta. Este estudo demonstra o desempenho do uso de técnicas avançadas de aprendizado de máquina, como

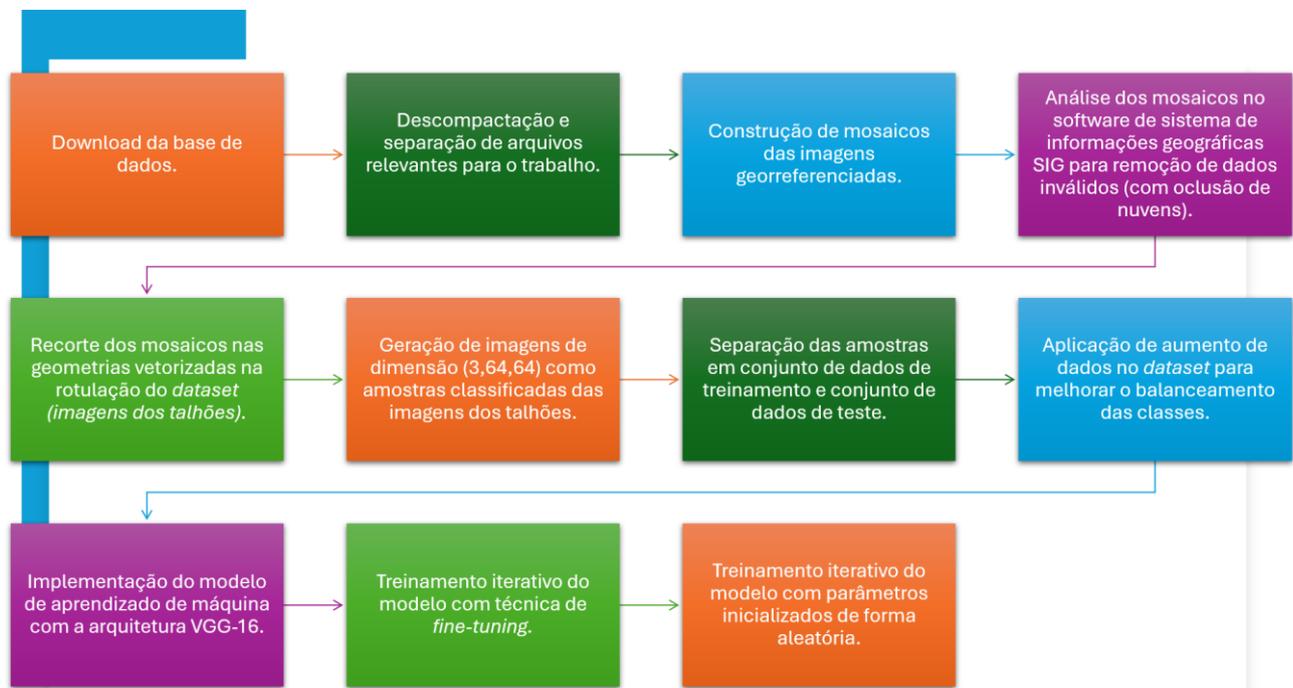
redes neurais recorrentes e convolucionais, para melhorar a métrica de *overall accuracy* na classificação de dados de culturas multitemporais. Isso ressalta a importância da integração de diferentes técnicas de aprendizado de máquina para resolver problemas complexos de classificação de dados em aplicações de sensoriamento remoto.

Dutra *et al.* (2019) investigaram a influência da expansão de áreas de soja na mudança de cobertura da terra no município de Luiz Eduardo Magalhães, Bahia, usando o *dataset* de *benchmark*. O autor utilizou a referência de campo do banco de dados LEM, para mapear a soja e a vegetação nativa e avaliar o impacto da expansão da cultura da soja entre 2007-2014 e 2014-2017. Os resultados desta análise mostraram que a expansão agrícola no município ocorre principalmente ao longo das linhas de cumeeira do relevo, onde se encontram as principais estradas para o escoamento da produção.

3 METODOLOGIA PROPOSTA

A classificação de uso do solo com uso de um modelo do tipo CNN, a partir da base de dados do LEM Benchmark foi realizada utilizando-se de um ambiente computacional (NVIDIA GeForce GTX 1080, com uma taxa de *clock* de memória de 1.7335 GHz, processador Intel(R) Core(TM) i7-6700K CPU, operando a 4.00 GHz e 32 GB de RAM) habilitado para execução de 5 algoritmos em um fluxo de processamento para preparação de dados e posterior implementação, treinamento e execução de inferências do modelo de aprendizado de máquina. Estes algoritmos são executados de forma sequencial em um ambiente computacional implementado com o *framework* Anaconda 5.0, que habilita a instalação do Python em diversas versões bem como possui um repositório de bibliotecas para diversas aplicações. O Python utilizado na criação do ambiente computacional deste projeto foi o Python 3.6, por apontar maior compatibilidade com as ferramentas disponíveis nas biblioteca tensorflow-gpu 1.14.0 e keras 2.11.0. A Figura 6 apresenta de forma sequencial os processos que foram implementados por meio de algoritmos codificados em Python 3.6 e executados no ambiente computacional especificado.

Figura 6 - Fluxo geral de processos executados na metodologia proposta para classificação de uso do solo com um modelo de rede neural convolucional VGG-16.

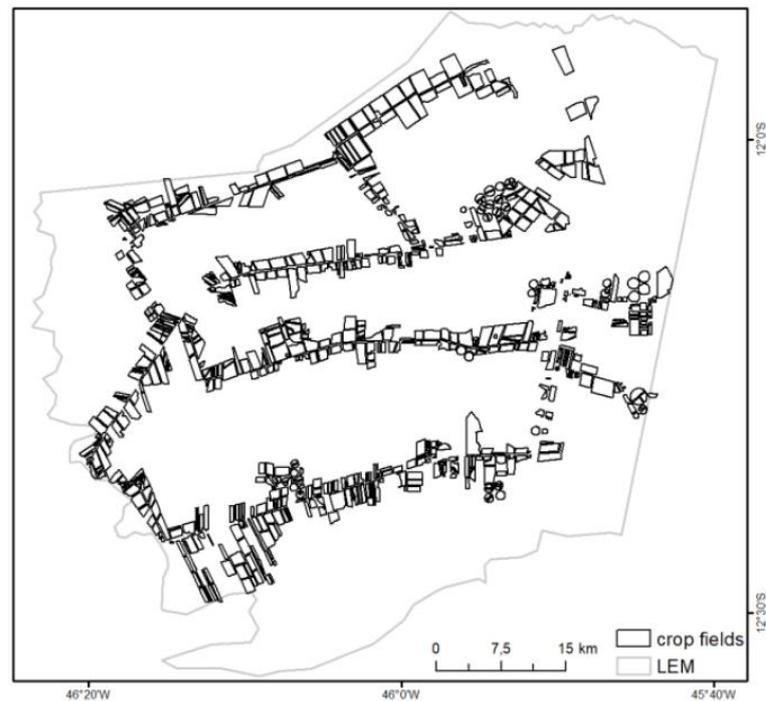


Fonte: Autoria própria.

3.1 DESCRIÇÃO DA BASE DE DADOS

O *dataset* LEM foi criado para contribuir para o desenvolvimento e melhoria de métodos de processamento de imagens na área de sensoriamento remoto para a agricultura, fornecendo informações sobre as culturas em campo por meio de dados coletados *in situ*. Luis Eduardo Magalhães, também conhecido como LEM, é um município localizado no estado da Bahia, na região nordeste do Brasil. Esta cidade está situada a uma latitude de 12°05'31.00" sul e longitude de 45°48'01.80" oeste. O município tem uma área aproximada de 4.000 km² e está a uma altitude de 720 metros (Achanccaray, 2019). O clima de LEM é classificado como Tropical Aw, a temperatura média é de 24,2°C e a precipitação média anual é de 1.511 mm. O solo predominante na região é o latossolo amarelo (Köppen-Geiger, 1928). As áreas alvo da região de estudo são representadas na Figura 7.

Figura 7 -Distribuição das áreas capturadas no LEM database.



Fonte: Adaptado de Sanches *et al.* (2018).

Uma série temporal de imagens ópticas dos sensores Sentinel-2/MSI e Landsat-8/OLI foi adquirida de junho de 2017 a junho de 2018. As imagens do sensor OLI foram adquiridas em reflectância de superfície do Centro de Observação e Ciência de Recursos Terrestres do Serviço Geológico dos Estados Unidos. As imagens do MSI foram adquiridas em reflectância no topo da atmosfera do *Copernicus Open Access Hub*. Em seguida, as imagens de nível 1C

foram convertidas em reflectância de superfície corrigida atmosféricamente usando o algoritmo de Correção Atmosférica Sentinel-2 (Sen2Cor) da Agência Espacial Europeia (ESA). Além das imagens ópticas, imagens SAR de banda C do Sentinel-1A com polarizações VV e VH foram adquiridas, entre junho de 2017 e junho de 2018, do Sentinel *Scientific Data Hub* no modo *Interferometric Wide Swath* (IWS), produto de nível 1 *Ground Range Detected* (GRD) e foram pré-processadas usando a Caixa de Ferramentas Sentinel-1 5.0.

A sequência de processamento para preparação do *dataset* envolveu a aplicação de correções de órbita, calibração radiométrica, correção de terreno e transformação linear para dB. Durante a aplicação da correção de órbita, os vetores de estado de órbita fornecidos nos metadados do Sentinel-1A, que geralmente não são precisos segundo Sanches *et al.* (2018), foram refinados com arquivos de órbita precisos disponíveis em dias a semanas após a geração do produto. Em seguida, os valores de pixel digital foram convertidos radiometricamente e o retroespalhamento calibrado para o coeficiente de calibração *sigma nought* para obter o valor para a antena de uma área unitária no solo relacionada ao alcance do solo. Sanches *et al.* (2018) detalharam que em seguida, foi empregada uma correção de terreno *Range Doppler* usando um modelo digital de elevação da Missão de Topografia de Radar de Ônibus Espaciais (SRTM) para compensar distorções devido a dados de imagem que não estão diretamente na localização do sensor. As imagens foram georreferenciadas para o sistema WGS84. Finalmente, ambas as bandas, VV e VH, foram escalonadas para dB.

Os dados foram coletados em duas campanhas de campo, uma no primeiro e outra no segundo ciclo de colheita do ano agrícola brasileiro de 2017-2018. As informações foram coletadas utilizando o software *Locus Map Pro* em uma tabela, com base em imagens falsas de cores de Sentinel-2 em resolução espacial de 10 metros como fundo. As fronteiras dos campos foram delimitadas usando mosaicos de imagens Sentinel-2 em resolução espacial de 10 metros com falsas cores. As classes de uso da terra foram determinadas para cada campo e mês durante o ano agrícola brasileiro de 2017-2018, com base nas informações coletadas *in situ*, nas falsas cores de séries temporais de imagens ópticas (MSI/Sentinel-2) e em *Normalized Difference Vegetation Index* (NDVI) de séries temporais (MODIS/Terra). Os *shapefiles* foram criados e editados usando o software *Open Source QGIS* (*Quantum Geographic Information System*). As imagens Sentinel-2 foram baixadas do *Hub* de Acesso Aberto da Copernicus e do *Google Earth Engine* (Sanches *et al.*, 2018). Os períodos das aquisições das imagens podem ser observados na Tabela 1.

Tabela 1 - Datas da aquisição das imagem Landsat-8/OLI, Sentinel-2/MSI e Sentinel-1/SAR.

Ano	Mês	Dia OLI	Dia MSI	Dia Sentinel-1
2017	June	15	04, 24	12, 24
	July	01, 17	09, 14	06, 30
	August	02, 18	03, 18, 23	11, 23
	September	03, 19	07, 12, 27	04, 16, 28
	October	05, 21	02, 17, 22	10
	November	06, 20	06, 11, 16, 26	03, 15, 27
	December	08, 24	01, 06, 16, 21, 26	09, 21
2018	January	09, 25	05, 10, 15, 25, 30	02, 14, 26
	February	10, 26	04, 09, 14, 19, 24, 30	07, 19
	March	14, 30	01, 06, 11, 16, 21, 26, 31	03, 15, 27
	April	15	05, 10, 15, 20, 25, 30	08, 20
	May	01, 17	05, 10, 15, 20, 25, 30	02, 14, 26
	June	02, 18	04, 09, 14, 19, 24, 29	07, 19

Fonte: Adaptado de Sanches *et al.* (2018).

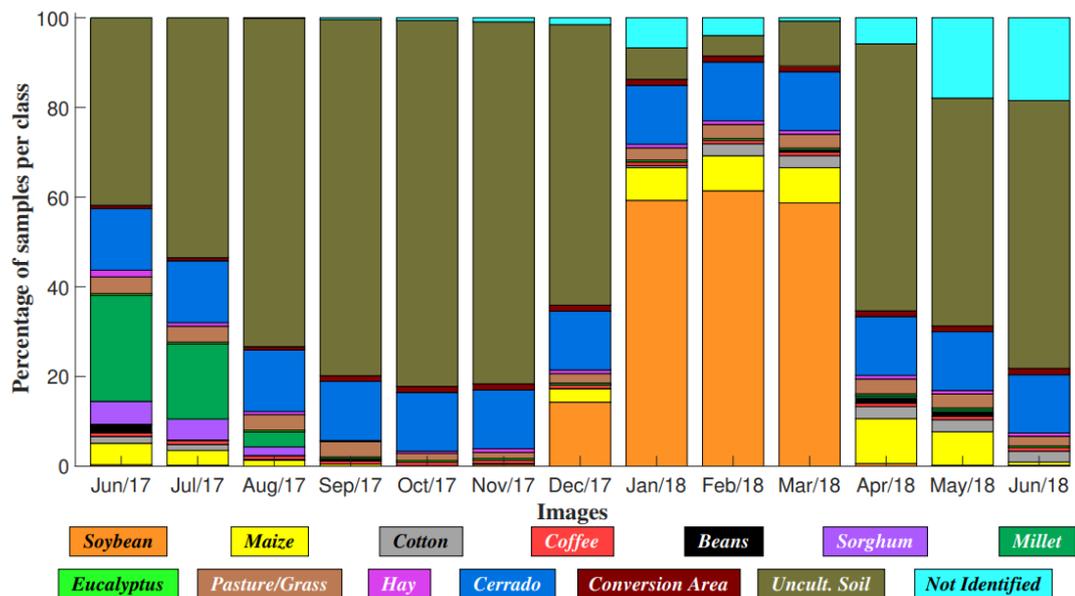
As classes especificadas para categorização dos dados são: soja; milho; algodão; café; feijão; trigo; sorgo; milheto (milheto comercial e não comercial); eucalipto; pastagem; feno; grama, crotalária (espécies de plantas herbáceas); milho e crotalária (milho cultivado em consórcio com crotalária); terreno típico do bioma cerrado como área de conversão (campo de cerrado anterior que foi recentemente desmatado, para finalidade desconhecida); solo não cultivado (solo nu, solo com resíduos de colheita anterior, e solo com ervas daninhas); outras culturas não comerciais (NCC); e não identificado (plantio observado nas imagens entre agosto e novembro, em áreas irrigadas por pivô central). A Tabela 2 mostra a distribuição dos campos por classe em todas as imagens do conjunto de dados. A Figura 8 mostra um gráfico de barras com o acumulado em número de amostras por período para cada classe capturada.

Tabela 2 - Número de campos por classe em cada época.

Class	2017							2018					
	Jun	Jul	Aug	Sep	Oct	Nov	Dec	Jan	Feb	Mar	Apr	May	Jun
Soybean	4	2	-	-	-	10	127	450	450	420	7	4	4
Maize	41	29	15	6	1	4	25	54	61	56	71	53	11
Cotton	15	14	4	-	-	-	-	4	23	23	23	23	22
Coffee	17	17	17	15	15	15	15	15	15	15	15	15	15
Beans	27	8	4	2	-	-	1	1	-	5	15	12	-
Wheat	1	1	1	-	-	-	-	-	-	-	-	-	-
Sorghum	48	40	20	2	-	-	-	-	-	-	-	-	-
Millet	197	140	38	3	-	-	-	-	1	1	6	6	1
Eucalyptus	8	8	8	8	8	8	8	8	8	8	8	8	7
Pasture	30	30	30	30	28	24	24	24	24	24	23	23	23
Hay	23	14	9	6	8	13	13	13	13	13	12	11	9
Grass	22	20	19	19	12	14	22	27	28	27	29	26	18
Crotalaria	1	1	-	-	-	-	-	-	-	-	-	-	-
Maize+Crotalaria	1	1	1	1	-	-	-	-	-	-	-	-	-
Cerrado	66	66	66	65	63	63	63	63	63	63	63	63	62
Conversion area	6	6	6	7	9	9	9	9	9	8	8	8	9
Uncultivated soil	286	396	552	618	636	625	464	49	51	113	437	360	444
NCC	1	1	1	1	1	1	1	3	3	3	3	3	2
Not identified	-	-	3	11	13	8	22	74	45	15	74	179	167

Fonte: Adaptado de Sanches *et al.* (2018).

Figura 8 - Porcentagem de amostras por classe em cada época do conjunto de dados LEM.



Fonte: Adaptado de Achancaray (2019).

De forma geral, o banco de dados contém informações de uso da terra de 794 campos de cultivo localizados no município de Luís Eduardo Magalhães, Brasil, que apresenta dinâmicas de cultivo típicas de áreas tropicais e foi criado para servir como referência para

novas abordagens de mapeamento de culturas baseadas em dados de sensoriamento remoto multitemporal com diferentes sensores. O banco de dados LEM contém sequências de imagens de sensoriamento remoto óptico (Landsat-8/OLI e Sentinel-2/MSI) e radar (banda C do Sentinel-1) pré-processadas. O *dataset* pode ser útil para o desenvolvimento de novos métodos de reconhecimento de padrões para mapeamento e monitoramento de uso da terra agrícola, pode ser utilizado para comparação de diferentes métodos de classificação e análise de séries temporais ópticas e radar remotos.

3.2 PREPARAÇÃO DA BASE PARA O ALGORITMO DE CLASSIFICAÇÃO

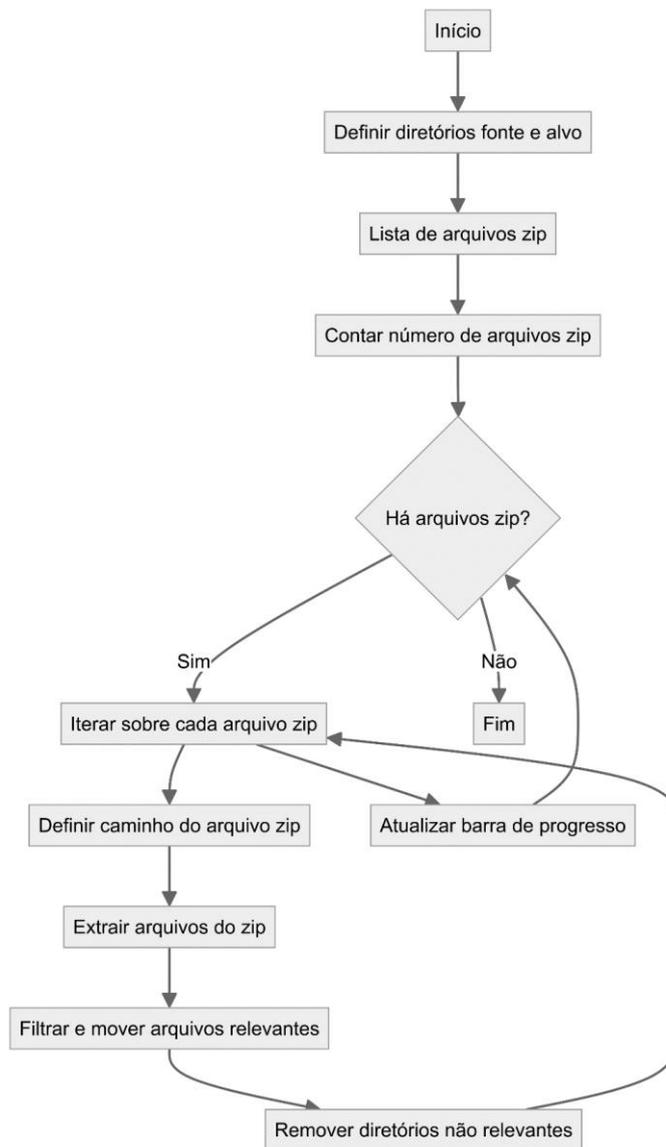
Para utilização da Base de Dados LEM no problema de classificação de uso do solo, implementou-se uma série de 5 algoritmos de carregamento e transformação de dados para formatação do padrão de entrada do modelo utilizado.

Além das principais bibliotecas citadas no início deste capítulo, que são as mais relevantes para implementação do modelo CNN, outras ferramentas de apoio foram utilizadas nesta fase de preparação de dados, dentre elas as principais incluem Affine 2.4.0, para transformações geométricas; Augmentor 0.2.12, para aumento de dados de imagens; GDAL 3.6.2, para manipulação de dados geoespaciais raster e vetorial; Geopandas 0.14, para operações de geoprocessamento; Matplotlib 3.8.4, para visualização de dados; NumPy 1.26, para manipulação de arrays e operações matemáticas; OpenCV 4.9.0.80, para pré-processamento e análise de imagens; Pillow 10.3, para manipulação básica de imagens e Rasterio 1.3.10, para manipulação de dados raster geoespaciais.

O primeiro algoritmo implementado foi o de carregamento dos dados do repositório do LEM Benchmark. Este algoritmo automatiza o processo de extração, filtragem e organização de arquivos em um *dataset* estruturado. Ele trabalha com um conjunto predefinido de arquivos zip, carregados em um diretório de origem após *download* dos dados, e executa a extração de seu conteúdo para o mesmo diretório. Em seguida, percorre os arquivos extraídos, identificando aqueles que correspondem a uma extensão específica de acordo com o tipo de dados a ser extraído, como imagens de radar ou múltiplas bandas ópticas, que são armazenadas separadamente na estrutura dos dados do LEM. Esses arquivos são então movidos para um diretório de destino predefinido. Após a movimentação dos arquivos, o algoritmo remove os diretórios que não contêm informações relevantes, garantindo que apenas os dados necessários sejam mantidos. O tipo de dado, diferentes bandas espectrais para as imagens ópticas ou de radar entram como parâmetros neste algoritmo, neste caso o estudo

foi feito com a aquisição das imagens RGB no formato (jp2). O código também monitora e exibe o progresso da operação utilizando a biblioteca tqdm 4.66.4, fornecendo uma barra de progresso visual para o usuário. Esse processo é especialmente útil para manipular grandes volumes de dados, como imagens de satélite. A Figura 9 apresenta o fluxo lógico de operações do algoritmo desenvolvido.

Figura 9 - Algoritmo de carregamento dos dados a serem utilizados no modelo CNN.

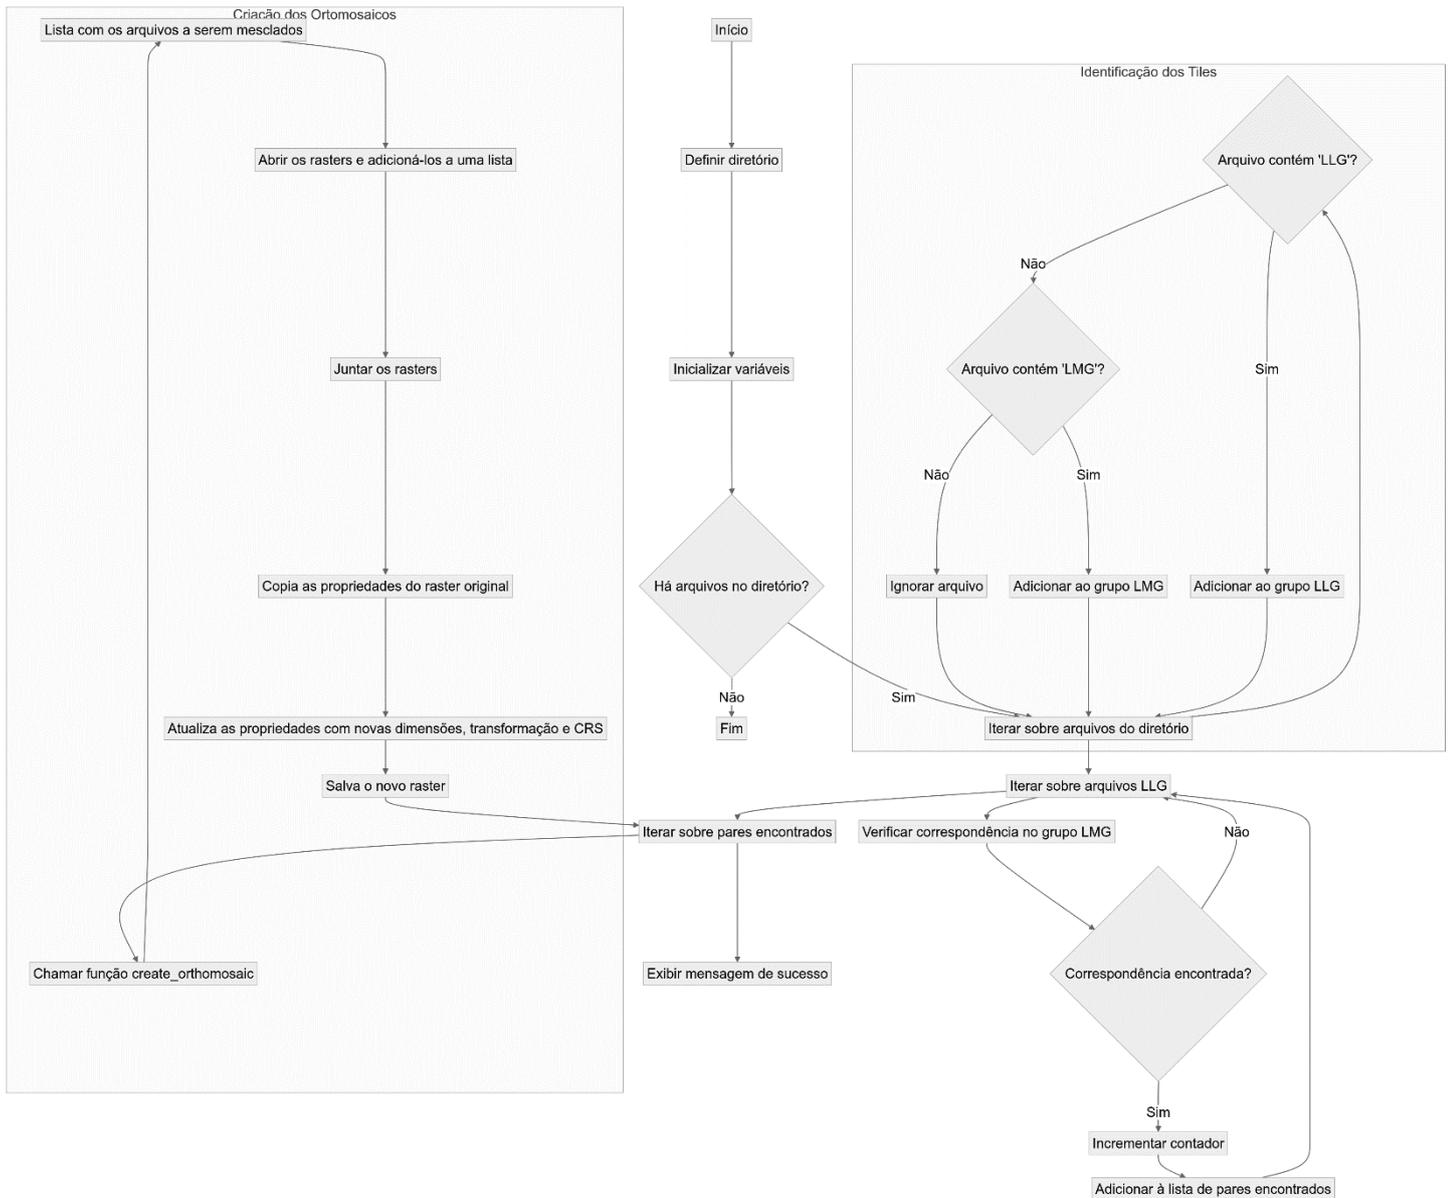


Fonte: Autoria própria.

Na sequência, implemetou-se um algoritmo que automatiza a organização e processamento do arquivos de imagem LLG e LMG, que são os nomes de 2 *Tiles* adquiridos dos dados do sensor Sentinel-2 na região de estudo, cada um deles é uma imagem georreferenciada em 10.000 km² com resolução espacial de 10 m por pixel. Estes 2 *Tiles*

foram adquiridos para cada período da coleta de dados em campo do LEM. Inicialmente, o algoritmo categoriza os arquivos no diretório especificado, separando-os em grupos LLG e LMG. Em seguida, encontra e armazena pares correspondentes de arquivos LLG e LMG. Utilizando a biblioteca rasterio 1.3.10, ele cria ortomosaicos para cada par encontrado, combinando os rasters das imagens LLG e LMG. A função “create_orthomosaic” abre os arquivos raster, mescla-os, e salva o mosaico resultante com metadados atualizados. A Figura 10 apresenta o fluxo de operações realizadas para a composição dos ortomosaicos da região alvo.

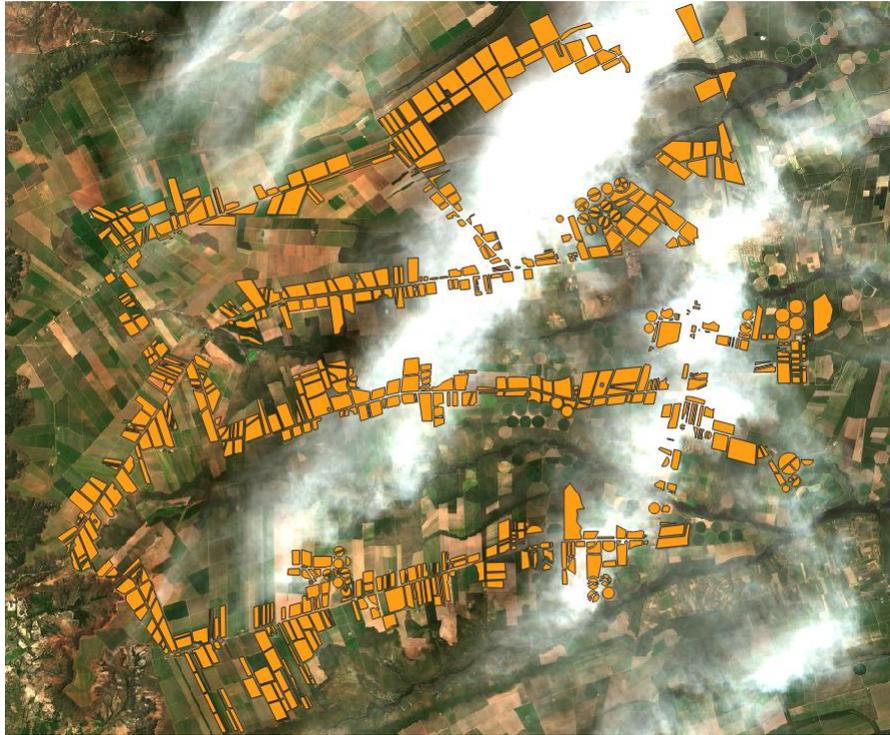
Figura 10 - Fluxo de processamento dos ortomosaicos do Sentinel-2.



Fonte: Autoria própria.

Após o processamento do mosaico, todas as imagens foram carregadas no software QGIS 3.34.3, para que cada raster fosse visualizado e categorizado em termos de cobertura de nuvens, esta categorização foi manual, a partir de uma análise direta sobre a imagem, nos casos em que as regiões de plantio estavam oclusas em parte significativa das áreas alvo, o conjunto inteiro foi removido do *dataset*. Uma versão do *dataset* contendo todas as imagens também foi guardada para avaliação do desempenho do modelo quando treinado sem este filtro. As Figuras 11 e 12 mostram um exemplo dos dados quando submetidos a estas condições.

Figura 11 - Cobertura parcial de nuvens na região do LEM Benchmark, observa-se que para alguns talhões a informação na imagem RGB está totalmente ocluída e em alguns pontos saturada.



Fonte: Autoria própria.

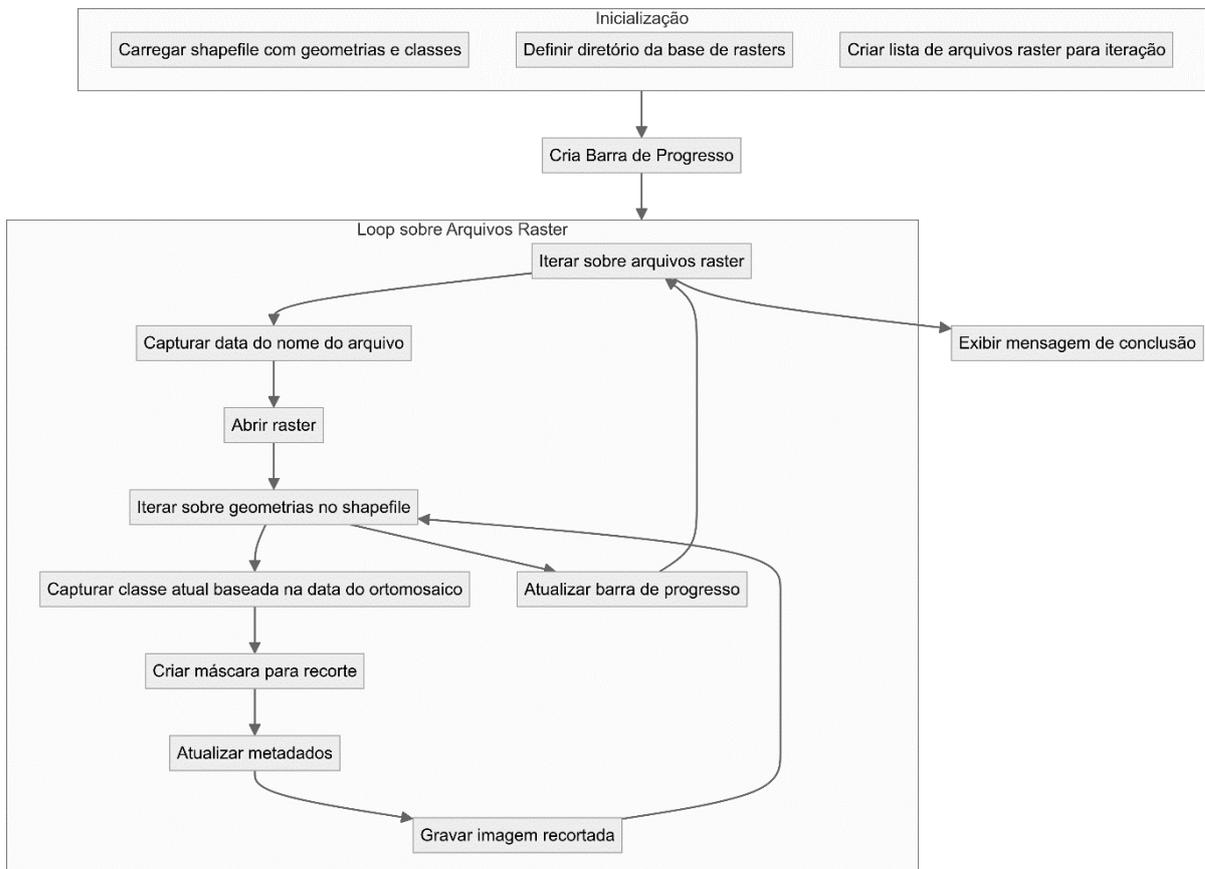
Figura 12- Cobertura de nuvens com forte influência de sombras sobre a superfície terrestre na região do LEM Benchmark, neste caso além das regiões cobertas por nuvens existem também as regiões ocluídas pelas sombras.



Fonte: Autoria própria.

A partir dos mosaicos processados e filtrados, o próximo passo tem o objetivo de extrair as imagens dos talhões específicos do *dataset*, categorizados no arquivo *shapefile* disponível no repositório do LEM. O algoritmo representado na Figura 13 automatiza o recorte de rasters baseados em geometrias definidas no *shapefile*, associando essas geometrias a datas e classes específicas. Utilizando as bibliotecas *geopandas* 0.14.4, *rasterio* 1.3.10, *shapely* 2.0.4, e *tqdm* 4.66.4, ele realiza o seguinte processo: primeiro, carrega o *shapefile* contendo as geometrias de interesse. Em seguida, varre um diretório especificado para encontrar arquivos *raster* (.jp2) e extrai a data de cada arquivo *raster* a partir de seu nome. Para cada *raster*, itera sobre as geometrias do *shapefile*, aplicando uma máscara para recortar a imagem *raster* conforme a geometria. Os metadados da imagem recortada são atualizados e a imagem é salva com um nome de arquivo que inclui a classe, data e índice da geometria. A barra de progresso *tqdm* monitora e exibe o progresso do processamento dos rasters.

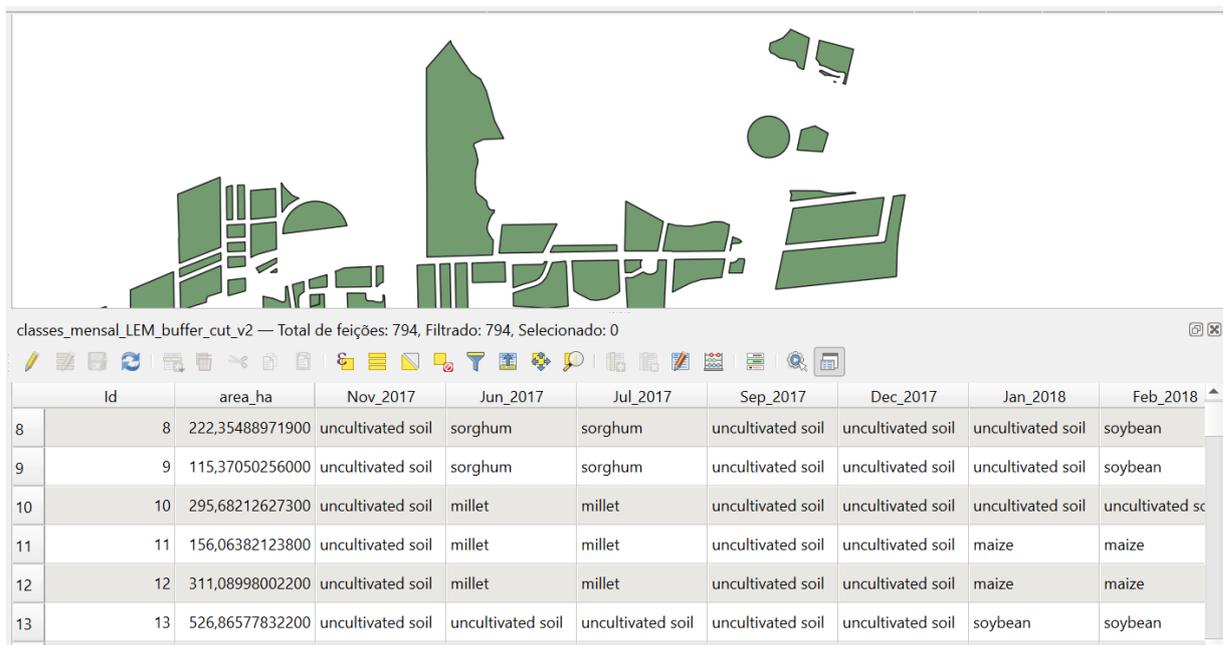
Figura 13 - Criação das imagens dos talhões do dataset, metodologia para extração e categorização das regiões amostradas.



Fonte: Autoria própria.

O *shapefile*, utilizado no algoritmo para captura das geometrias e classes dos talhões em função do tempo, pode ser compreendido como uma tabela de atributos para cada objeto talhão. Estes objetos talhão possuem um atributo principal de polígono, (*geometry*) e mais um atributo para cada mês do período analisado, como apresentado na Figura 14, onde observa-se que em cada data os polígonos recebem uma classe de cultura.

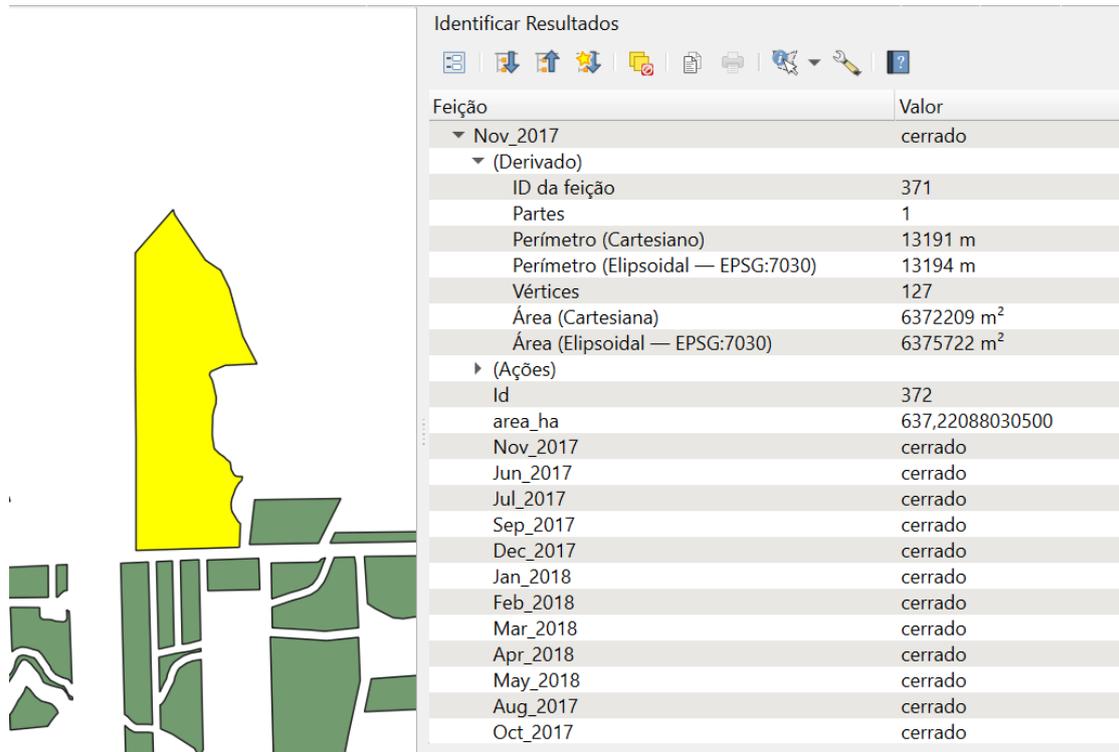
Figura 14 - Visualização do *shapefile* com a tabela de atributos para cada objeto. O Sistema de Informações Geográficas (SIG) apresenta os polígonos de forma gráfica além da tabela com os atributos da geometria.



Fonte: Autoria própria.

Além da visão de conjunto, cada talhão pode ser avaliado também individualmente, como mostra a Figura 15, que apresenta um talhão que permaneceu com a mesma cultura ao longo do período de coleta de dados do LEM *Benchmark*. Além de mostrar informações calculadas pelo Sistema de Informações Geográficas (SIG) com base na geometria do polígono destacado.

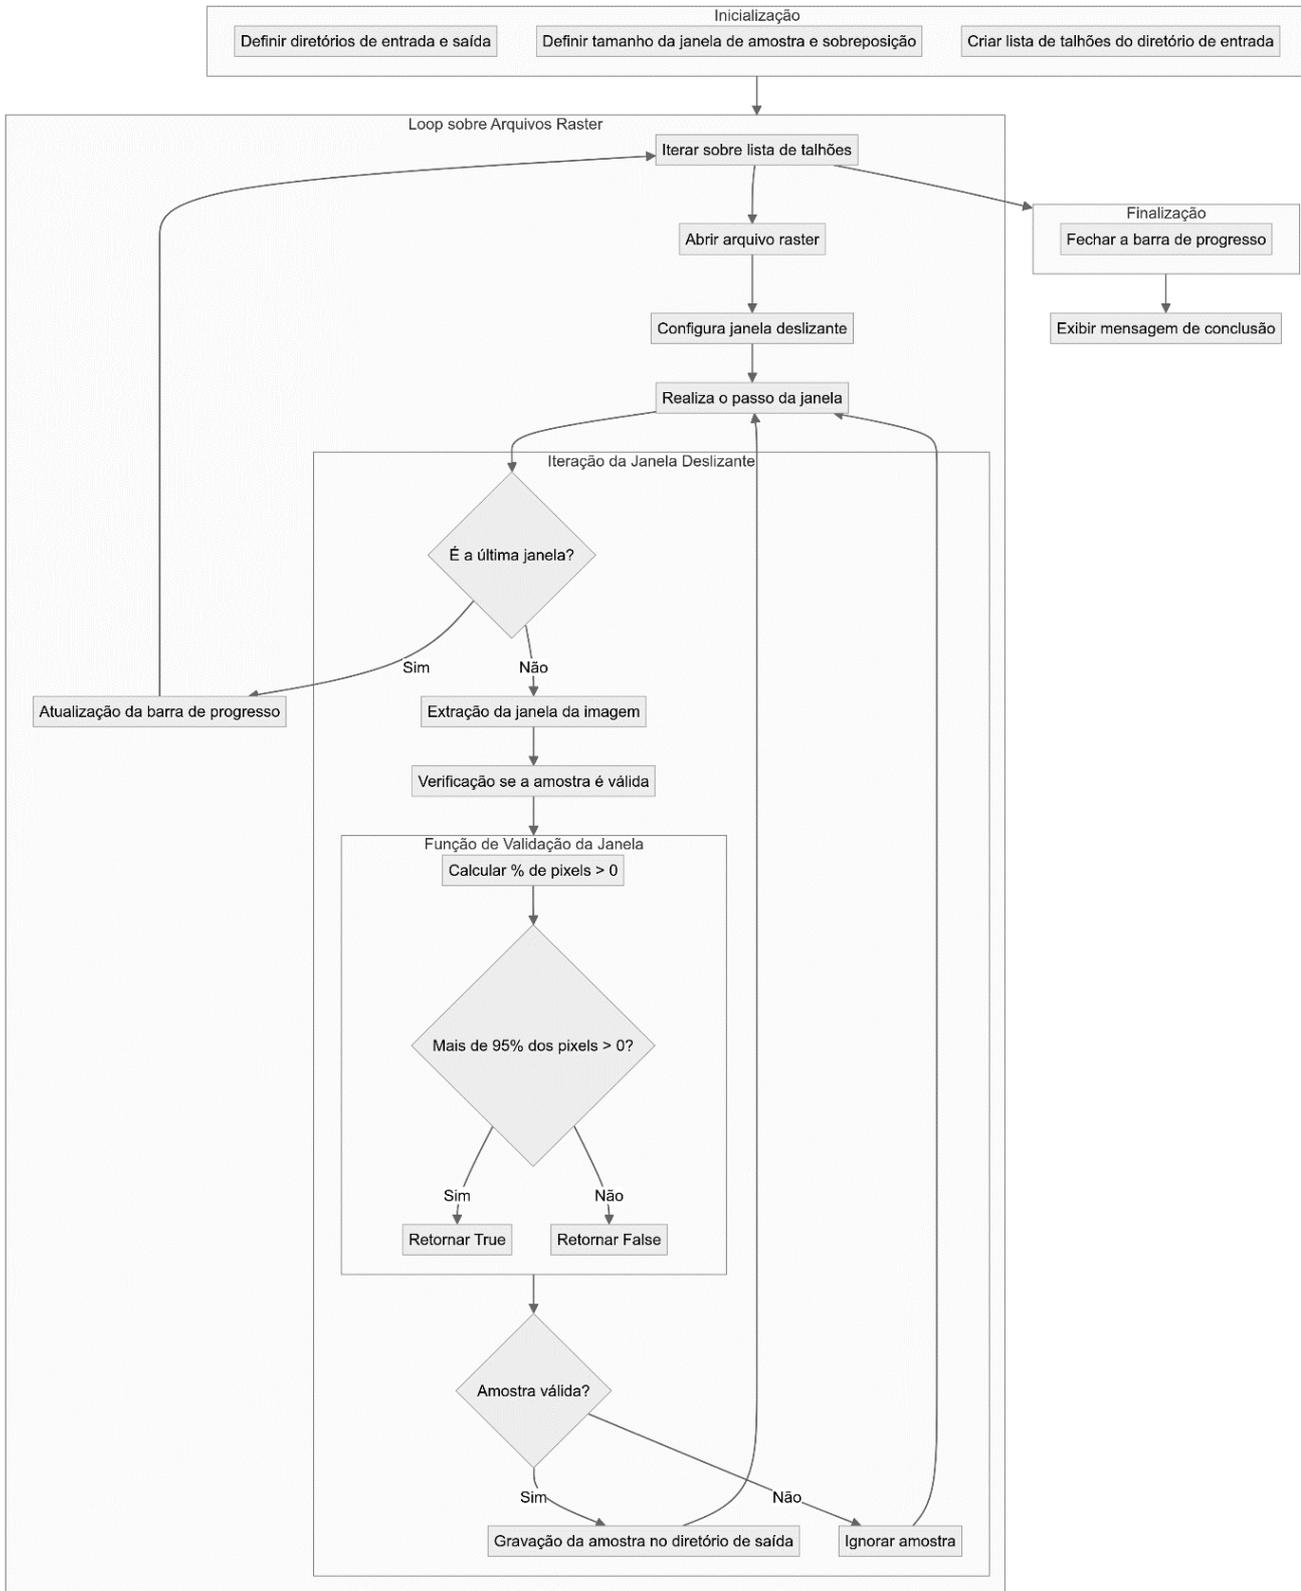
Figura 15 - Visualização das propriedades de uma geometria. Neste exemplo, todos os meses do período apresentaram a mesma classe "cerrado".



Fonte: Autoria própria.

A abordagem utilizada para a classificação das imagens consiste em um modelo que possui uma arquitetura padrão, e recebe os dados em uma dimensão fixa de 64 x 64 pixels em 3 camadas *red*, *green* e *blue* (RGB). Desta forma, a partir dos talhões recortados e rotulados, um outro algoritmo automatiza a extração de amostras destas imagens, gerando uma série de recortes de dimensão fixa extraídos por uma janela deslizante nos *rasters* de talhão. Esta janela deslizante recebe como parâmetros o passo que é deslocado na horizontal e vertical, compondo desta forma também a sobreposição aceita em duas amostras diferentes. Esta técnica aumenta a quantidade de dados quando se especifica um passo menor com maior sobreposição. O algoritmo apresentado na Figura 16 foi implementado com alguns testes para identificação da validade da janela, pois uma janela que não possui informação deve ser descartada, como as encontradas nas bordas das imagens, para isso, realiza-se um teste do percentual de pixels com valor zero dentro da janela. As informações de metadados e classes de cada amostra são herdadas da imagem de talhão.

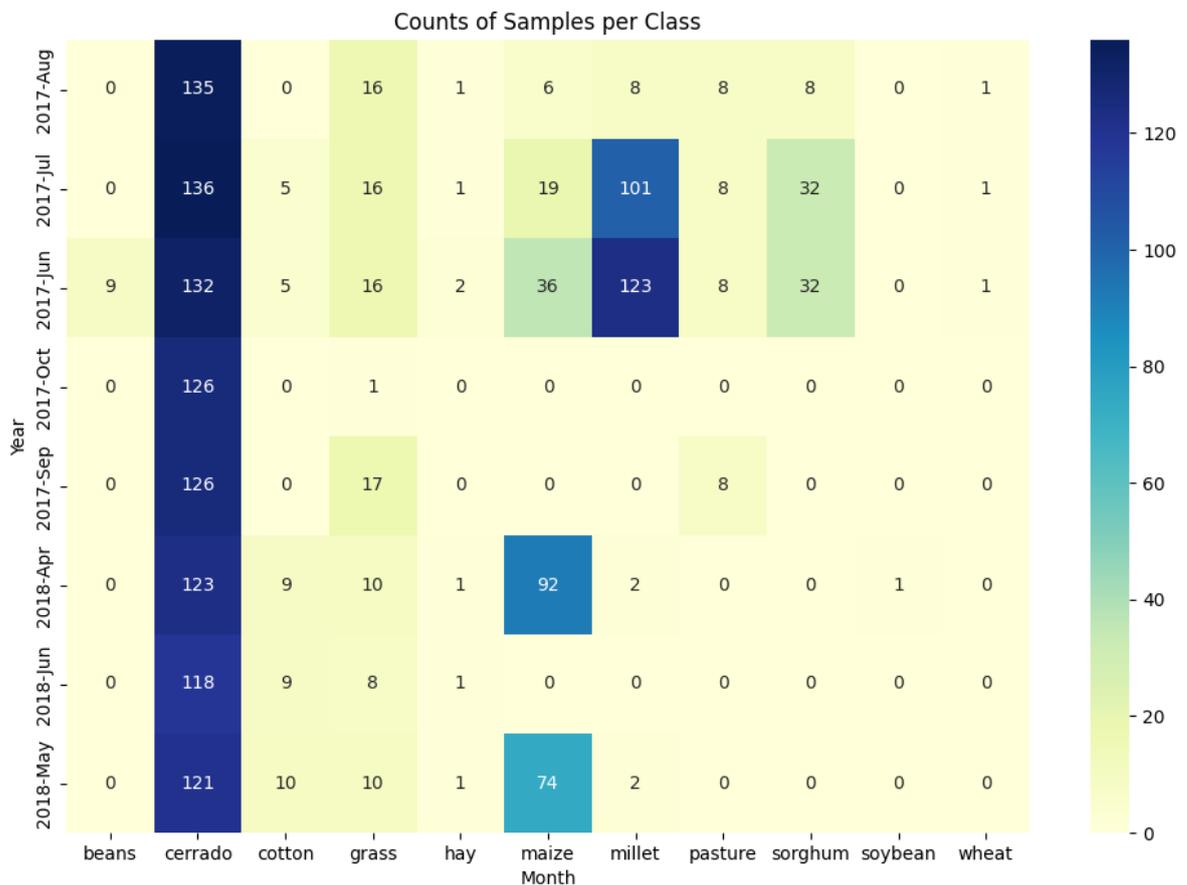
Figura 16- Algoritmo de geração de amostras com base em uma janela deslizante para recorte de imagens válidas.



Fonte: Autoria própria.

A partir das amostras geradas e categorizadas, implementou-se um algoritmo para organização do *dataset* de forma que cada amostra seja armazenada em um diretório correspondente à sua classe. O algoritmo da Figura 19 automatiza este processo e evidencia a quantidade de amostras por classe, neste caso, duas classes foram removidas do conjunto após as observações realizadas neste passo, uma classe que correspondia a mais de 50% dos dados e outra classe que estava representada por apenas 4 imagens. A Figura 17 mostra a condição do *dataset* quando utilizado o conjunto com remoção das imagens de nuvens, observa-se que apenas uma imagem é encontrada para a classe “soybean”, enquanto a classe “cerrado” apresenta um volume muito superior.

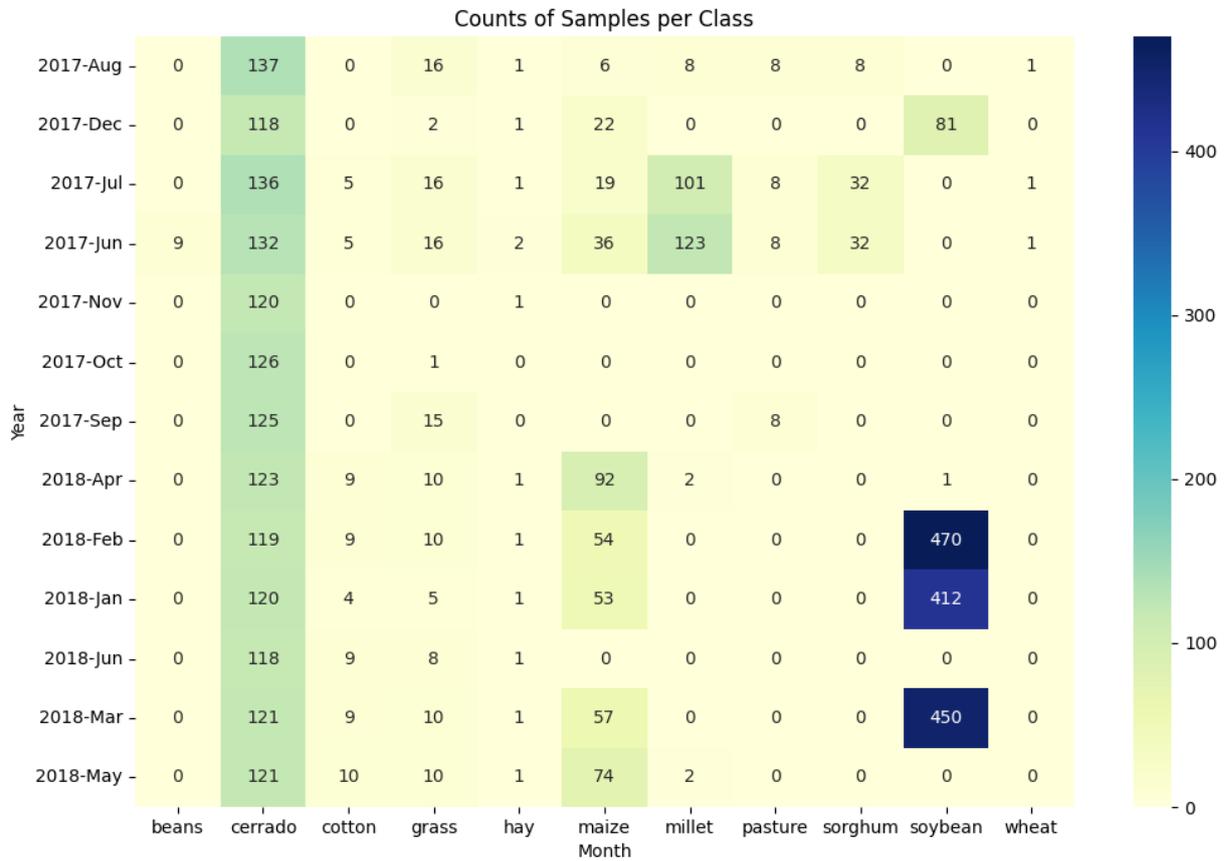
Figura 17 - Representação das classes no *dataset* LEM Benchmark após a geração de amostras dos talhões para o modelo CNN quando removidas as imagens com cobertura de nuvem.



Fonte: Autoria própria.

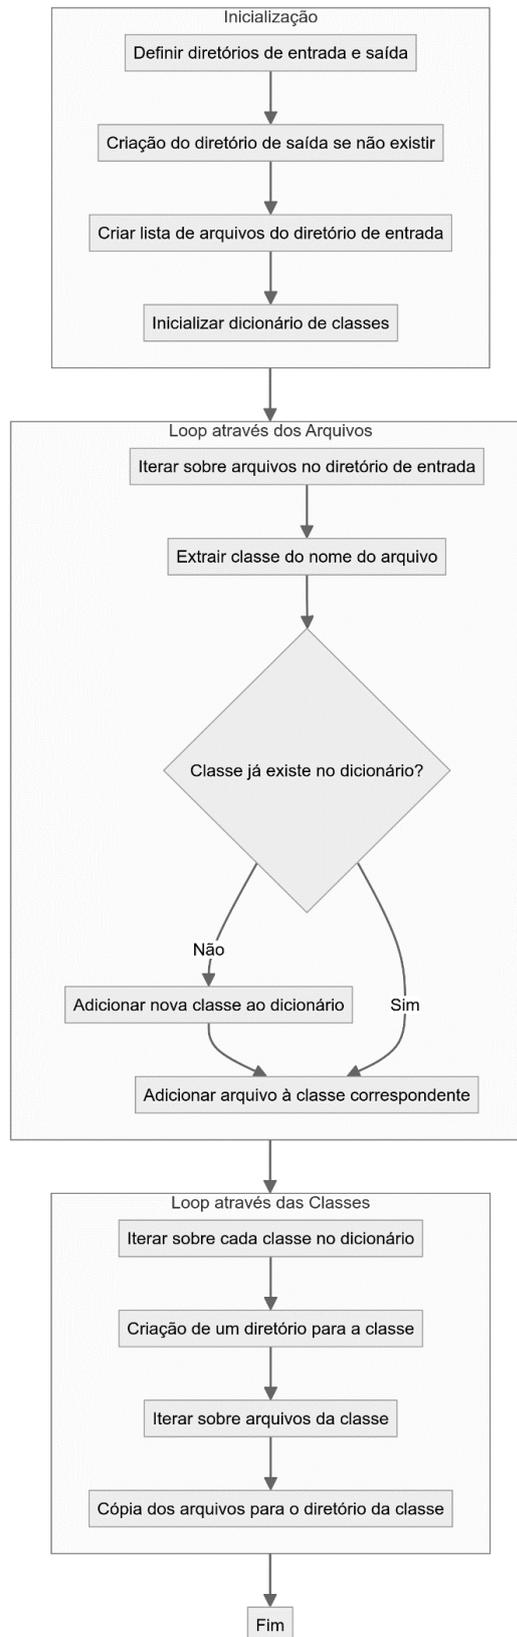
A Figura 18 mostra qual seria a condição caso não houvesse a remoção de imagens ocluídas pelas nuvens, o cenário é melhor, porém ainda com um desbalanceamento significativo.

Figura 18 - Representação das classes no *dataset* LEM Benchmark após a geração de amostras dos talhões para o modelo CNN sem a remoção de nenhum dado, neste caso, todos os mosaicos foram considerados para todos os períodos do estudo.



Fonte: Autoria própria.

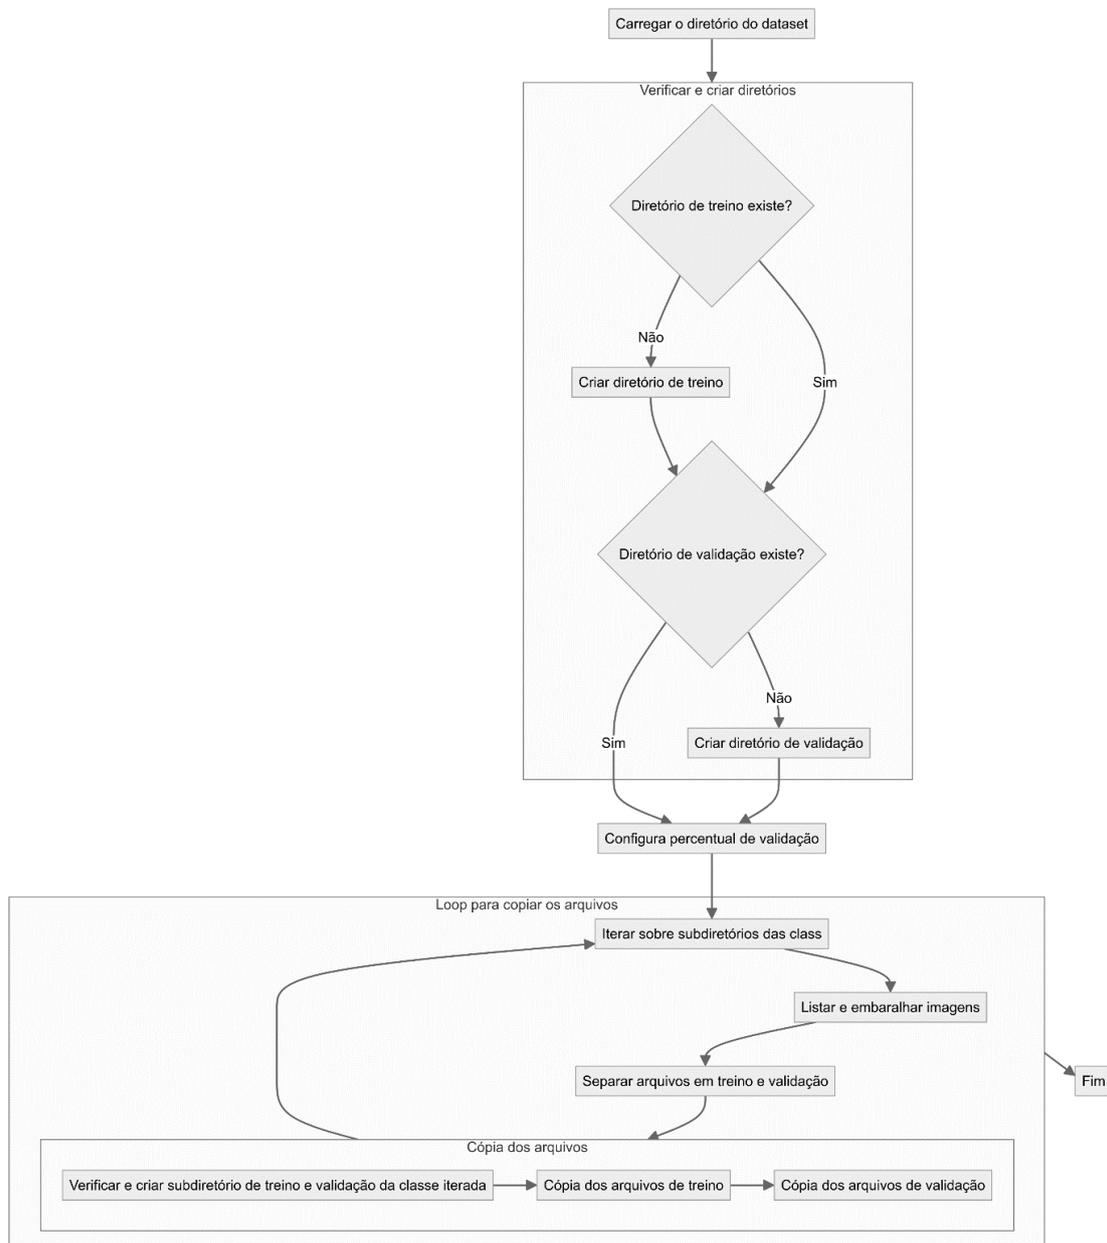
Analisando-se a composição dos dados após filtrar as imagens com oclusão de nuvens, observa-se que há um desbalanceamento expressivo entre algumas classes, o que indica que uma técnica de aumento de dados pode ser necessária para evitar que o modelo seja ajustado com viés para as classes dominantes, além disso para minimizar o impacto do desbalanceamento e preservar o volume de dados referente à classe *soybean*, optou-se pela utilização do *dataset* sem a remoção das imagens ocluídas, porém eliminando-se a classe *wheat*, que ficou constituída de apenas 3 amostras.

Figura 19 - Organização do *dataset* nos diretórios das classes a serem inferidas pelo modelo.

Fonte: Autoria própria.

Com todos os diretórios que compõem o conjunto de dados já estruturados, pode-se seguir com a preparação da próxima etapa, a divisão do conjunto em dados de treinamento e validação do modelo. O algoritmo implementado para esta etapa realiza uma varredura em todos os diretórios, capturando de forma aleatória um percentual especificado de amostras para validação e parcela complementar de amostras para o treinamento, exportando para uma cópia do diretório origem, para dois destinos, validação e treinamento, que armazenam os diretórios de cada classe com os dados já distribuídos. Para preparação dos dados deste conjunto, especificou-se o percentual de 30% dos dados de cada classe para validação e 70% de treinamento. A Figura 20 apresenta o algoritmo que automatiza este processo.

Figura 20 - Algoritmo de separação de dados em conjunto de treinamento e de validação do modelo.

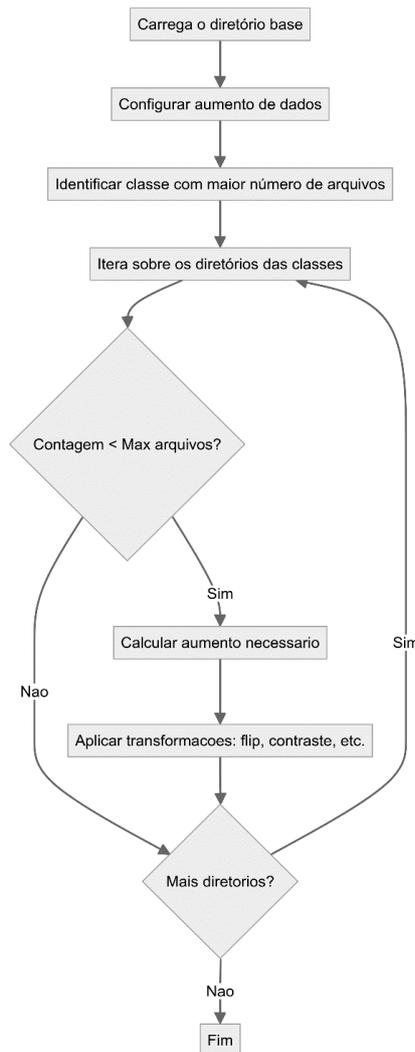


Fonte: Autoria própria.

Após a execução do processo de separação dos dados de treinamento e validação, o *dataset* está pronto para ser utilizado pelo modelo. Porém, por efeitos de testes e otimização, implementou-se uma outra etapa com um processo de aumento de dados para tratar do balanceamento e garantir a representação de todas as classes. O algoritmo apresentado na Figura 21 foi implementado recebendo a instrução de aumentar os dados até que todas as classes obtivessem o mesmo número de amostras da classe com maior quantidade de dados. Para geração dos dados aumentados, realizaram-se cópias das amostras com alterações aleatórias de rotação, contraste e espelhamento das imagens, utilizando-se a biblioteca *Augmentor* na versão v0.2.10 com os seguintes parâmetros:

1. *flip_left_right(probability=0.5);*
2. *randon_contrast(probability=0.5, min_factor=0.7, max_factor=1.3);*
3. *rotate(probability=0.7, max_left_rotation=10, max_right_rotation=10).*

Figura 21 - Algoritmo de aumento de dados utilizado para balanceamento das classes.



Fonte: Autoria própria.

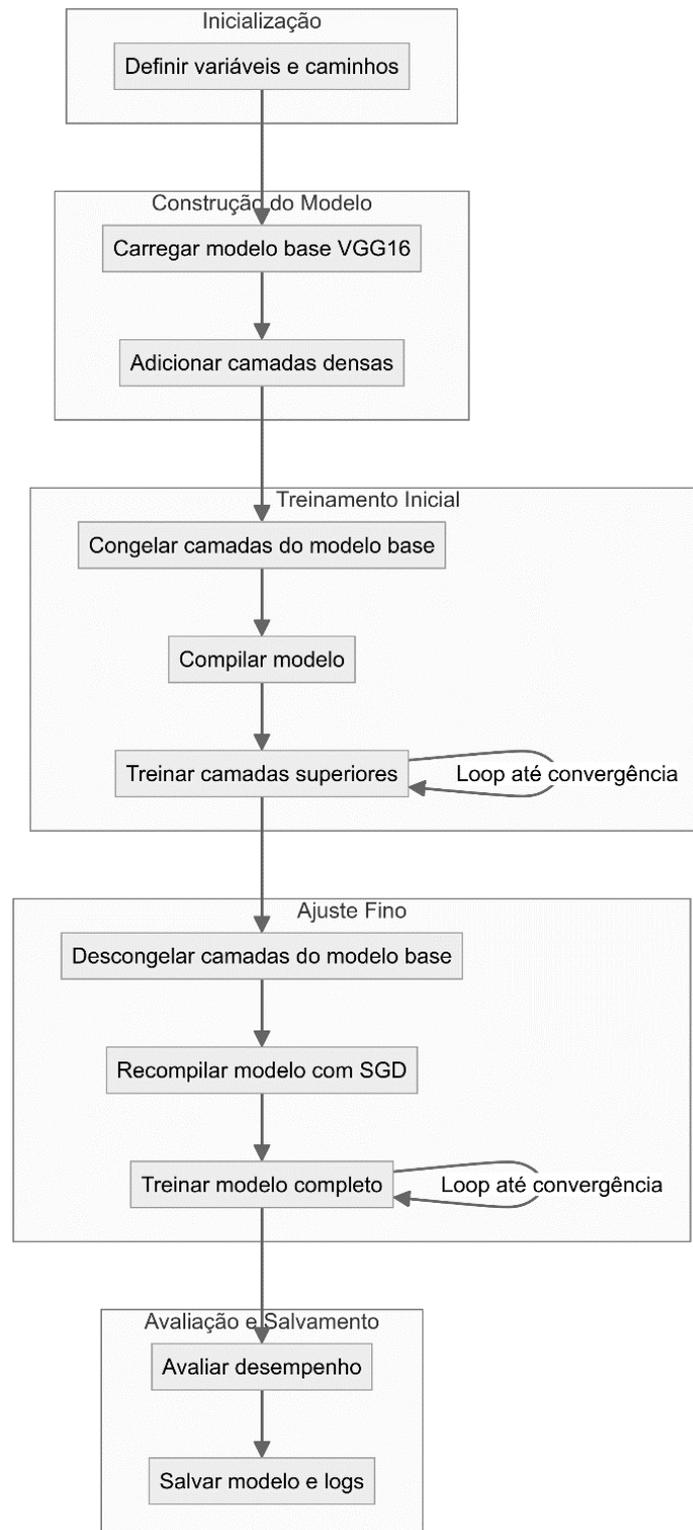
3.3 CLASSIFICAÇÃO DAS IMAGENS COM A CNN VGG-16

Com base nos resultados obtidos pelos trabalhos de Shafapourtehrany *et al.* (2023) e Wang *et al.* (2021), que mostraram performance superior da arquitetura VGG-NET frente a outros modelos CNN performando sobre dados do Sentinel-2, optou-se por implementar esta arquitetura para classificação das imagens no problema de classificação de uso do solo. A metodologia inclui também a técnica de *fine-tuning*, aproveitando os pesos já treinados com o conjunto de dados *ImageNet, dataset* descrito por Deng *et al.* (2009).

Para construção do modelo, utilizou-se do mesmo ambiente computacional especificado para a preparação dos dados, Python 3.6 com uso principalmente das bibliotecas tensorflow-gpu 1.14.0 e keras 2.11.0. A lista completa de dependências do ambiente pode ser encontrada no Apêndice A.

O algoritmo apresentado na Figura 22, refere-se à implementação do processo de treinamento do modelo VGG16, que neste caso foi obtido da API do Keras 2.11.0 pré-treinado. O processo envolve o treinamento inicial e o ajuste fino *fine-tuning* do modelo para a tarefa de classificação de imagens em múltiplas classes. As bibliotecas utilizadas incluem 'tensorflow.keras.applications.vgg16', 'tensorflow.keras.callbacks' que contém callbacks como *EarlyStopping*, *ModelCheckpoint* e *TensorBoard*, 'tensorflow.keras.layers' com camadas como Dense e GlobalAveragePooling2D, 'tensorflow.keras.models' para definir e compilar o modelo, 'tensorflow.keras.optimizers' que inclui o otimizador SGD (*Stochastic Gradient Descent*) e adadelta, e 'tensorflow.keras.preprocessing.image' utilizada para o pré-processamento e geração de lotes de dados de imagem.

Figura 22 - Processo de implementação e treinamento do modelo VGG-16 adaptado.



Fonte: Autoria própria.

Os diretórios utilizados no processo são especificados para organizar os dados e salvar os resultados do treinamento. Os principais diretórios relacionado ao fluxo de dados no processo de treinamento são: *'base_dir'*, diretório base onde logs e modelos treinados são armazenados; *'path_to_split_datasets'*, diretório contendo os conjuntos de dados divididos (treinamento e validação); *'path_to_train'* e *'path_to_validation'*, são subdiretórios específicos para os dados de treinamento e validação, respectivamente. Estes diretórios permitem que o modelo acesse os dados de forma estruturada e eficiente durante o processo de treinamento.

Os hiperparâmetros do modelo são configurados para otimizar o desempenho e evitar *overfitting*. O *'batch_size'* é definido como 64, o que determina o número de amostras que serão processadas antes de atualizar os parâmetros do modelo. A configuração do modelo inclui *'include_top=False'* para remover a camada de classificação final e *'weights=imagenet'* para utilizar os pesos pré-treinados no *ImageNet*.

A construção do modelo envolve a adição de camadas personalizadas após o modelo base. O *'GlobalAveragePooling2D'* é utilizado para reduzir as dimensões espaciais da saída da CNN. Em seguida, são adicionadas duas camadas totalmente conectadas (*Dense*) com 2048 unidades e função de ativação *'relu'* para melhorar a capacidade de aprendizado. Finalmente, uma camada de classificação (*Dense*) com número de unidades igual ao número de classes e função de ativação *'softmax'* é adicionada para fornecer a correspondente saída do classificador. Entre as últimas camadas (*Dense*) utilizaram-se camadas de regularização com as técnicas de *batch normalization* e *dropout*. Este modelo combinado é então compilado para o treinamento. A Tabela 3 mostra a arquitetura do modelo após ser compilado.

Tabela 3 - Arquitetura da CNN do tipo VGG-16 implementada para classificação das imagens.

CAMADA	FORMA DE SAÍDA	PARÂMETROS
input_1 (InputLayer)	(64, 64, 3)	0
block1_conv1 (Conv2D)	(64, 64, 64)	1792
block1_conv2 (Conv2D)	(64, 64, 64)	36928
block1_pool (MaxPooling2D)	(32, 32, 64)	0
block2_conv1 (Conv2D)	(32, 32, 128)	73856
block2_conv2 (Conv2D)	(32, 32, 128)	147584
block2_pool (MaxPooling2D)	(16, 16, 128)	0
block3_conv1 (Conv2D)	(16, 16, 256)	295168
block3_conv2 (Conv2D)	(16, 16, 256)	590080
block3_conv3 (Conv2D)	(16, 16, 256)	590080
block3_pool (MaxPooling2D)	(8, 8, 256)	0
block4_conv1 (Conv2D)	(8, 8, 512)	1180160
block4_conv2 (Conv2D)	(8, 8, 512)	2359808
block4_conv3 (Conv2D)	(8, 8, 512)	2359808
block4_pool (MaxPooling2D)	(4, 4, 512)	0
block5_conv1 (Conv2D)	(4, 4, 512)	2359808
block5_conv2 (Conv2D)	(4, 4, 512)	2359808
block5_conv3 (Conv2D)	(4, 4, 512)	2359808
block5_pool (MaxPooling2D)	(2, 2, 512)	0
global_average_pooling2d	(512)	0
batch_normalization	(512)	2048
dense (Dense)	(2048)	1050624
batch_normalization_1	(2048)	8192
dropout (Dropout)	(2048)	0
dense_1 (Dense)	(2048)	4196352
batch_normalization_2	(2048)	8192
dropout_1 (Dropout)	(2048)	0
dense_2 (Dense)	(10)	20490

Fonte: Autoria própria.

O *fine-tuning*, do modelo envolve um processo em duas etapas. Primeiro, todas as camadas da base do modelo são congeladas para preservar os pesos pré-treinados e apenas as camadas superiores adicionadas são treinadas, o otimizador neste caso tem a taxa de aprendizado adaptativa conforme o algoritmo ‘adadelta’ de Zeiler, 2012. Depois que as camadas superiores são treinadas, as camadas inferiores do modelo base são descongeladas e treinadas com uma taxa de aprendizado de 0,001, dez vezes menor do que a taxa padrão do otimizador SGD (*stochastic gradient descent*) implementado na biblioteca Keras 2.11.0, o parâmetro de *momentum* também foi alterado do padrão 0 para 0,9, forçando assim um aprendizado mais lento para ajustar finamente os parâmetros do modelo. Este processo é

essencial para aproveitar ao máximo os pesos pré-treinados enquanto adapta o modelo às características específicas do novo conjunto de dados.

Durante o treinamento inicial, apenas as camadas superiores são treinadas. Para isso, todas as camadas do modelo base são configuradas como não treináveis, e o modelo é compilado utilizando a função de custo '*categorical_crossentropy*' e a métrica '*categorical_accuracy*'. Os *callbacks* '*ModelCheckpoint*', '*EarlyStopping*' e '*TensorBoard*' são configurados para salvar o melhor modelo, interromper o treinamento se a métrica de validação não melhorar após um número definido de épocas e registrar os logs do treinamento, respectivamente.

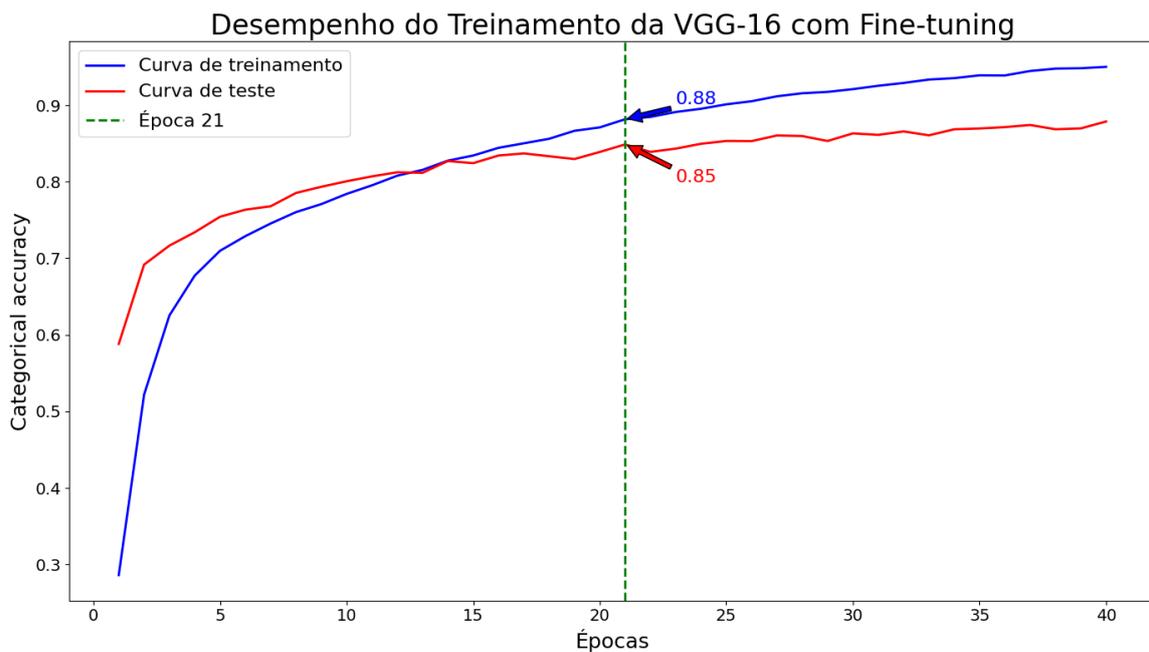
Além da otimização realizada a partir dos pesos pré-treinados, realizou-se também o treinamento do modelo a partir dos pesos da CNN inicializados de forma aleatória, sendo treinados completamente pelas iterações de otimização da função de custo '*categorical_crossentropy*' e otimizador 'adadelta'.

4 RESULTADOS E DISCUSSÕES

Neste capítulo, os resultados obtidos no treinamento do modelo VGG-16 são analisados com base nas duas metodologias aplicadas, com *fine-tuning* e sem *fine-tuning*: treinamento dos pesos do modelo do zero com inicialização aleatória e utilizando-se pesos pré-treinados do *ImageNet Dataset*. Os resultados foram interpretados do comportamento das curvas da *categorical accuracy* e função de custo utilizada no modelo. A discussão discorre os aspectos que indicam *overfitting*, possíveis melhorias com base nas observações dos gráficos e aspectos comparativos relacionados à metodologia adotada na primeira análise de classificação de uso do solo utilizando o *LEM Benchmark* com o uso do algoritmo *Random Forest*.

Os resultados apresentados no treinamento da VGG-16 com *fine-tuning* mostram que o modelo desempenhou melhor do que quando treinado sem *fine-tuning*, com uma diferença de 3% a mais em *categorical accuracy*. Analisando-se o gráfico apresentado na Figura 23, podemos observar que a curva de *categorical accuracy* tanto para o conjunto de treinamento quanto para o conjunto de teste apresentam uma taxa de crescimento maior ao longo das épocas iniciais, o que é esperado em treinamentos de redes neurais profundas que iniciam o treinamento com pesos pré-treinados. No entanto, a partir de certo ponto, a curva de teste começa a estabilizar, indicando a proximidade do ponto de saturação do modelo.

Figura 23 - Treinamento do modelo VGG-16 com aplicação da técnica de fine-tuning com pesos pré-treinados do conjunto de dados ImageNet.



Fonte: Autoria própria.

O momento de parada do treinamento é crucial para evitar o fenômeno do *overfitting*, onde o modelo começa a "memorizar" os dados de treinamento ao invés de aprender padrões generalizáveis. No gráfico apresentado, a época 21 foi marcada como o ponto de parada ideal, onde a *categorical accuracy* do conjunto de teste atingiu 0.85, enquanto o conjunto de treinamento apresentou *categorical accuracy* de 0.88. A diferença de 3% entre os desempenhos de treinamento e teste nesse ponto é um indicador de que o modelo está começando a se sobreajustar aos dados de treinamento, mas ainda mantém uma boa generalização.

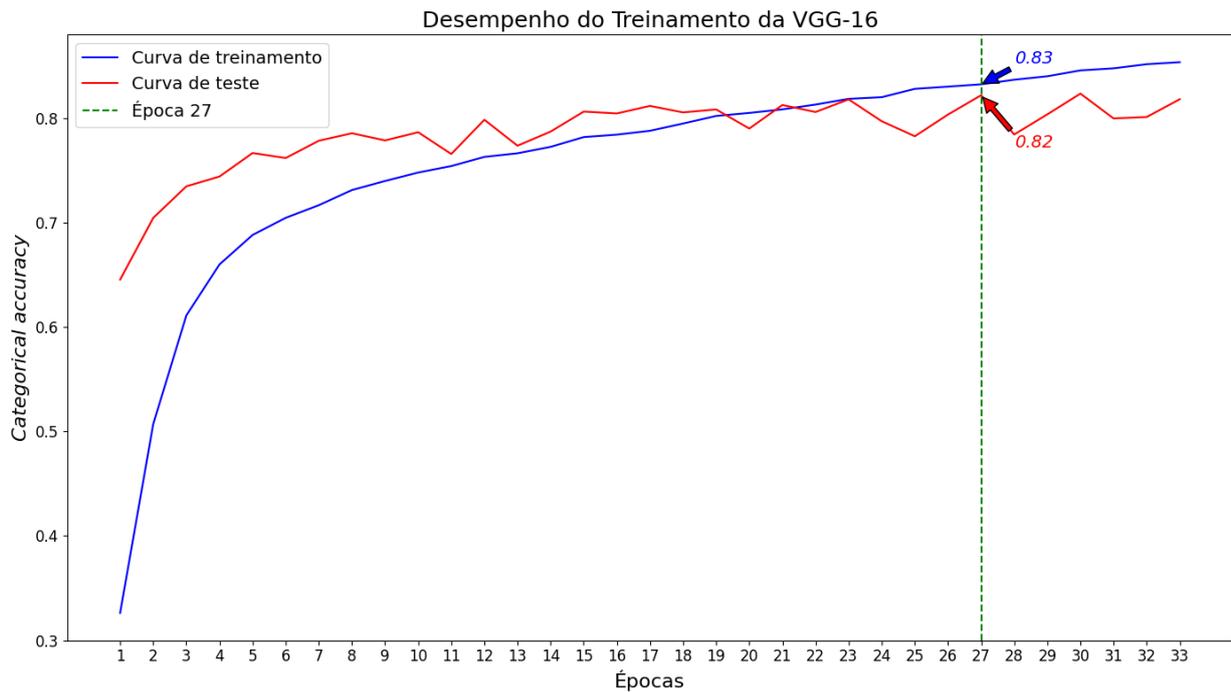
Após a época 21, observamos que a curva de treinamento continua a aumentar, atingindo valores próximos a 0.9, enquanto a curva do conjunto de teste não apresenta melhorias significativas e começa a oscilar. Essa divergência crescente entre as curvas de treinamento e teste é um sinal de *overfitting*. Em outras palavras, o modelo se torna cada vez mais especializado nos dados de treinamento, perdendo a capacidade de generalizar para novos dados, o que é evidenciado pela estabilização e eventual declínio na performance do conjunto de teste.

Dessa forma, a interpretação técnica dos resultados indica que, embora o *fine-tuning* tenha trazido ganhos na performance inicial, o monitoramento cuidadoso da diferença de desempenho entre os conjuntos de treinamento e teste é essencial para determinar o ponto de parada ideal do treinamento. Nesse caso, parar na época 21 ajudou a prevenir um *overfitting* mais severo, garantindo que o modelo mantenha um bom equilíbrio entre a capacidade de aprendizado e a generalização.

4.1 TREINAMENTO SEM PESOS DO *IMAGENET DATASET*

O treinamento do modelo a partir do zero, ou seja, sem a utilização de pesos pré-treinados, é uma abordagem que oferece uma taxa de aprendizado mais lenta, este comportamento é esperado, já que o modelo começa com pesos aleatórios e precisa "aprender do zero" a identificar e extrair características relevantes dos dados, ao contrário dos modelos que utilizam pesos pré-treinados, onde as camadas já possuem algum conhecimento prévio sobre padrões básicos, como bordas, texturas, etc., aqui o modelo deve desenvolver essas capacidades de forma independente, o que leva a um período inicial onde a curva da função de custo é otimizada mais lentamente. A Figura 24 mostra a curva de treinamento e teste do modelo quando os pesos (parâmetros) são inicializados de forma aleatória, sem os valores pré-treinados do conjunto de dados *ImageNet*.

Figura 24 - Treinamento do modelo VGG-16 com pesos inicializados de forma aleatória.



Fonte: Autoria própria.

No treinamento da VGG-16 sem o uso de *fine-tuning*, as curvas de *categorical accuracy* para os conjuntos de treinamento e teste revelam aspectos importantes sobre o desempenho do modelo e os desafios enfrentados ao treinar uma rede profunda sem ajustes adicionais. Inicialmente, podemos observar que ambas as curvas, tanto para o conjunto de treinamento quanto para o de teste, também apresentam uma taxa de aprendizado maior nas primeiras épocas, apesar de atingir a faixa de 80% em *categorical accuracy* mais tarde do que na abordagem sem o *fine-tuning*. A curva de treinamento aumenta de forma constante, o que indica que o modelo está aprendendo e se ajustando progressivamente aos dados. No entanto, a curva de teste começa a estabilizar e oscilar em torno de um valor antes mesmo do treinamento completo, o que sugere que o modelo está começando a atingir sua capacidade máxima de generalização.

Um ponto crítico a ser observado é a divergência que ocorre entre as curvas de treinamento e teste a partir de uma determinada época, destacada no gráfico da Figura 24 pela época 27. Nesse momento, a curva no conjunto de treinamento atinge 0.83, enquanto no conjunto de teste estabiliza em 0.82. A diferença de desempenho de 1% entre os dois conjuntos nesse ponto indica que o modelo tem capacidade de generalização melhor do que na abordagem sem o *fine-tuning*, apesar de apresentar menor *categorical accuracy* e ter um custo computacional maior para chegar neste desempenho.

Após a época 27, a curva de treinamento continua a subir, alcançando valores mais altos, enquanto a curva de teste começa a oscilar e até mesmo a declinar ligeiramente em algumas épocas. Esse comportamento é um sinal claro de *overfitting*, onde o modelo está se tornando excessivamente ajustado aos dados de treinamento, capturando ruídos e padrões específicos dos dados de treino que não se generalizam bem para novos dados. Isso é evidenciado pela falta de melhorias significativas na *categorical accuracy* de teste, apesar do aumento contínuo na curva do conjunto de treinamento.

A interpretação técnica dessas curvas sugere que, sem o *fine-tuning*, o modelo VGG-16, embora eficiente em termos de generalização, atinge um ponto de saturação onde a capacidade de aprendizado não supera os resultados obtidos a partir dos pesos pré-treinados. Dado o comportamento observado na curva de desempenho no conjunto de teste, com evidente estagnação no aprendizado, algumas estratégias podem ser consideradas para melhorar o desempenho ao treinar pesos do zero:

1. *Learning rate schedule*: Ajustar dinamicamente a taxa de aprendizado (*learning rate*) durante o treinamento com diferentes algoritmos de otimização pode ajudar o modelo a escapar de platôs, permitindo um aprendizado mais eficiente nas fases posteriores.
2. Regularização: Implementar mais técnicas de regularização, como *dropout*, *L2 regularization*, ou até mesmo técnicas mais avançadas como *adversarial training*, pode ajudar a prevenir *overfitting* e a manter a capacidade de generalização do modelo durante o treinamento prolongado.
3. Transferência parcial de conhecimento: em vez de treinar inteiramente do zero, uma abordagem híbrida onde apenas as últimas camadas são treinadas do zero, enquanto as primeiras camadas utilizam pesos pré-treinados, pode oferecer um bom equilíbrio entre aproveitar conhecimento existente e adaptar-se às especificidades do novo conjunto de dados.
4. Introdução de técnicas de aumento mais sofisticadas, como o uso de GANs (*Generative Adversarial Networks*) para gerar novos exemplos que mantenham a distribuição original dos dados, poderia reduzir o impacto negativo observado no aumento tradicional.
5. Filtrar os dados originais com técnicas mais avançadas, como a utilização de filtros baseados em aprendizado profundo, poderia melhorar a qualidade dos dados de entrada e, conseqüentemente, os resultados finais. Explorar outras arquiteturas de redes neurais, como ResNet ou EfficientNet, que possuem mecanismos internos de regularização, poderia ajudar a mitigar o *overfitting* e melhorar a capacidade de

generalização.

6. Revisar os hiperparâmetros do modelo, como a taxa de aprendizado e o número de épocas, poderia melhorar a estabilidade do treinamento, especialmente nos casos onde o aumento de dados está em uso.

4.1.1 Comparação dos resultados obtidos com CNN e *Random Forest*

Os resultados obtidos com a CNN mostraram uma melhoria em relação ao *Random Forest* (RF) quando observamos as métricas de *Overall Accuracy* (OA) e *categorical accuracy*. Enquanto o *Random Forest*, conforme reportado no trabalho de Sanches, *et al.*,(2018) apresentou uma OA de aproximadamente 80%, a CNN implementada conseguiu superar esta marca, atingindo na métrica equivalente 85% após a fase de *fine-tuning* no conjunto de dados original.

Essa diferença nos resultados pode ser atribuída principalmente à capacidade da CNN de capturar e explorar padrões espaciais complexos nas imagens, que o RF, mesmo com a inclusão do aspecto temporal, não foi capaz de explorar de maneira eficaz. A arquitetura convolucional é inerentemente mais adequada para lidar com dados espaciais, como imagens, pois pode aprender filtros que detectam bordas, texturas e formas que são cruciais para a classificação de padrões visuais.

A metodologia utilizada na implementação da CNN difere significativamente do RF, especialmente na forma como os dados foram processados e utilizados para a inferência. Enquanto o RF considerou o aspecto temporal, mesmo que este não tenha contribuído substancialmente para a melhora dos resultados, a abordagem com CNN focou na análise do *dataset* completo, desconsiderando explicitamente o aspecto temporal. Essa escolha se mostrou vantajosa devido a alguns fatores, como o fato de que a CNN é desenhada para capturar relações espaciais complexas que podem ser difíceis de modelar com técnicas baseadas em árvores de decisão, como o RF. Quando os dados são representados como imagens, as CNNs podem extrair características hierárquicas, que são essenciais para uma boa classificação, algo que o RF não faz de forma nativa.

O aspecto temporal, quando não adequadamente modelado, pode introduzir ruído nos dados, levando o modelo de RF a se ajustar a padrões que não são generalizáveis. Ao desconsiderar essa dimensão e utilizar o *dataset* completo, evitamos a possibilidade de *overfitting*, focando exclusivamente nos padrões espaciais relevantes para a classificação.

Desconsiderar o aspecto temporal pode ser uma boa alternativa quando o objetivo é

capturar padrões espaciais robustos que são consistentes ao longo do tempo. Se o aspecto temporal não adiciona uma variabilidade significativa ou não captura mudanças que afetam diretamente a classe de interesse, ele pode ser ignorado para simplificar a modelagem e melhorar a eficiência computacional.

Além disso, ao utilizar o *dataset* completo para as inferências, pode-se garantir que o modelo seja treinado com o máximo de variabilidade espacial disponível, o que pode levar a uma melhor generalização, especialmente em cenários onde as imagens apresentam variações significativas em termos de iluminação, ângulos de captura ou condições climáticas.

5 CONCLUSÕES

Os resultados apresentados neste estudo evidenciam a importância de um tratamento adequado dos dados para o sucesso de modelos de aprendizado de máquina, como a VGG-16. A análise das curvas de treinamento e validação revelou que o uso de dados pré-processados, com uma estratégia de aumento de dados (*data augmentation*), proporciona uma performance superior em termos de *categorical accuracy* e estabilidade do modelo em comparação a abordagens sem um pré-processamento e filtro de dados para manter a qualidade das amostras. Essa abordagem demonstrou não apenas uma capacidade de generalização, mas também uma eficácia em evitar o sobreajuste (*overfitting*), que é um dos maiores desafios ao se trabalhar com redes neurais profundas.

Por outro lado, o aumento de dados pode ser prejudicial ao desempenho do modelo quando não estabelecido um fator de parada automatizada do aprendizado, assim como métodos de regularização para evitar o ajuste exagerado do modelo ao conjunto de dados de treinamento. Quando não estabelecido um plano para evitar o *overfitting*, o modelo, em vez de focar nos padrões relevantes, pode acabar aprendendo ruídos ou características não generalizáveis, o que compromete a sua performance, como observado nas curvas da Figura 23 a partir da época 25, que indicaram um comportamento de estagnação do desempenho do teste em fases avançadas do treinamento, aumentando gradualmente a diferença percentual entre a *categorical accuracy*, de treino e validação. Adicionalmente, o aumento de dados deve ser cuidadosamente planejado para evitar a introdução de variações que não contribuem para o aprendizado do modelo. Estratégias de aumento de dados avançadas, como o uso de técnicas de *Generative Adversarial Networks* (GANs) para criar novos exemplos de alta qualidade ou o uso de transformações que preservem a integridade das características mais importantes dos dados, poderiam proporcionar ganhos adicionais na performance do modelo.

Além disso, a capacidade de generalização observada em todos os casos mostrou que o pré-processamento de geração de “janelas” de amostras nos talhões, especificado na metodologia, foi eficiente para a remoção de ruídos e realce de características importantes nos dados. Esta abordagem evita o redimensionamento dos dados utilizando-se interpolações que podem prejudicar a preservação das características das classes do *dataset*.

Os resultados obtidos em ambas as abordagens indicam que a escolha de uma rede neural convolucional (CNN) para a tarefa de classificação foi mais eficaz, quando utilizado todo o conjunto de dados, do que a utilização de um *Random Forest* (RF), mesmo sem a inclusão do aspecto temporal dos dados. Isso pode ser explicado pela capacidade intrínseca

das CNNs de capturar padrões espaciais complexos, que são fundamentais para o reconhecimento e classificação de imagens. Enquanto o RF é uma técnica poderosa e eficaz em muitos contextos, ele é limitado em sua habilidade de capturar e modelar essas complexidades espaciais, especialmente quando se trata de dados de imagens, onde as relações entre pixels em diferentes posições e direções são críticas para a tarefa de classificação. No entanto, é importante destacar que o uso de CNNs implica em um custo computacional significativamente maior, tanto em termos de tempo de treinamento quanto em recursos de hardware necessários. Apesar disso, o desempenho superior das CNNs justifica esse custo adicional, especialmente em aplicações onde a precisão e a robustez do modelo são prioridades.

No estudo comparativo, a não utilização do aspecto temporal dos dados na CNN, ao contrário do RF que tentou incorporar esse aspecto, mostrou-se uma decisão acertada. Embora o uso de dados temporais possa, em teoria, oferecer informações adicionais que poderiam melhorar a precisão do modelo, na prática, essa abordagem pode aumentar a complexidade do modelo sem necessariamente trazer melhorias significativas, especialmente quando o aspecto temporal não tem uma correlação forte com as características que estão sendo aprendidas. Neste contexto, a decisão de utilizar o *dataset* completo sem focar no aspecto temporal permitiu à CNN concentrar-se em capturar as características espaciais essenciais, resultando em uma performance superior.

6 PROPOSTA PARA TRABALHOS FUTUROS

Uma das principais direções para trabalhos futuros em continuação a este é a experimentação com arquiteturas de rede mais avançadas que oferecem um equilíbrio otimizado entre complexidade computacional e performance. Embora a VGG-16 tenha demonstrado bons resultados, outras arquiteturas, como as redes *ResNet* (*Residual Networks*) e *EfficientNet*, merecem investigação. A *ResNet*, com suas conexões residuais, permite o treinamento de redes muito profundas sem sofrer com problemas de degradação, o que poderia ser benéfico em conjuntos de dados mais complexos. Já a *EfficientNet*, que utiliza uma estratégia de escalonamento eficiente, pode proporcionar ganhos de precisão sem exigir um aumento proporcional na complexidade computacional. A avaliação dessas arquiteturas em conjunto com o *dataset* utilizado neste trabalho poderia revelar novas possibilidades de otimização.

Outra área promissora é a integração de modelos que consideram a dimensão temporal dos dados, especialmente em situações onde a sequência de eventos ou a evolução temporal das imagens pode fornecer informações relevantes para a tarefa de classificação. Neste contexto, a combinação de CNNs com redes neurais recorrentes (RNNs) ou redes do tipo LSTM (*Long Short-Term Memory*) poderia ser explorada. Estas arquiteturas são capazes de modelar dependências temporais, o que poderia ser benéfico para melhorar a precisão em *datasets* como o LEM Benchmark, onde as informações temporais são presentes na rotulagem da classificação. Embora o aspecto temporal tenha sido desconsiderado neste estudo com sucesso, futuras investigações poderiam avaliar se há cenários específicos nos quais a incorporação dessa dimensão poderia agregar valor.

O aprendizado por transferência, já parcialmente explorado neste trabalho, continua a ser uma área fértil para pesquisas futuras. Trabalhos futuros poderiam explorar de maneira mais profunda o *fine-tuning* de modelos pré-treinados em *datasets* ainda mais diversos ou de maior tamanho, especialmente aqueles que compartilham características semelhantes ao *dataset* em estudo. A adaptação de modelos que foram treinados em tarefas similares, mas com características de dados ligeiramente diferentes, pode proporcionar uma base sólida sobre a qual novas tarefas de classificação podem ser rapidamente desenvolvidas e refinadas, economizando tempo e recursos computacionais.

Os resultados deste trabalho mostraram que o aumento de dados é uma ferramenta válida, mas que deve ser usada com cautela. Trabalhos futuros poderiam investigar técnicas mais sofisticadas de aumento de dados, como a utilização de redes generativas adversariais

(GANs) para a geração de novos exemplos sintéticos que se assemelham aos dados reais. Outra abordagem seria a aplicação de técnicas de aprendizado auto-supervisionado, onde o modelo é treinado a aprender representações úteis dos dados sem a necessidade de rótulos. Essas representações poderiam, posteriormente, ser usadas para melhorar a performance de modelos supervisionados, como as CNNs.

Além disso, há uma oportunidade significativa para explorar o uso de redes neurais profundas em conjunto com dados multimodais, onde informações adicionais (por exemplo, texto, sensores, ou dados de séries temporais) são combinadas com imagens para fornecer um contexto maior para a classificação. Isso pode abrir novas fronteiras para a aplicação de redes neurais em problemas complexos e de grande escala.

O aprimoramento das técnicas de regularização também deve ser uma prioridade em futuras pesquisas. Métodos como *dropout*, *batch normalization*, e técnicas de *early stopping* podem ser combinados com estratégias de *ensemble learning* para criar modelos mais robustos e menos propensos ao *overfitting*. O *ensemble* de modelos, onde múltiplas instâncias do modelo são treinadas com variações nos dados ou nas arquiteturas e suas previsões são combinadas, tem o potencial de melhorar a performance.

Finalmente, a eficiência computacional é um aspecto que não pode ser negligenciado. Trabalhos futuros devem se concentrar em otimizar o uso de recursos computacionais durante o treinamento e a inferência. Isso pode incluir o desenvolvimento de técnicas de quantização e poda de modelos, que reduzem o tamanho e a complexidade dos modelos sem sacrificar o desempenho, e a exploração de novas tecnologias de hardware, como GPUs mais avançadas ou o uso de TPUs (*Tensor Processing Units*), para acelerar o treinamento.

Em resumo, o campo de visão computacional e aprendizado profundo continua a evoluir rapidamente, e há inúmeras oportunidades para expandir e aprimorar os métodos e técnicas explorados neste estudo. A adoção dessas novas abordagens e tecnologias permitirá a criação de modelos mais precisos, eficientes e aplicáveis a uma ampla gama de problemas no mundo real.

7 REFERÊNCIAS

ACHANCCARAY DIAZ, P. M. **Crop Recognition in Tropical Regions based on spatio-temporal conditional random fields from multi-temporal and multi-resolution sequences of remote sensing images**. 2019. 86 f. Tese (Doutorado em Engenharia Elétrica) - Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, 2019.

BENEDIKTSSON, J. A.; SWAIN, P. H.; ERSOY, O. K. **Neural network approaches versus statistical methods in classification of multisource remote sensing data**. IEEE Transactions on Geoscience and Remote Sensing, v. 28, n. 4, p. 540-552, 1990.

BREIMAN, L. **Random Forests**. Machine Learning, v. 45, n. 1, p. 5-32, 2001. Disponível em: <https://doi.org/10.1023/a:1010933404324>.

CALICIOGLU, O. *et al.* **The Future Challenges of Food and Agriculture: An Integrated Analysis of Trends and Solutions**. Sustainability, v. 11, n. 1, 2019.

CHAMORRO, J. *et al.* **A Many-to-Many Fully Convolutional Recurrent Network for Multitemporal Crop Recognition**. ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences, v. IV-2/W7, p. 25-32, 2019. Disponível em: <https://doi.org/10.5194/isprs-annals-iv-2-w7-25-2019>.

CHAVES, M. E. D.; SOARES, A. R.; MATAVELI, G. A. V.; SÁNCHEZ, A.; SANCHES, I. **A semi-automated workflow for LULC mapping via Sentinel-2 data cubes and spectral indices**. Automation, v. 4, n. 1, 2023. Disponível em: <https://doi.org/10.3390/automation4010007>. Acesso em: 21 ago. 2024.

CHEMBIAN, W. T. *et al.* **A high-performance infrastructure for remote sensing data applications using HPC paradigms**. International Journal of Electrical & Electronics Research, 2022. Disponível em: <https://doi.org/10.37391/ijeer.100255>. Acesso em: 21 ago. 2024.

CHU, D. A. *et al.* **Global monitoring of air pollution over land from the Earth Observing System-Terra Moderate Resolution Imaging Spectroradiometer (MODIS)**. *Journal of Geophysical Research: Atmospheres*, v. 108, n. 21, 2003.

CLIMATE-ADAPT. **Use of Remote Sensing in Climate Change Adaptation**. 2018. Disponível em: <https://climate-adapt.eea.europa.eu/en/metadata/adaptation-options/use-of-remote-sensing-in-climate-change-adaptation>.

DA SILVA, J. F. *et al.* **Land Use/ Cover (Lulc) Mapping In Brazilian Cerrado Using Neural Network With Sentinel-2 Data**. *FLORESTA*, v. 50, n. 3, p. 1430, 2020.

DEL'ARCO SANCHES, I. *et al.* **Campo Verde Database: Seeking to Improve Agricultural Remote Sensing of Tropical Areas**. *IEEE Geoscience and Remote Sensing Letters*, v. 15, n. 3, p. 369–373, 2018b.

DENG, J.; DONG, W.; SOCHER, R.; LI, L.-J.; LI, Kai; FEI-FEI, Li. **ImageNet: A large-scale hierarchical image database**. In: *IEEE CONFERENCE ON COMPUTER VISION AND PATTERN RECOGNITION, 2009, Miami. Proceedings...* Miami: IEEE, 2009. p. 248-255. DOI: 10.1109/CVPR.2009.5206848.

DENG, Z. *et al.* **Land use/land cover classification using time series Landsat 8 images in a heavily urbanized area**. *Advances in Space Research*, v. 63, n. 7, p. 2144-2154, 2019. Disponível em: <https://doi.org/10.1016/j.asr.2019.01.026>. Acesso em: 21 ago. 2024.

DUTRA, A. C. *et al.* **Influência Da Expansão Das Áreas De Soja Na Mudança De Cobertura Da Terra No Município De Luís Eduardo Magalhães, Bahia**. In: *ANAIS DO XIX SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 2019, Santos. Anais eletrônicos...* São José dos Campos, INPE, 2019.

ESA - EUROPEAN SPACE AGENCY. **Sentinel-2 user handbook**. 1. ed. Darmstadt: ESA, 2015. 64 p.

FAN, J. *et al.* **A GNN-RNN Approach for Harnessing Geospatial and Temporal Information: Application to Crop Yield Prediction**. *AAAI Conference on Artificial Intelligence*, 2021.

HEGAZI, E. H. *et al.* **Prediction of Soil Moisture Content from Sentinel-2 Images Using Convolutional Neural Network (CNN).** *Agronomy*, 2023.

HEYDARI, S. S.; MOUNTRAKIS, G. **Meta-analysis of deep neural networks in remote sensing: a comparative study of mono-temporal classification to support vector machines.** *ISPRS Journal of Photogrammetry and Remote Sensing*, v. 152, p. 192-210, 2019.

IMMITZER, M.; VUOLO, F.; ATZBERGER, C. **First experience with Sentinel-2 data for crop and tree species classifications in central Europe.** *Remote Sensing*, v. 8, n. 3, p. 166, 2016.

JL, S. *et al.* **3D Convolutional Neural Networks for Crop Classification with Multi-Temporal Remote Sensing Images.** *Remote Sensing*, 2018.

KENDUIYWO, B. K.; BARGIEL, D.; SOERGEL, U. **Higher Order Dynamic Conditional Random Fields Ensemble for Crop Type Classification in Radar Images.** *IEEE Transactions on Geoscience and Remote Sensing*, v. 55, n. 8, p. 4638–4654, 2017.

KHAN, S. D. *et al.* **Deep Hybrid Network for Land Cover Semantic Segmentation in High-Spatial Resolution Satellite Images.** *Information-an International Interdisciplinary Journal*, 2021.

KOSARAJU, C. *et al.* **Mirchi Crop Yield Prediction based on Soil and Environmental Characteristics using modified RNN.** 2023 IEEE International Students' Conference on Electrical, Electronics and Computer Science (SCEECS), p. 1–5, 2023.

KUKREJA, V. *et al.* **Crop Vigil: Automated Wheat Bunt Disease Multi-Classification with a CNN-RNN Hybrid Model and Attention Block.** 2023 14th International Conference on Computing Communication and Networking Technologies (ICCCNT), p. 1–6, 2023.

KUMARI, N.; MINZ, S. **Deep Residual SVM: A Hybrid Learning Approach to obtain High Discriminative Feature for Land Use and Land Cover Classification.** *Procedia Computer Science*, v. 218, p. 1454–1462, 2023.

LIN, S.-K. **Introduction to Remote Sensing.** Fifth Edition. Edited by James B. Campbell and Randolph H. Wynne, The Guilford Press, 2011; 662 pages. *Remote Sensing*, v. 5, n. 1, p. 282–283, 2013.

LU, D.; WENG, Q. **A survey of image classification methods and techniques for improving classification performance.** Journal of Remote Sensing, 2007.

MAO, M. *et al.* **In-Season Crop Type Detection by Combing Sentinel-1A and Sentinel-2 Imagery Based on the CNN Model.** Agronomy, 2023.

NDIKUMANA, E. *et al.* **Deep Recurrent Neural Network for Agricultural Classification Using Multitemporal SAR Sentinel-1 for Camargue, France.** Remote Sensing, v. 10, n. 8, p. 1217, 2018. Disponível em: <https://doi.org/10.3390/rs10081217>.

NIHARIKA; KUKREJA, V.; SHARMA, R.; SHARMA, V.; VERMA, A. **Precision diagnosis of wheat bunt disease: a hybrid CNN-RNN model for multi classification.** In: 2023 4th International Conference on Smart Electronics and Communication (ICOSEC), 2023, p. 992–997. Disponível em: <https://doi.org/10.1109/ICOSEC58147.2023.10276213>. Acesso em: 21 ago. 2024.

PEEL, M. C.; FINLAYSON, B. L.; MCMAHON, T. A. **Updated world map of the Köppen-Geiger climate classification.** Hydrology and Earth System Sciences, v. 11, n. 5, 2007.

PELLETIER, C. *et al.* **Temporal Convolutional Neural Network for the Classification of Satellite Image Time Series.** Remote Sensing, v. 11, n. 5, p. 523, 2019. Disponível em: <https://doi.org/10.3390/rs11050523>.

PRUDENTE, V. H. R. *et al.* **Utilização De Dados Sar Na Classificação De Espécies Agrícolas De Primeira E Segunda Safra.** In: ANAIS DO XIX SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 2019, Santos. São José dos Campos, INPE, 2019.

RESEARCH RABBIT. **Research Rabbit: The most powerful discovery app ever built for researchers,** 2024. Disponível em: <https://researchrabbitapp.com/home>. Acesso em: maio 2024.

SANCHES, I. D. *et al.* **Lem Benchmark Database For Tropical Agricultural Remote Sensing Application.** ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 2018.

SANCHES, I. D., *et al.* **First Results of the Lem Benchmark Database for Agricultural Applications.** *Int. Arch. Photogramm. Remote Sens. Spatial Inf. Sci.*, XLIII-B5-2020, p. 251–256, 2020. Disponível em: <https://doi.org/10.5194/isprs-archives-XLIII-B5-2020-251-2020>.

SHAFAPOURTEHRANY, M. *et al.* **Mapping Post-Earthquake Landslide Susceptibility Using U-Net, VGG-16, VGG-19, and Metaheuristic Algorithms.** *Remote Sens.*, v. 15, p. 4501, 2023. Disponível em: <https://doi.org/10.3390/rs15184501>.

SISHODIA, R. P.; RAY, R. L.; SINGH, S. K. **Applications of Remote Sensing in Precision Agriculture: A Review.** *Remote Sensing*, v. 12, n. 19, 2020.

SOTERRONI, Aline C. *et al.* **Expanding the Soy Moratorium to Brazil's Cerrado.** *Science Advances*, v. 5, n. 7, p. eaav7336, 2019. Disponível em: <https://doi.org/10.1126/sciadv.aav7336>.

TALUKDAR, S. *et al.* **Land-Use Land-Cover Classification by Machine Learning Classifiers for Satellite Observations—A Review.** *Remote Sensing*, v. 12, n. 7, 2020. Disponível em: <https://doi.org/10.3390/rs12071135>.

TAY, Aaron. **ResearchRabbit is out of Beta—My Review of This New Literature Mapping Tool.** Medium, 15 ago. 2021. Disponível em: <https://medium.com/a-academic-librarians-thoughts-on-open-access/researchrabbit-is-out-of-beta-my-review-of-this-new-literature-mapping-tool-3c593d061c63>.

THANH NOI, P.; KAPPAS, M. **Comparison of Random Forest, k-Nearest Neighbor, and Support Vector Machine Classifiers for Land Cover Classification Using Sentinel-2 Imagery.** *Sensors*, v. 18, n. 1, 2018.

THENKABAIL, P.; LYON, J. G.; HUETE, A. **Hyperspectral Remote Sensing of Vegetation.** Taylor & Francis Group, 2012.

VADREVU, K. P. **Introduction to Remote Sensing (Fifth Edition).** Edited by J. B. Campbell and R. H. Wynne. *Photogrammetric Record*, v. 28, p. 117-118, 2013. Disponível em: <https://doi.org/10.1111/phor.12021>.

WANG, Y. *et al.* **Building Extraction in Multitemporal High-Resolution Remote Sensing Imagery Using a Multifeature LSTM Network.** IEEE Geoscience and Remote Sensing Letters, v. 18, n. 9, p. 1645-1649, Sept. 2021. DOI: 10.1109/LGRS.2020.

WANG, Y. *et al.* **Remote Sensing Applications in Monitoring of Protected Areas.** Remote Sensing, v. 12, n. 9, 2020. Disponível em: <https://doi.org/10.3390/rs12091370>.

YANG, H. *et al.* **A Review of Remote Sensing for Water Quality Retrieval: Progress and Challenges.** Remote Sensing, v. 14, n. 8, 2022. Disponível em: <https://doi.org/10.3390/rs14081770>.

ZALLES, Viviana *et al.* **Rapid Expansion of Human Impact on Natural Land in South America Since 1985.** Science Advances, v. 7, n. 14, p. eabg1620, 2021. Disponível em: <https://doi.org/10.1126/sciadv.abg1620>.

ZEILER, Matthew D. **Adadelta: An Adaptive Learning Rate Method.** 2012. Disponível em: <https://arxiv.org/abs/1212.5701>.