

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ

JULIANO TIAGO RINALDI

**UMA NOVA ABORDAGEM PARA CLASSIFICAÇÃO E AVALIAÇÃO DE
CARBONO E NITROGÊNIO DE SOLOS POR ANÁLISE DE IMAGEM: UM
CASO DE ESTUDO COM LATOSSOLOS E CAMBISSOLOS**

PATO BRANCO

2025

JULIANO TIAGO RINALDI

**UMA NOVA ABORDAGEM PARA CLASSIFICAÇÃO E AVALIAÇÃO DE
CARBONO E NITROGÊNIO DE SOLOS POR ANÁLISE DE IMAGEM: UM
CASO DE ESTUDO COM LATOSSOLOS E CAMBISSOLOS**

**A New Approach for Classification and Assessment of Soil Carbon and
Nitrogen through Image Analysis: A Case Study with Oxisols and Inceptisols**

Trabalho de Pesquisa de Mestrado como requisito para obtenção do título de Mestre em Engenharia Elétrica e de Computação do Mestrado em Engenharia Elétrica e de Computação da Universidade Tecnológica Federal do Paraná.

Orientador(a): Prof. Dr. Dalcimar Casanova

Coorientador(a): Prof^ª. Dr^ª. Larissa Macedo dos Santos Tonial

PATO BRANCO

2025



[4.0 Internacional](https://creativecommons.org/licenses/by/4.0/)

Esta licença permite compartilhamento, remixe, adaptação e criação a partir do trabalho, mesmo para fins comerciais, desde que sejam atribuídos créditos ao(s) autor(es). Conteúdos elaborados por terceiros, citados e referenciados nesta obra não são cobertos pela licença.



Ministério da Educação
Universidade Tecnológica Federal do Paraná
Campus Pato Branco



JULIANO TIAGO RINALDI

UMA NOVA ABORDAGEM PARA CLASSIFICAÇÃO E AVALIAÇÃO DE CARBONO E NITROGÊNIO DE SOLOS POR ANÁLISE DE IMAGEM: UM CASO DE ESTUDO COM LATOSSOLOS E CAMBISSOLOS

Trabalho de pesquisa de mestrado apresentado como requisito para obtenção do título de Mestre Em Engenharia Elétrica E De Computação da Universidade Tecnológica Federal do Paraná (UTFPR). Área de concentração: Sistemas E Processamento De Energia.

Data de aprovação: 29 de Agosto de 2025

Dr. Dalcimar Casanova, Doutorado - Universidade Tecnológica Federal do Paraná

Dr. Andre Ricardo Backes, Doutorado - Universidade Federal de São Carlos (Ufscar)

Dr. Jefferson Tales Oliva, Doutorado - Universidade Tecnológica Federal do Paraná

Documento gerado pelo Sistema Acadêmico da UTFPR a partir dos dados da Ata de Defesa em 16/09/2025.

Dedico este trabalho, em primeiro lugar, a **Deus**; sem Ele, eu não estaria aqui. Com a mesma alegria, dedico-o também à minha **família**, que sempre foi meu alicerce nos momentos mais desafiadores. Este trabalho é, igualmente, uma forma de retribuir todo o carinho e a confiança que sempre me deram.

AGRADECIMENTOS

A Deus, fonte de sabedoria e força, dedico primeiramente minha gratidão. Sem Sua presença em minha vida, nada disso seria possível. Foi Ele quem me sustentou nos momentos mais desafiadores e me deu a perseverança necessária para concluir esta etapa.

À minha família, meu porto seguro, expresso todo o meu reconhecimento. À minha esposa, Loreni, que com paciência infinita e amor incondicional sempre me apoiou, assumindo tantas responsabilidades quando eu estava dedicado a este trabalho. Ao meu filho Elyan, que compreendeu a importância deste projeto, mesmo quando eu não pude dar-lhe toda a atenção que ele merecia. Ao meu pequeno Isaac, que chegou ao mundo durante este período e trouxe alegria e motivação, reforçando em meu coração que eu estava no caminho certo. À minha mãe, pelo apoio constante, pelo incentivo aos meus estudos e por acreditar em mim em todos os momentos. Vocês são minha maior inspiração.

Ao meu orientador, Professor Doutor Dalcimar Casanova, registro minha profunda gratidão pela dedicação, paciência e sabedoria com que guiou este trabalho. Sua expertise e direcionamento foram fundamentais em cada etapa desta jornada. Mais do que um orientador, foi um mentor que, com generosidade e atenção, me mostrou caminhos que enriqueceram não apenas este trabalho, mas também minha formação acadêmica e profissional.

Além dele, outros professores também tiveram papel essencial no desenvolvimento deste trabalho. Destaco, entre eles, Larissa M. Tonial (PPGAG), Heitor S. Lopes e Thiago H. Silva (CPGEI), e Marcelo Teixeira (PPGEEC), cujas contribuições foram de grande relevância. Ressalto, contudo, que a importância não se limita apenas a esses nomes, pois muitos outros docentes colaboraram direta ou indiretamente ao longo desta trajetória.

À Universidade Tecnológica Federal do Paraná (UTFPR), Campus Pato Branco, agradeço pela oportunidade de realizar este trabalho e pelo ambiente de aprendizado e crescimento que proporciona. Agradeço também a todos os professores com quem tive o privilégio de aprender, tanto em Pato Branco quanto os professores da UTFPR em Curitiba, que contribuíram diretamente para minha formação. Cada aula, cada conversa e cada orientação foram peças-chave neste processo.

Aos amigos e colegas que, de alguma forma, estiveram ao meu lado durante esta caminhada, expresso o mais sincero agradecimento. Seja pelo apoio, incentivo, palavras de motivação ou pela troca de conhecimento, vocês tornaram esta jornada ainda mais enriquecedora e marcante. Esta experiência foi muito mais significativa graças à convivência com pessoas tão especiais.

Por fim, agradeço a todos que, de alguma forma, contribuíram para a realização desta pesquisa, direta ou indiretamente. Vocês têm, cada um à sua maneira, um papel importante na conclusão deste trabalho e na construção deste momento tão especial em minha vida.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

RESUMO

A classificação precisa de solos e a predição de suas propriedades químicas, como o teor de carbono e nitrogênio, são fundamentais em diversas áreas, incluindo agricultura, geologia e gestão ambiental. Métodos tradicionais de classificação e análise de solos são frequentemente caros, demorados e dependem de profissionais especializados, o que limita sua escalabilidade, especialmente em regiões com terrenos diversos ou recursos limitados. Este estudo propõe duas abordagens complementares baseadas em análise de imagens e aprendizado profundo. No primeiro estudo, trabalhamos na classificação de solos, uma rede neural convolucional pré-treinada (ResNet50) alcançou uma acurácia balanceada de 93,73% no conjunto de teste, em contrapartida, aplicamos o método de combinação por votação majoritária às predições das janelas realizadas sobre o primeiro experimento, assim, este método resultou em uma impressionante acurácia balanceada de 100,0% na distinção entre Latossolos e Cambissolos, dois tipos de solo comuns no sul do Brasil. No segundo estudo, objetivamos aproximar as predições dos teores de carbono e nitrogênio dos valores reais medidos, para isso, foi utilizado um modelo EfficientNetV2-S ajustado para regressão, com dois experimentos realizados: um prevendo valores para janelas segmentadas das imagens e outro utilizando a mediana das predições das janelas para cada amostra de solo. Este último melhorou significativamente o desempenho, alcançando um R^2 de 0,7425 para o carbono e 0,7774 para o nitrogênio. Esses métodos oferecem alternativas mais rápidas, não destrutivas e escaláveis em relação às análises laboratoriais tradicionais, contribuindo para práticas agrícolas sustentáveis e facilitando a classificação e o manejo do solo em contextos com recursos limitados.

Palavras-chave: solo; carbono; nitrogênio; aprendizado por transferência; aprendizado profundo.

ABSTRACT

The accurate classification of soils and the prediction of their chemical properties, such as carbon and nitrogen content, are fundamental in several fields, including agriculture, geology, and environmental management. Traditional methods for soil classification and analysis are often expensive, time-consuming, and dependent on specialized professionals, which limits their scalability, especially in regions with diverse terrain or limited resources. This study proposes two complementary approaches based on image analysis and deep learning. In the first study, focused on soil classification, a pre-trained convolutional neural network (ResNet50) achieved a balanced accuracy of 93.73% on the test set. In contrast, applying a majoritarian voting method to the window predictions from the first experiment resulted in an impressive balanced accuracy of 100% in distinguishing between Latosols and Cambisols, two common soil types in southern Brazil. In the second study, we aimed to approximate the predictions of carbon and nitrogen content to the real measured values. For this, a fine-tuned EfficientNetV2-S model was used for regression, with two experiments conducted: one predicting values for segmented windows from the images and another using the median of the window predictions for each soil sample. The latter approach significantly improved performance, achieving an R^2 of 0.7425 for carbon and 0.7774 for nitrogen. These methods offer faster, non-destructive, and scalable alternatives to traditional laboratory analyses, contributing to sustainable agricultural practices and facilitating soil classification and management in resource-limited contexts.

Keywords: soil; carbon; nitrogen; transfer-learning; deep learning.

LISTA DE FIGURAS

Figura 1 – Tipos de Latossolo	13
Figura 2 – Tipos de Cambissolos	13
Figura 3 – Representação ilustrativa do sistema de captura de imagens.....	24
Figura 4 – Amostra de Latossolo	25
Figura 5 – Amostra de Cambissolo	25
Figura 6 – Exemplos das janelas para Latossolos e Cambissolos	26
Figura 7 – Método de particionamento <i>3-way hold-out</i>.....	29
Figura 8 – Exemplos de classificação - Experimento 1	31
Figura 9 – Classificação das amostras originais - votação majoritária	32

LISTA DE TABELAS

Tabela 1 – Coordenadas das localidades de coleta das amostras.....	24
Tabela 2 – Resumo do modelo baseado em EfficientNetV2-S.....	27
Tabela 3 – Matriz de confusão - Classificação: Experimento 1.....	30
Tabela 4 – Resultado da homogeneidade das janelas - Classificação: Experimento 1	31
Tabela 5 – Matriz de confusão - Classificação: Experimento 2.....	32
Tabela 6 – Métricas do Experimento 1 (janelas).....	33
Tabela 7 – Resumo de dados de Teste.....	34
Tabela 8 – Métricas do Experimento 2 (mediana das janelas).....	34
Tabela 9 – Resultados de carbono e nitrogênio Experimento 1 Amostras com me- lhores e piores predições sobre as janelas	35
Tabela 10 – Resultados de carbono e nitrogênio Experimento 2 Amostras com me- lhores e piores predições pela mediana	36

SUMÁRIO

1	INTRODUÇÃO	10
1.1	Objetivos do Trabalho	11
2	REFERENCIAL TEÓRICO	12
2.1	Solos Latossolos e Cambissolos	12
2.2	Métodos Tradicionais de Classificação e Análise de Solos	13
2.3	Inteligência Artificial	15
2.4	Aprendizado de Máquina	16
2.5	Aprendizado Profundo	17
2.6	Visão Computacional	18
2.7	Redes Neurais Convolucionais (CNNs)	19
3	TRABALHOS RELACIONADOS SOBRE CLASSIFICAÇÃO E ANÁLISE DE SOLOS	21
3.1	Classificação de Solos	21
3.2	Predição de Propriedades Químicas do Solo	23
4	MATERIAIS E MÉTODOS	24
4.1	Aquisição de Imagens	24
4.1.1	Sistema de Captura de Imagens	24
4.2	Análise Laboratorial	25
4.3	Particionamento de Amostras	25
4.4	Modelo de Transfer-Learning	26
4.4.1	Arquitetura dos Modelos	27
4.4.2	Treinamento dos Modelos	28
4.4.3	Seleção e Avaliação dos Modelos	28
5	RESULTADOS	30
5.1	Resultados da Classificação	30
5.1.1	Classificação: Experimento 1	30
5.1.2	Classificação: Experimento 2	32
5.2	Resultados da Regressão	32
5.2.1	Regressão: Experimento 1	32
5.2.2	Regressão: Experimento 2	33
5.3	Limitações do Estudo	37
6	CONCLUSÃO	38
6.1	Classificação de Solos	38
6.2	Predição de Carbono e Nitrogênio	38
6.3	Limitações e Perspectivas Futuras	39
6.4	Considerações Finais	39
6.5	Produções Técnicas e Científicas	40
6.6	Declaração sobre o uso de IA generativa e tecnologias assistidas por IA no processo de escrita	40
	REFERÊNCIAS	41

1 INTRODUÇÃO

O solo pode ser definido como a camada mais superficial da crosta terrestre, formada pela decomposição das rochas e por processos erosivos originados pelos ventos, chuvas e organismos vivos. Ele possui diferentes componentes como areia, silte e argila; cada um composto por elementos minerais e orgânicos (Santos *et al.*, 2018).

Existem muitos tipos de solos que são classificados de acordo com suas características físicas, químicas e biológicas. Segundo o Sistema Brasileiro de Classificação de Solos (SiBCS), há 13 classes de solos no Brasil. Dentre essas, os Latossolos e Cambissolos (equivalentes a *Oxisols (Hapludox, etc)* e *Inceptisols (principalmente Dystrudepts)* na Taxonomia dos EUA (United States Soil Conservation Service, 1975)) são frequentemente observados em superfícies tropicais nas regiões Sudeste e Sul do Brasil (Santos *et al.*, 2018). A cor do solo influencia fortemente esse sistema de classificação, com inferências sobre a gênese do solo, fertilidade natural, textura e manejo (Andrade *et al.*, 2020).

A classificação correta dos solos é crucial em diversas áreas do conhecimento, como agricultura, engenharia, geologia e ecologia. Na agricultura, a classificação precisa do solo pode resultar em uma seleção mais eficiente de fertilizantes e práticas de manejo, levando a maiores produtividades e redução de custos. Na engenharia, a classificação correta dos solos é essencial para a construção de fundações seguras e estruturas sustentáveis. Na geologia e ecologia, a classificação adequada do solo é necessária para entender a distribuição de espécies vegetais e animais, bem como para compreender os processos de formação do solo e da geologia (Brady; Weil, 2016).

De acordo com Siqueira *et al.* (2016), o processo de classificar tipos de solos, estimar propriedades químicas e físicas em uma determinada área e geocodificar essas informações, também conhecido como levantamento pedológico, pode ser extrapolado e utilizado para diferentes finalidades: desde a verificação da qualidade dos recursos do solo de um país ou região até o planejamento sustentável do uso da terra. No entanto, esse processo envolve profissionais treinados e pesquisas de campo e laboratoriais. Geralmente, são abertas trincheiras para análise morfológica dos perfis de solo, e amostras indeformadas são coletadas para determinação de atributos físicos e químicos essenciais para a classificação taxonômica. Esses estudos incluem notas de observação, compilação de dados, análises e interpretações das características físicas, químicas, mineralógicas, biológicas e morfológicas dos solos, com o objetivo de classificá-los. Esses métodos tradicionais de classificação de solos são custosos e não possuem boa escalabilidade, especialmente em locais com topografia diversificada.

Considerando a complexidade dos métodos tradicionais de classificação e análise de solos e a importância dessas informações, existe uma demanda significativa não atendida. Uma possível forma de suprir essa demanda seria criar um sistema automatizado de análise de solos que permita a classificação e análise de características básicas dos solos de forma rápida (em minutos ou poucas horas), utilizando imagens do solo. Esse processo poderia ser acompanhado

por um especialista da área para aceitar a classificação ou solicitar análises mais detalhadas em caso de dúvidas ou análises inconclusivas.

Seguindo essa ideia, este trabalho propõe um novo método de classificação e análise de dois indicadores químicos de solos (carbono e nitrogênio) utilizando métodos modernos de visão computacional. Para esse propósito, um modelo de classificação foi treinado utilizando imagens de porções de terrenos de dois tipos de solos, Latossolos e Cambissolos. As amostras desses solos foram previamente classificadas por um especialista da área que considerou a análise visual, bem como as propriedades químicas e físicas dos solos.

Essa abordagem, em conjunto com um especialista da área, pode ajudar a acelerar a classificação e análise de solos, reduzir custos e viabilizar novas aplicações, especialmente em países em desenvolvimento, onde os recursos podem ser escassos.

1.1 Objetivos do Trabalho

O objetivo deste trabalho é desenvolver e avaliar um método automatizado de classificação e análise de solos utilizando métodos de visão computacional.

1. **Classificação de Solos:** O primeiro objetivo é desenvolver um modelo de *deep learning* para classificar Latossolos e Cambissolos com base em imagens de solo. Para isso, no primeiro experimento foi utilizada uma rede neural convolucional pré-treinada (ResNet50), que permite identificar padrões texturais e cromáticos de forma eficiente. O melhor modelo alcançou uma acurácia balanceada de até 93,73% nas janelas extraídas das amostras originais, já no segundo experimento, aplicamos como técnica votação pela maioria, resultando na junção de janelas extraídas para cada amostra original definida pela votação, com isso, atingimos a incrível marca de 100% de acertos, demonstrando seu potencial para acelerar e reduzir os custos da classificação de solos.
2. **Predição de Carbono e Nitrogênio:** O segundo objetivo é estimar os teores de carbono e nitrogênio nos solos, utilizando das mesmas imagens RGB, porém, com redes neurais ajustadas para regressão. Dentro deste objetivo, novamente houveram dois experimentos, para o primeiro, foi utilizado o modelo EfficientNetV2-S aplicando *transfer-learning* com algumas camadas adicionais, tendo como resultado de baixa performance: R^2 de 0,5012 para carbono e 0,5201 para nitrogênio, em contrapartida, no segundo experimento, calculamos a janela que representa a mediana, obtendo uma visível melhora performática: R^2 0,7425 para carbono e 0,7774 para nitrogênio, destacando-se como uma alternativa rápida e não destrutiva aos métodos laboratoriais tradicionais.

Essas abordagens automatizadas oferecem soluções promissoras para superar as limitações dos métodos convencionais, contribuindo para práticas agrícolas mais sustentáveis e uma melhor compreensão das propriedades dos solos.

2 REFERENCIAL TEÓRICO

Nesse capítulo são abordados conceitos essenciais relacionados aos solos Latossolos e Cambissolos, propriedades químicas como carbono e nitrogênio, métodos tradicionais de análise de solos e, por fim, as tecnologias computacionais empregadas para classificação e predição de propriedades do solo.

2.1 Solos Latossolos e Cambissolos

Dentre os solos do Brasil, os Latossolos e Cambissolos ocupam uma vasta extensão territorial (Silva *et al.*, 2022) e, portanto, são as principais classes de solos em diversos ambientes, especialmente na América do Sul (Skorupa *et al.*, 2017). Neste trabalho, estudamos esses solos devido à sua importância particular na região Sul do Brasil, especificamente nos Estados do Paraná e de Santa Catarina, onde ambos são predominantes.

Os Latossolos geralmente apresentam textura relativamente uniforme, variando de média a muito argilosa. A estrutura consiste em agregados granulares dispostos de tal forma que deixam grande espaço poroso, o que garante alta permeabilidade, mesmo quando são muito argilosos. São ricos em cálcio e fósforo, mas apresentam baixo teor de nutrientes, o que demanda suplementação na agricultura. No entanto, são economicamente produtivos para o cultivo de culturas como soja, milho, sorgo e algodão.


Além disso, os Latossolos possuem propriedades que favorecem a produção, como relevo suavemente ondulado (o que facilita o trabalho de máquinas agrícolas), baixa suscetibilidade à erosão hídrica e boas propriedades de permeabilidade (Suddarth *et al.*, 2019).

Esses solos passaram por diversas transformações durante seu processo de formação e, tipicamente, são pouco espessos, apresentam textura de arenosa a franca e estrutura blocada a granular (Gonçalves; Lohe; Campos, 2015). Com relação à cor, a Figura 1 mostra que esses solos podem ser avermelhados ou amarelados.

Os Cambissolos são solos frágeis amplamente utilizados para a agricultura e pecuária (Silva *et al.*, 2022); normalmente ocorrem em relevos mais acidentados e são naturalmente densos e rasos, dificultando o crescimento das raízes em camadas mais profundas do solo (Pinto *et al.*, 2016). A Figura 2 mostra uma leve variação entre os horizontes dos Cambissolos, especialmente em termos de cor e textura.

Além disso, os Cambissolos são, em sua maioria, de origem mineral e, portanto, possuem boa reserva de nutrientes. Conseqüentemente, são bons solos para o cultivo de culturas, pois, mesmo com baixa fertilidade natural e localizados em áreas com relevo acentuado, quando manejados corretamente, podem promover alta produtividade agrícola (Silva *et al.*, 2022).


Figura 1 – Tipos de Latossolo



(a) Vermelho, (b) Vermelho-amarelo, (c) Amarelo, (d) Marrom

Fonte: Fontana, Balieiro e Pereira (2020).

Figura 2 – Tipos de Cambissolos



(a) húmico, (b) háplico, (c) flúvico

Fonte: Fontana, Balieiro e Pereira (2020).

2.2 Métodos Tradicionais de Classificação e Análise de Solos

Ao longo do anos foram desenvolvidas várias metodologias e procedimentos para padronizar a classificação e análises do solo devido sua importância, com intuito de melhor aproveitamento para manejo agrícola, ambiental e científico. A seguir apresentamos os principais métodos tradicionais conhecidos:

O Sistema Brasileiro de Classificação de Solos (SiBCS) é a principal referência nacional para identificação e categorização dos solos, sendo utilizado para planejamento agrícola e conservação ambiental. O método envolve a descrição detalhada do perfil do solo em campo, utilizando ferramentas como perfuradores de terra e cartas de cores de Munsell. Após a coleta de amostras, análises laboratoriais complementam a classificação, permitindo a inserção

do solo dentro da hierarquia estabelecida pelo SiBCS, que vai desde ordens até subgrupos, garantindo precisão na caracterização pedológica (Santos *et al.*, 2018).

Em métodos americanos, destacamos a *Soil Taxonomy*, desenvolvido pelo *United States Department of Agriculture* (USDA), sendo seu sistema de classificação de solo amplamente utilizado internacionalmente, no qual fornece uma abordagem padronizada baseada em propriedades observáveis e mensuráveis do solo. O processo inicia-se com a identificação dos horizontes diagnósticos, levando em conta características como textura, cor e estrutura. Com base nesses atributos, o solo é classificado dentro de uma estrutura hierárquica que inclui ordens, subordens, grandes grupos, subgrupos, famílias e séries, permitindo a comparação entre diferentes solos do mundo (Department, 2014).

No âmbito internacional em parceria com a Organização das Nações Unidas (ONU), destaca-se a *World Reference Base for Soil Resources* (WRB), desenvolvido e mantido pela *Food and Agriculture Organization* (FAO) e em colaboração com a *International Union of Soil Sciences* (IUSS) para harmonizar a classificação de solos em escala global. O método utiliza um sistema de grupos de referência de solo *Reference Soil Groups* (RSGs) e qualificadores diagnósticos que descrevem propriedades específicas do solo. A abordagem do WRB permite maior flexibilidade na categorização dos solos, facilitando sua adaptação a diferentes regiões e tipos de uso, sendo amplamente empregada em pesquisas científicas e estudos comparativos globais (Wrb, 2022).

Se tratando de análises química do solo, destacamos alguns dos métodos mais conhecidos como o Walkley-Black (combustão úmida): é uma técnica clássica para determinar o teor de carbono orgânico no solo por oxidação úmida. O procedimento utiliza dicromato de potássio e ácido sulfúrico para oxidar a matéria orgânica, e o carbono não reagido é posteriormente quantificado por titulação com sulfato ferroso. Esse método é amplamente aplicado devido à sua simplicidade e custo reduzido, sendo adequado para solos com teores moderados de matéria orgânica, embora possa subestimar o carbono em solos muito ricos nesse elemento (Santos *et al.*, 2018).

Considerado o método mais preciso: combustão seca, realizado por analisadores elementares, determina a quantificação de carbono total e nitrogênio total no solo. A amostra é queimada a temperaturas elevadas, convertendo o carbono em dióxido de carbono (CO₂) e o nitrogênio em gás nitrogênio (N₂), que são quantificados por espectrometria de massa ou condutividade térmica. Esse método apresenta alta precisão e permite a análise simultânea de carbono e nitrogênio, sendo comumente utilizado em estudos ambientais e de fertilidade do solo (Teixeira *et al.*, 2017).

Amplamente utilizado, o método de Kjeldahl tem objetivo na determinação do teor de nitrogênio total em amostras de solo e outras matrizes orgânicas. Esse método envolve três etapas principais: digestão, destilação e titulação. Na digestão, o material é tratado com ácido sulfúrico concentrado na presença de um catalisador, resultando na conversão do nitrogênio orgânico em sulfato de amônio. Em seguida, na etapa de destilação, esse composto é transformado em amônia pela adição de uma base forte, como hidróxido de sódio, e destilado em uma

solução ácida receptora. Por fim, a amônia é quantificada por titulação com um ácido padrão. Embora seja um método confiável, ele não diferencia nitrogênio orgânico de nitrogênio inorgânico e pode ser menos preciso para solos com altos teores de nitratos, sendo frequentemente complementado por outras técnicas analíticas (Dieckow *et al.*, 2007).

Se mostrando em evidência por não ser um método destrutivo, a espectroscopia no infravermelho próximo (NIR – *Near Infrared Reflectance*) tem se destacado como uma metodologia para a quantificação de atributos químicos do solo, em especial os teores de carbono e nitrogênio. Essa técnica se baseia na absorção seletiva de radiação eletromagnética por ligações químicas específicas presentes nos compostos orgânicos do solo (Felix, 2015).

2.3 Inteligência Artificial

Em um trabalho que está abaixo do guarda chuva da inteligência artificial (IA), é importante conhecer um pouco de sua história e o que ela aborda, portanto, a IA surgiu na década de 1950, quando pioneiros da ciência da computação começaram a questionar se as máquinas poderiam pensar. O objetivo da IA é automatizar tarefas intelectuais normalmente realizadas por humanos. Inicialmente, a IA não estava intrinsecamente ligada ao aprendizado; por exemplo, os primeiros programas de xadrez funcionavam com regras codificadas por programadores e não eram considerados aprendizado de máquina. O paradigma dominante nas primeiras décadas da IA foi a IA simbólica, que buscava alcançar a inteligência humana através da criação manual de um grande conjunto de regras explícitas para manipular o conhecimento armazenado em bancos de dados.

Embora a IA simbólica fosse eficaz para problemas lógicos bem definidos, como jogar xadrez, mostrou-se intratável para problemas mais complexos e ambíguos, como classificação de imagens, reconhecimento de fala ou tradução de linguagem natural. Essa limitação levou ao surgimento de uma nova abordagem: a aprendizagem de máquina (2.4 Aprendizagem de Máquina). Em contraste com a programação explícita de regras, a aprendizagem de máquina permite que os computadores aprendam a partir de dados, identificando estruturas estatísticas em exemplos relevantes para uma tarefa e, eventualmente, formulando suas próprias regras para automatizá-la.

Dentro do campo da aprendizagem de máquina, surgiu o aprendizado profundo (2.5 Aprendizagem Profundo). O aprendizado profundo se distingue por utilizar redes neurais com múltiplas camadas (de onde deriva o termo profundo) para aprender representações de dados. Essa abordagem provou ser particularmente eficaz em tarefas complexas de percepção, levando a avanços significativos em áreas como visão computacional (2.6 Visão Computacional) e processamento de linguagem natural. O sucesso do aprendizado profundo trouxe consigo um novo período de intenso interesse, investimento e divulgação na área de IA.

É crucial reconhecer que, apesar do entusiasmo em torno da IA, é importante distinguir o sinal do ruído e discernir entre os desenvolvimentos transformadores e a publicidade exagerada. Embora a IA ainda não tenha alcançado todo o seu potencial geral, a visão de longo prazo

é que a IA será aplicada a quase todos os processos que compõem nossa sociedade e nossas vidas, de forma semelhante ao impacto da internet. O aprendizado profundo, em particular, já demonstrou um enorme valor econômico e tecnológico, permitindo avanços como reconhecimento de fala em nível humano, assistentes inteligentes e tradução automática aprimorada (Chollet, 2021).

2.4 Aprendizado de Máquina

Sendo definido como um algoritmo capaz de aprender através de grande massa de dados como entrada, e em sua saída, predizendo os resultados com alta assertividade, permite abordar tarefas complexas demais para serem resolvidas com programas fixos projetados por humanos. O principal desafio em aprendizado de máquina é a generalização, ou seja, a capacidade de um modelo ter um bom desempenho em dados novos e não vistos anteriormente, e não apenas nos dados de treinamento. Os algoritmos de aprendizado de máquina geralmente funcionam melhor quando sua capacidade (a habilidade de aprender uma ampla variedade de funções) é adequada para a verdadeira complexidade da tarefa e a quantidade de dados de treinamento fornecida. Modelos com capacidade insuficiente sofrem *underfitting* (incapacidade de capturar a complexidade dos dados), enquanto modelos com capacidade excessiva podem sofrer *overfitting* (memorização dos dados de treinamento, resultando em mau desempenho em novos dados).

Para formalizar as noções de generalização, *underfitting* e *overfitting*, a estatística fornece ferramentas como estimadores, bias (viés) e variância. A estimação pontual busca fornecer a melhor previsão única de uma quantidade de interesse, que pode ser um parâmetro ou uma função inteira. Os algoritmos de aprendizado de máquina podem ser amplamente divididos em aprendizado supervisionado, aprendizado não supervisionado, aprendizado semi-supervisionado e aprendizado por reforço. No aprendizado supervisionado, o algoritmo aprende a mapear entrada(s) para saída(s) com base em pares de entrada-saída rotulados, como exemplo este próprio trabalho, enquanto no aprendizado não supervisionado, o algoritmo aprende padrões e estruturas nos dados de entrada não rotulados, como exemplo fazer agrupamento de dados em um grande conjunto de dados (Goodfellow; Bengio; Courville, 2016), já no aprendizado semi-supervisionado é uma abordagem situada entre a aprendizagem supervisionada e a não supervisionada, de uso relevante quando dados não rotulados são abundantes como processamento de imagens e bioinformática (Chapelle; Scholkopf; Zien eds., 2009). O aprendizado por reforço utiliza um agente que aprende a otimizar seu comportamento através da interação direta com um ambiente incerto, objetivando maximizar um sinal de recompensa numérico cumulativo ao longo do tempo, o que ele faz descobrindo quais ações produzem mais recompensas por meio de tentativas e erros (Sutton; Barto, 2015).

2.5 Aprendizado Profundo

O aprendizado profundo é uma vertente específica do aprendizado de máquina que se destaca pela sua capacidade de aprender representações de dados em múltiplos níveis de abstração. Fundamentalmente, um algoritmo de aprendizado de máquina aprende com dados, de tal forma que seu desempenho em uma determinada classe de tarefas melhora com a experiência. O aprendizado profundo se diferencia ao construir essas representações através da composição de muitas funções mais simples, organizadas em uma hierarquia profunda. A motivação para o desenvolvimento do aprendizado profundo reside na dificuldade dos algoritmos tradicionais de aprendizado de máquina em generalizar bem em tarefas complexas de inteligência artificial, especialmente ao lidar com dados de alta dimensionalidade. O desafio da **maldição da dimensionalidade** surge quando o número de possíveis configurações dos dados de entrada cresce exponencialmente com o número de dimensões, tornando a generalização para novos exemplos exponencialmente mais difícil. A abordagem do aprendizado profundo busca superar essas limitações assumindo que os dados são gerados pela composição de fatores ou características em múltiplos níveis de uma hierarquia, permitindo ganhos exponenciais na relação entre o número de exemplos e a quantidade de regiões que podem ser distinguidas.

A trajetória histórica do aprendizado profundo pode ser vista em três ondas principais de desenvolvimento. A primeira onda, nos anos 1940-1960, conhecida como cibernética, focou em modelos computacionais inspirados no aprendizado biológico e culminou nos primeiros modelos de redes neurais, como o *perceptron*. A segunda onda, nos anos 1980-1990, chamada de conexismo, trouxe avanços como o algoritmo de retropropagação para treinar redes neurais com uma ou duas camadas ocultas. A onda atual, que começou por volta de 2006, popularizou o termo aprendizado profundo e se caracteriza pela capacidade de treinar redes neurais com muito mais camadas do que anteriormente possível. O sucesso recente do aprendizado profundo também se deve ao aumento significativo no tamanho dos conjuntos de dados disponíveis e ao poder computacional cada vez maior.

No cerne do aprendizado profundo está a ideia de modelos profundos, que consistem na composição de múltiplas camadas de funções, onde a saída de uma camada serve como entrada para a próxima. A profundidade de um modelo é dada pelo comprimento da cadeia dessas composições. Cada camada oculta em uma rede profunda aprende a extrair características cada vez mais abstratas dos dados de entrada. O processo de aprendizado envolve a otimização dos parâmetros do modelo de forma a minimizar uma função de custo que mede o quão bem o modelo se ajusta aos dados de treinamento.

É precisamente essa capacidade de aprender representações hierárquicas que impulsionou sua aplicabilidade de alto impacto em uma vasta gama de domínios. Um exemplo proeminente é o reconhecimento de fala, onde redes neurais profundas são componentes cruciais de sistemas utilizados por grandes empresas. Outra área de impacto significativo é a tradução automática, em que modelos de aprendizado profundo têm demonstrado avanços notáveis na conversão de sequências de símbolos de uma língua para outra. O processamento de linguagem

natural (NLP) em geral se beneficia enormemente do aprendizado profundo, com aplicações em modelagem de linguagem, análise de texto e compreensão semântica. Em tarefas de NLP com vocabulários extensos, o aprendizado profundo enfrenta desafios relacionados à representação de distribuições de probabilidade sobre um grande número de palavras (Chollet, 2021).

2.6 Visão Computacional

Impulsionada pelos algoritmos de aprendizado profundo, emergiu como um campo de grande relevância na tecnologia e ciência da computação, com potencial para revolucionar áreas como a automotiva, bancária e de segurança. Inicialmente, os cientistas buscaram estruturas que pudessem replicar a importância das conexões entre as características de entrada, levando ao surgimento das redes neurais. Em uma rede neural simples, cada neurônio em uma camada está conectado a cada neurônio da camada anterior, e o aumento da profundidade da rede impacta significativamente o tempo de treinamento e a qualidade da predição. Um desafio inicial na análise de imagens era o grande número de pesos a serem calculados para cada pixel. Foi em 1989, então que **Yann LeCun** introduziu pela primeira vez o conceito das redes neurais convolucionais (CNNs), comentado adiante no item (2.7 Redes Neurais Convolucionais (CNNs)); ele, junto de sua equipe apresentou os primeiros passos da CNN através do artigo *Backpropagation Applied to Handwritten Zip Code Recognition* (Lecun *et al.*, 1989). O conceito ganhou força, teve aprimoramentos, e com o sucesso, se tornou o núcleo de um novo campo na visão computacional. O desenvolvimento da comunidade de aprendizado de máquina também foi impulsionado pela disponibilidade de conjuntos de dados online e competições como o *ImageNet*, uma colaboração entre Stanford e Princeton que se tornou um *benchmark* com aproximadamente quatorze milhões de imagens rotuladas, inicialmente focada na classificação de imagens, mas que evoluiu para a detecção de objetos e segmentação de imagens.

No domínio da classificação de imagens, vários modelos foram propostos para solução, contudo, foi com CNN que capturou a atenção pública através do *AlexNet*, que alcançou uma taxa de erro *top-five* de 15.3% no desafio ImageNet, superando significativamente os resultados anteriores. O *AlexNet*, considerado hoje uma arquitetura relativamente simples, consistia em cinco camadas convolucionais consecutivas, camadas de *pooling* e três camadas totalmente conectadas. Após esse marco, os cientistas buscaram explorar sequências mais profundas de camadas convolucionais. Em 2014, foi lançado o modelo VGG16, com dezesseis camadas convolucionais, múltiplas camadas de *pooling* e três camadas totalmente conectadas ao final. Uma característica importante do VGG16 era a combinação de múltiplas camadas convolucionais com funções de ativação ReLU para criar transformações não lineares, permitindo que os modelos aprendessem padrões mais complexos, além da introdução de filtros 3x3, que se mostraram capazes de reconhecer os mesmos padrões que filtros maiores com menos parâmetros. O VGG16 alcançou uma taxa de erro de 7.3% no desafio ImageNet. No mesmo ano, em 2014, nasceu o *Inception V1*, com 22 camadas utilizando módulos de inicialização para um total de mais de 50 camadas, alcançando uma taxa de erro de 6.7% no ImageNet. Versões subse-

quentes, como o *Inception V2* e *Inception V3*, refinaram a arquitetura, reduzindo o número de parâmetros e melhorando a precisão, com o *Inception V3* atingindo a menor taxa de erro de 3.58% usando dados de teste do ImageNet.

Além da classificação de imagens, a visão computacional aborda tarefas mais complexas como a detecção de objetos e a segmentação semântica. Enquanto a classificação de imagens atribui uma única categoria à imagem, a detecção de objetos identifica múltiplos objetos relevantes em uma única imagem, localizando-os. Os primeiros modelos de detecção de objetos intuitivamente começavam com uma busca por regiões e depois realizavam a classificação. Com o avanço da técnica, modelos como o YOLO prevê simultaneamente as regiões dos objetos e suas probabilidades de classe em uma única avaliação, permitindo a previsão em tempo real. Já a segmentação semântica tem como objetivo classificar cada pixel de uma imagem em uma categoria correspondente a um objeto ou parte dele, buscando uma compreensão mais profunda do conteúdo visual, modelos como o ParseNet e o EncNet, buscaram incorporar o contexto global da imagem para melhorar a precisão da segmentação.

O campo da visão computacional alcançou um progresso notável em um curto período de tempo. Há menos de uma década, a distinção entre categorias básicas como cachorro e gato era considerada um grande avanço. Hoje, redes generativas podem até mesmo criar vídeos realistas, demonstrando a rápida evolução da área. Os pesquisadores agora exploram a Inteligência Artificial Geral, com sistemas como as redes de *Neural Architecture Search* (NAS) capazes de gerar arquiteturas de rede que superam o desempenho de modelos projetados por humanos na classificação de imagens. Além disso, algoritmos de aprendizado por reforço impulsionados pela visão computacional demonstram a capacidade de dominar jogos complexos em prazos surpreendentemente curtos. A inteligência artificial, e a visão computacional como um de seus pilares, representa um marco no desenvolvimento da civilização humana, com o potencial de influenciar significativamente o desenvolvimento tecnológico e melhorar a qualidade de vida. Os avanços atuais em visão computacional, desde a classificação básica até a compreensão complexa de cenas, indicam um futuro promissor para a área e suas aplicações multifacetadas (Tarsala; Kasprzyk, 2021).

2.7 Redes Neurais Convolucionais (CNNs)

Representam uma evolução significativa no campo do aprendizado de máquina, particularmente no que diz respeito a tarefas de reconhecimento de padrões impulsionadas por imagens. Uma das características mais notáveis das CNNs é sua arquitetura precisa e simplificada, em sua essência, as CNNs são compostas por neurônios que se auto-otimizam através do aprendizado, onde cada neurônio recebe uma entrada e executa uma operação, como um produto escalar seguido por uma função não linear. A principal distinção reside no fato de que as CNNs são primordialmente aplicadas no campo do reconhecimento de padrões em imagens, permitindo a codificação de características específicas da imagem em sua arquitetura.

A arquitetura das CNNs é especificamente projetada para processar imagens, com os neurônios organizados em três dimensões: a dimensionalidade espacial da entrada (altura e largura) e a profundidade (cores). É importante distinguir a profundidade do número total de camadas; ela se refere à terceira dimensão de um volume de ativação. Os neurônios em qualquer camada de uma CNN se conectam apenas a uma pequena região da camada precedente, denominada campo receptivo do neurônio. Uma arquitetura típica de CNN é composta por três tipos principais de camadas: camadas convolucionais, camadas de *pooling* e camadas totalmente conectadas. O empilhamento dessas camadas forma a arquitetura da CNN.

A camada convolucional desempenha um papel fundamental no funcionamento das CNNs, com seus parâmetros centrados no uso de *kernels* aprendíveis. Esses *kernels* são geralmente pequenos em dimensionalidade espacial, mas se estendem por toda a profundidade da entrada. Quando os dados entram em uma camada convolucional, a camada convolve cada filtro pela dimensionalidade espacial da entrada para produzir um mapa de ativação 2D. À medida que o *kernel* desliza pela entrada, o produto escalar é calculado para cada valor no *kernel*. Através desse processo, a rede aprende *kernels* que disparam quando detectam uma característica específica em uma determinada posição espacial da entrada, e essas detecções são conhecidas como ativações. Cada *kernel* terá um mapa de ativação correspondente, e esses mapas são empilhados ao longo da dimensão da profundidade para formar o volume de saída completo da camada convolucional (O'shea; Nash, 2015).

3 TRABALHOS RELACIONADOS SOBRE CLASSIFICAÇÃO E ANÁLISE DE SOLOS

A classificação e a análise de propriedades químicas do solo são temas amplamente estudados, com diferentes abordagens propostas na literatura recente. Este trabalho se diferencia por combinar objetivos de classificação de Latossolos e Cambissolos com a predição de teores de carbono e nitrogênio, utilizando amplas técnicas dentro da inteligência artificial. A seguir, são revisados os principais trabalhos relacionados, organizados de acordo com os dois objetivos.

3.1 Classificação de Solos

No Brasil, a classificação dos solos baseia-se em critérios estabelecidos pela SiBCS com autoria de Santos *et al.* (2018), os quais consideram as propriedades físicas, químicas e biológicas do solo. O processo de classificação envolve uma avaliação *in situ*, na qual as características do solo são observadas e descritas detalhadamente em campo. Além dessa avaliação no local, são necessárias análises laboratoriais, o que requer a coleta de uma amostra representativa do solo para a caracterização química e física (Andrade *et al.*, 2020; Vasques *et al.*, 2014).

O processo se inicia com a identificação do perfil do solo, por meio da abertura de uma trincheira que pode atingir até 2 m de profundidade (em solos profundos), a partir da qual é possível observar os horizontes do solo. Em seguida, é feita uma avaliação das propriedades físicas do solo, incluindo textura, estrutura, cor e outras características. Posteriormente, são coletadas amostras indeformadas para determinação de atributos químicos e físicos em laboratório. Ao final do procedimento, todas as informações são compiladas, e a interpretação dos dados permite classificar o solo de acordo com (Santos *et al.*, 2018), utilizando critérios morfológicos, físicos, químicos e mineralógicos.

O processo manual de classificação dos tipos de solos pode ser trabalhoso e exige treinamento especializado, além de equipamentos, laboratório e materiais adequados. Portanto, tal processo não pode ser facilmente escalado, especialmente considerando regiões muito extensas. Por esse motivo, esforços automáticos para aprimorar os métodos e facilitar a classificação de solos são bem-vindos.

Poucos trabalhos na literatura recente propõem algum tipo de classificação automática de solos. Aqui, fazemos uma breve revisão dos mais relevantes que utilizam métodos computacionais modernos nesta área.

Um estudo conduzido por Srunitha e Padmavathi (2016) apresenta uma abordagem para identificar diferentes tipos de solos utilizando uma Máquina de Vetores de Suporte (SVM) como classificador. O processo de classificação envolve aquisição de imagens do solo, pré-processamento, extração de características e classificação. Para extrair informações de textura, foram utilizados vários métodos de processamento de imagem, como filtros passa-baixa, filtros de Gabor, histogramas no espaço de cor HSV e quantização de cor.

Os autores utilizaram um conjunto de dados com 175 amostras de solo, incluindo Areia Siltosa, Argila Arenosa, Turfa, Argila com Húmus, Areia Argilosa, Turfa Argilosa e Argila. Os resultados experimentais mostraram que o classificador baseado em SVM foi capaz de reconhecer e classificar diferentes tipos de solos. No entanto, ao considerar todas as classes juntas, os resultados mostraram espaço para melhorias, alcançando uma taxa de segmentos corretamente classificados de quase 61% e uma taxa de instâncias corretamente classificadas próxima de 74,4%.

(Harlianto; Adji; Setiawan, 2017) examinou diversas abordagens de aprendizado de máquina para classificar tipos de solo. Os autores avaliaram os métodos de classificação SVM, Redes Neurais, Árvore de Decisão e Naive Bayes. Como resultado, a SVM se destacou em comparação aos outros métodos, especialmente ao utilizar um *kernel* de função linear. No geral, o método alcançou 82,35% de acurácia na classificação. Vale destacar que a acurácia da SVM não aumentou significativamente com a seleção de atributos ou redução de classes, indicando que ainda há perspectivas promissoras de melhorias nos resultados.

(Srivastava; Shukla; Bansal, 2021) apresentou um conjunto de métodos de classificação de solos. Seus procedimentos incluem aquisição de imagem, segmentação e extração de características, para posterior classificação do solo. Os métodos utilizados foram: Floresta Aleatória, Estimativa de Máxima Verossimilhança, K-Vizinhos Mais Próximos e Redes Neurais Convolucionais (CNN). Segundo o estudo, o modelo baseado em CNN foi o mais preciso. Contudo, vale destacar que métodos de aprendizado profundo, como CNN, exigem um grande número de imagens na etapa de treinamento para alcançar bom desempenho na etapa de teste. Portanto, esse é um ponto crítico, considerando a dificuldade de coleta de amostras de solo.

(Barman; Choudhury, 2020) propôs um sistema de classificação de imagens de solo voltado a agricultores rurais, oferecendo uma solução de baixo custo para compreensão da textura do solo. Os autores exploram um classificador SVM multiclasse para classificar as imagens de solo. A abordagem apresentada alcança uma acurácia média de 91,37% nas amostras de solo.

Há também outras propostas na literatura com a mesma direção dos estudos mencionados, como (Lanjewar; Gurav, 2022; Beucher *et al.*, 2022; J.; T., 2023; Zhan *et al.*, 2023). No entanto, até onde sabemos, nenhum desses trabalhos classifica o solo segundo uma taxonomia amplamente reconhecida. Por exemplo, (Lanjewar; Gurav, 2022) classifica solos em tipos aluviais, negros, argilosos e vermelhos. Os trabalhos de (Barman; Choudhury, 2020) e (J.; T., 2023) estimam a fração de areia, silte e argila na amostra de solo. A acidez do solo sulfático é estimada em (Beucher *et al.*, 2022) utilizando uma CNN. O trabalho de (Zhan *et al.*, 2023) estima a distribuição do tamanho de partículas usando métodos de aprendizado profundo.

Nosso trabalho se diferencia de todos os trabalhos relacionados por tentar classificar os solos seguindo uma taxonomia amplamente reconhecida, isto é, a SiBCS desenvolvida por Santos *et al.* (2018), que considera as propriedades físicas, químicas e biológicas dos solos.

3.2 Predição de Propriedades Químicas do Solo

Além da classificação, a predição de propriedades químicas, como teor de carbono e nitrogênio, tem atraído atenção na literatura recente. Um exemplo é o estudo de (Morais *et al.*, 2020), que desenvolveu uma metodologia para estimar o carbono orgânico e a textura do solo utilizando imagens digitais de 177 amostras de diferentes regiões do Brasil. O método utilizou calibração multivariada e alcançou um animado resultado do $R^2 = 0,9287$ com a técnica de Máquinas de Vetor Suporte por Mínimos Quadrados (LSSVMR), demonstrando a viabilidade de correlacionar imagens com parâmetros de fertilidade.

Outro trabalho na área, é o de (Ai *et al.*, 2024), que combinou PCA, Fuzzy C-Means (FCM) e Regressão de Mínimos Quadrados Parciais (PLSR) para prever o conteúdo de carbono orgânico em solos da base de dados LUCAS. O modelo alcançou RMSE de 1,20 e $R^2 = 6,80$, destacando-se pela integração de técnicas de agrupamento e regressão.

Também através de imagens obtidas por *smartphones*, o estudo de (Kang *et al.*, 2022) propôs um modelo preditivo para estimar o teor de carbono no solo utilizando imagens capturadas por *smartphones* e análise estatística multivariada. Foram analisadas amostras coletadas de diferentes tipos de uso agrícola na Coreia do Sul, sendo as imagens processadas para extração de variáveis de cor em diferentes espaços cromáticos, além de parâmetros físicos como densidade aparente e teor gravimétrico de água. Após análises de correlação e regressão, os modelos ajustados alcançaram R^2 ajustado de até 0,756 para solos de pomares. O estudo demonstrou a viabilidade e eficiência do uso de imagens simples, como as obtidas por celulares, para estimativas quantitativas de carbono no solo, oferecendo uma alternativa prática e de baixo custo em relação a métodos laboratoriais convencionais.

No entanto, a maioria desses trabalhos se concentra em propriedades isoladas como o carbono, ou utiliza métodos que não consideram a variabilidade entre diferentes tipos de solo. Nosso trabalho se diferencia ao realizar a predição de carbono e nitrogênio simultaneamente e ao incluir a classificação prévia dos tipos de solo (Latosolos e Cambissolos) no modelo. Essa abordagem integrada tem o potencial de aumentar a confiabilidade e precisão das estimativas, especialmente em solos com características distintas.

4 MATERIAIS E MÉTODOS

Este capítulo apresenta os materiais e métodos utilizados no desenvolvimento deste trabalho, abordando os procedimentos para aquisição e preparação de imagens, análise laboratorial e particionamento de amostras, além dos detalhes dos modelos de aprendizado de máquina utilizado no projeto.

4.1 Aquisição de Imagens

O conjunto de dados utilizado foi composto por 40 imagens de Latossolos e 51 de Cambissolos, coletadas em diferentes localidades da região sul do Brasil. As amostras foram obtidas em coordenadas específicas nos estados do Paraná e Santa Catarina, conforme descrito na Tabela 1. Esses solos foram escolhidos devido à sua relevância agrícola e ambiental na região.

Tabela 1 – Coordenadas das localidades de coleta das amostras.


Localidade	Lat. (S)	Long. (W)
Ponta Grossa, PR	25°15'	50°15'
Irati, PR	25°28'	50°54'
Abelardo Luz, SC	26°31'	52°15'

Cada imagem original corresponde a uma fração volumétrica de aproximadamente 20 cm³ de solo. Antes da captura das imagens, as amostras passaram por uma preparação que incluiu secagem ao ar, moagem, peneiramento em malha de 2 mm e disposição em placas de Petri com 9 cm de diâmetro. As amostras de Latossolos foram coletadas predominantemente na profundidade de 0 a 10 cm, com algumas provenientes de trincheiras de mais de 1 metro. Já as amostras de Cambissolos foram obtidas em profundidades variando de 0 a 20 cm.

4.1.1 Sistema de Captura de Imagens

O sistema de captura de imagens consistiu em uma câmera de *smartphone* e uma caixa de papelão de dimensões 30 cm × 22 cm × 12 cm, conforme ilustrado na Figura 3. A caixa foi pintada de preto para minimizar reflexos e vedada para bloquear luz externa. O *flash* da câmera foi utilizado para garantir iluminação consistente, enquanto a câmera foi posicionada em uma pequena abertura a uma distância fixa de 12 cm da amostra.

Figura 3 – Representação ilustrativa do sistema de captura de imagens



Todas as imagens foram capturadas com resolução de 4128 × 3096 pixels, utilizando o aplicativo Open Camera (Googleplay, Acessado Dez. 2024). Esse aplicativo foi escolhido devido à sua flexibilidade e compatibilidade com dispositivos acessíveis, como o *smartphone* utilizado (Samsung SM-J415G).

As Figuras 4 e 5 mostram exemplos representativos das imagens originais capturadas para Latossolos e Cambissolos, respectivamente.

Figura 4 – Amostra de Latossolo





Figura 5 – Amostra de Cambissolo



4.2 Análise Laboratorial

Após a captura das imagens, as amostras foram submetidas à análise química em laboratório para determinar os teores de carbono e nitrogênio. O método de combustão a seco foi utilizado, empregando um analisador elementar modelo Flash EA1112 (Thermo Electron Corporation, Milão, Itália) (Gordon; Sutcliffe, 1973). Nesse processo, o carbono e o nitrogênio presentes nos compostos orgânicos das amostras foram quantificados com base no CO₂ e N₂ liberados durante a combustão em altas temperaturas.

Os resultados laboratoriais foram utilizados como referência para calibração e validação dos modelos preditivos desenvolvidos neste trabalho.

4.3 Particionamento de Amostras


As imagens capturadas continham não apenas o solo (objeto de interesse), mas também elementos irrelevantes, como o fundo da caixa e a borda do recipiente de vidro. Para garantir que apenas o solo fosse analisado, as imagens foram segmentadas em sub-amostras ou “janelas” com dimensões de 256 × 256 pixels. Esse processo foi realizado de forma sistemática para cobrir toda a área útil da imagem original (4128 × 3096 pixels).

Ao todo, foram extraídas 17.472 janelas de 256 × 256 pixels. Após inspeção visual, janelas contendo elementos indesejados foram removidas, resultando em 12.773 janelas válidas. O conjunto final foi particionado em dois subconjuntos:

- **Treinamento e Validação:** 8.930 imagens (+- 70% das janelas).
 - Quantidade de Amostras: 36 Cambissolos e 28 Latossolos
- **Teste:** 3.843 imagens (+- 30% das janelas).
 - Quantidade de Amostras: 15 Cambissolos e 12 Latossolos

A separação garantiu que diferentes janelas de uma mesma amostra de solo fossem agrupadas no mesmo sub-conjunto, eliminando possíveis contaminações entre os dados de treinamento e teste. A Figura 6 apresenta exemplos de janelas representativas para Latossolos e Cambissolos.

Figura 6 – Exemplos das janelas para Latossolos e Cambissolos



4.4 Modelo de Transfer-Learning

Este trabalho utiliza o conceito de *transfer-learning*, uma técnica de aprendizado profundo que permite reutilizar modelos pré-treinados para resolver problemas específicos, redu-

zindo o esforço computacional e a necessidade de grandes bases de dados. Essa abordagem tem como base modelos *end-to-end*, que aprendem representações diretamente dos dados brutos até as saídas desejadas. A seguir, detalhamos a arquitetura dos modelos utilizados, os procedimentos para treinamento e seleção de hiperparâmetros, bem como a metodologia de avaliação.

4.4.1 Arquitetura dos Modelos

Para a classificação de Latossolos e Cambissolos, utilizamos a rede neural convolucional ResNet50, um modelo amplamente conhecido por sua capacidade de extrair características de imagens em diferentes níveis de abstração (He *et al.*, 2016). A ResNet50 é composta por 50 camadas convolucionais organizadas em blocos residuais, o que permite preservar informações ao longo das camadas e mitigar problemas de degradação de desempenho em redes profundas. Este modelo foi originalmente treinado no conjunto de dados ImageNet, que contém milhões de imagens em milhares de classes, tornando-o altamente eficiente na extração de características gerais (Deng *et al.*, 2009; Russakovsky *et al.*, 2015).

Utilizando como base o modelo ResNet50, aplicamos a técnica de *transfer-learning*, mantendo todas camadas congeladas e preservando os pesos pré-treinados no ImageNet, contudo, apenas a última camada foi substituída por uma camada densa, e assim, seguiu os procedimentos de treinamento e teste com as imagens janelas, com intuito de resultar na classificação entre Latossolos e Cambissolos.

Para a predição de teores de carbono e nitrogênio, testamos diversas arquiteturas pré-treinadas, como EfficientNetV2-S, DenseNet169 e InceptionResNetV2. O modelo EfficientNetV2-S destacou-se nos experimentos, apresentando excelente desempenho sem a necessidade de pré-processamento adicional nas imagens. Sua arquitetura inclui camadas convolucionais otimizadas, *dropout* para regularização e camadas densas para predição de saída. A Tabela 2 exemplifica os dados das camadas finais do modelo selecionado.

Tabela 2 – Resumo do modelo baseado em EfficientNetV2-S.

Camada	Saída	Parâmetros	Treinável?
efficientnetv2-s	1280	20.331.360	não
denso	128	163.968	sim
<i>dropout</i>	128	0	não
denso	64	8.256	sim
denso	2	130	sim
Total de parâmetros: 20.503.714			
Parâmetros treináveis: 172.354			

4.4.2 Treinamento dos Modelos

Para classificação, utilizado o modelo ResNet50 aplicando *transfer-learning*, o procedimento de treinamento incluiu:

- Função de ativação *sigmoid* para classificação binária (Latossolo ou Cambissolo).
- Otimização com o algoritmo Adam, configurado com taxa de aprendizado inicial 10^{-4} .
- Critério de parada antecipada (*early stopping*) para evitar *overfitting*, interrompendo o treinamento após 5 épocas sem melhoria na validação.

Já para o modelo EfficientNetV2-S de regressão, utilizado para predição de carbono e nitrogênio, as camadas pré-treinadas foram utilizadas como extrator de características, enquanto camadas densas adicionais foram treinadas para realizar a regressão. A configuração incluiu:

- Função de ativação linear na camada de saída para predição contínua.
- Função de perda baseada no erro quadrático médio (MSE).
- Otimização com RMSprop e regularização por *dropout* (taxa de 0,5).

Ambos os modelos foram treinados utilizando um conjunto de dados particionado conforme descrito na Seção 4.3, com 70% das janelas destinadas ao treinamento/validação e 30% reservadas para teste.

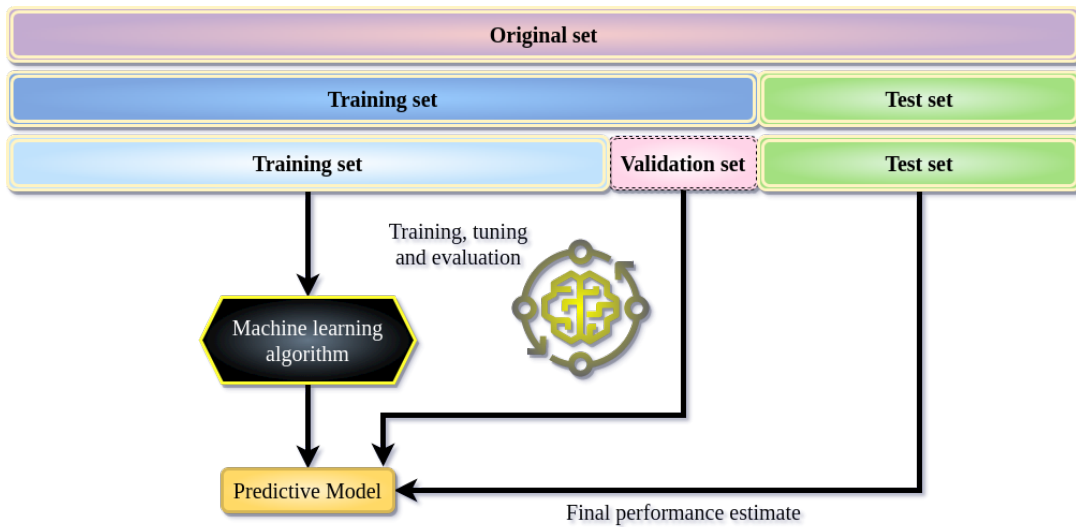
4.4.3 Seleção e Avaliação dos Modelos

Para selecionar os melhores modelos, utilizamos o método de validação cruzada *5-fold* combinado com *hold-out*. A Figura 7 ilustra o particionamento dos dados. Neste método, garantiu-se que as janelas extraídas de uma mesma amostra permanecessem exclusivamente no conjunto de treinamento ou de teste, evitando contaminação entre os conjuntos.

Na classificação, com *transfer-learning* sobre o ResNet50, aplicamos diversas combinações de hiperparâmetros para encontrar o modelo mais preciso, contudo, devido ao animado resultado inicial da rede neural, não estendemos para outras técnicas de tratamento de dados ou processamento de imagem. Em relação à avaliação, por se tratar de um *dataset* de classes desbalanceadas, aplicamos a métrica da acurácia balanceada, na qual é utilizada para compensar a distorção causada por conjuntos de dados desbalanceados. Ela é definida como a média aritmética das sensibilidades de cada classe, garantindo que todas as classes contribuam igualmente para a avaliação do modelo, independentemente de sua frequência (Scikit-learn, 2025).

Na regressão, em busca e seleção do modelo mais preciso, utilizamos *transfer-learning* sobre três modelos: EfficientNetV2-S, DenseNet169 e InceptionResNetV2. Durante a seleção

Figura 7 – Método de particionamento *3-way hold-out*



Fonte: Adaptado de Kumar (2022).

de hiperparâmetros, testamos diferentes configurações, além de outras técnicas, incluindo normalizações (*MinMaxScaler*, *StandardScaler*) e formas de pré-processamento das imagens. Este método de trabalho identificou no modelo EfficientNetV2-S superioridade de acertos sobre os demais, sem a necessidade de normalização dos dados ou pré-processamento de imagens. Como avaliação, utilizamos a métrica de erro absoluto médio (MAE), que nos ajuda a interpretar como está performando o modelo.

Dois experimentos foram realizados para o modelo de classificação, e mais dois experimentos para o modelo de regressão:

- **Classificação:**

- **Experimento 1:** Avaliação das janelas individuais para verificar possíveis variações locais no solo.
- **Experimento 2:** Classificação das imagens originais usando um método de votação majoritária (*majority voting*) baseado nos resultados do Experimento 1. O objetivo é verificar se há homogeneidade das amostras e atribuir maior confiabilidade a classificação final.

- **Regressão:**

- **Experimento 1:** Predição de Carbono e Nitrogênio sobre janelas individuais.
- **Experimento 2:** Identifica a janela mediana baseado nos resultado do Experimento 1, tornando-a representação da amostra de solo unitária. Objetivo é verificar se há homogeneidade das amostras e atribuir maior confiabilidade a predição de carbono e nitrogênio final.

5 RESULTADOS

Neste capítulo, são apresentados os resultados obtidos nos experimentos realizados sobre os solos: Latossolos e Cambissolos. Assim conheceremos a performance dos modelos de classificação e regressão (predição dos teores de carbono e nitrogênio). Além disso, são discutidas as limitações do estudo e as implicações práticas dos achados.

5.1 Resultados da Classificação

5.1.1 Classificação: Experimento 1

No primeiro experimento, o conjunto de treinamento/validação incluiu 8.930 imagens, enquanto o conjunto de teste continha 3.843 imagens. O modelo mais preciso, selecionado entre 10 redes treinadas, alcançou uma acurácia balanceada no conjunto de teste de 93,73%, demonstrando um desempenho robusto para a classificação de Latossolos e Cambissolos.

A Tabela 3 apresenta a matriz de confusão para este Experimento 1. Das 3.843 janelas classificadas, 2.070 eram Latossolos (1.884 classificadas corretamente, ou seja, 91,01%) e 1.773 eram Cambissolos (1.710 classificadas corretamente, ou seja, 96,45%).

Tabela 3 – Matriz de confusão - Classificação: Experimento 1

		<i>Predito</i>	
		Latossolo	Cambissolo
<i>Real</i>	Latossolo	1884	186
	Cambissolo	63	1710

O modelo apresentou bons resultados apesar das variações de cor e textura entre os solos (ver Figuras 1 e 2). A Figura 8 mostra alguns exemplos dos resultados da classificação. Vale ressaltar que no conjunto de dados, há imagens de solos coletados em diferentes horizontes superficiais, uns mais rasos outros mais profundos. Os resultados apontam que nossa abordagem classificou corretamente a maioria dos solos, independentemente de serem amostras de superfície ou não.

Já na análise de homogeneidade das janelas, apresentada na Tabela 4, revelou um desempenho consistente do modelo de classificação. Considerando as 27 amostras avaliadas, a taxa média de acerto foi de 93,17%, com um desvio padrão de $\pm 9,43\%$. Esse resultado indica que, na maioria das amostras, houve elevada concordância entre as janelas classificadas e a classe real atribuída à imagem original, o que reforça a robustez do modelo na identificação de padrões homogêneos. Ainda que algumas amostras tenham apresentado variações, o desempenho geral pode ser considerado satisfatório, especialmente no contexto de classificação de solos com características visuais semelhantes.

Figura 8 – Exemplos de classificação - Experimento 1



P = Predito | R = Real | C = Cambissolo | L = Latossolo

Tabela 4 – Resultado da homogeneidade das janelas - Classificação: Experimento 1

Amostra	Qtd. Janelas	% Acerto
C3	125	100,00%
C4	128	79,69%
C8	124	91,13%
C9	123	84,55%
C10	127	81,89%
C12	127	84,25%
C16	128	94,53%
C23	128	91,41%
C24	126	98,41%
C26	124	100,00%
C37	127	100,00%
C39	125	100,00%
C41	128	100,00%
C46	128	89,84%
C51	128	57,81%

Amostra	Qtd. Janelas	% Acerto
L2	125	100,00%
L5	127	100,00%
L7	127	98,43%
L12	127	92,91%
L17	184	97,28%
L20	181	100,00%
L23	177	100,00%
L26	183	100,00%
L29	185	92,43%
L33	161	90,06%
L37	189	92,06%
L40	181	98,90%

C = Cambissolo | L = Latossolo

5.1.2 Classificação: Experimento 2

No segundo experimento, foi adotada a estratégia de votação majoritária (*majority voting*) para realizar a classificação das amostras originais do conjunto de teste. Neste método, cada amostra é composta por várias janelas, e a classe final atribuída à amostra é determinada pela classe mais frequentemente predita entre essas janelas individuais. Ou seja, cada janela “vota” em uma classe, e a classe com o maior número de votos é considerada a predição final da amostra.


A aplicação dessa técnica resultou em uma acurácia balanceada de 100%, sem a ocorrência de erros de classificação. Esse desempenho indica que todas as amostras de Latossolo e Cambissolo foram corretamente identificadas, conforme ilustrado na Tabela 5, que apresenta a matriz de confusão do experimento.

Tabela 5 – Matriz de confusão - Classificação: Experimento 2

		<i>Predito</i>	
		Latossolo	Cambissolo
<i>Real</i>	Latossolo	12	0
	Cambissolo	0	15

Apesar do bom desempenho, a análise da confiança nas classificações revelou-se fraca para algumas amostras específicas, como a C51 (Cambissolo), que apresentou apenas 57,81% de acerto nas janelas individuais. Isso indica que variações locais podem influenciar os resultados, conforme ilustrado na Figura 9.

Figura 9 – Classificação das amostras originais - votação majoritária



L40: Latossolo - 98,90%

C26: Cambissolo - 100,00%

C51: Cambissolo - 57,81%

5.2 Resultados da Regressão

5.2.1 Regressão: Experimento 1

No primeiro experimento de regressão, buscou-se estimar os teores de carbono (C) e nitrogênio (N) a partir das janelas de textura extraídas das amostras de solo originais, empregando o mesmo *dataset* utilizado no experimento de classificação.

Para um coeficiente de determinação ideal, é necessário obter a máxima aproximação do resultado R^2 para 1,0; diante disso, os resultados obtidos foram apenas moderados. Ainda assim, apresentaram um coeficiente de determinação R^2 de 0,5012 para carbono e 0,5201 para nitrogênio (Tabela 6). Isso indica que o modelo foi capaz de explicar aproximadamente 50% da variabilidade dos dados em relação à média, insuficiente para capturar toda a complexidade das imagens. É importante destacar que este experimento foi conduzido com base em janelas extraídas das amostras, o que permitiu avaliar o desempenho do modelo em porções específicas do solo. No entanto, essa abordagem pode ter sido influenciada por variações locais e heterogeneidades intrínsecas às amostras analisadas.

Tabela 6 – Métricas do Experimento 1 (janelas)

	Carbono (C)	Nitrogênio (N)
R^2	0,5012	0,5201
RMSE	0,9160	0,0755

Para complementar a interpretação dos resultados do Experimento 1, é fundamental considerar o erro quadrático médio (RMSE), que mede a magnitude média dos erros de predição em relação aos valores observados, sendo expresso nas mesmas unidades das variáveis preditas. A interpretação do RMSE deve ser contextualizada com base na distribuição estatística dos dados, como ilustrado na Tabela 7.

No caso do carbono, com média de 2,9248 e desvio padrão de 1,2971; o RMSE deve ser comparado a esses valores para avaliar sua relevância prática. Um RMSE próximo ou superior a 1,2971; indicaria que os erros de predição são da mesma ordem de magnitude que a variabilidade natural do dado, o que compromete a utilidade do modelo para aplicações mais precisas. O mesmo raciocínio se aplica ao nitrogênio, cuja média é de 0,2296 e desvio padrão é de 0,1086. Se o RMSE estiver muito próximo a esse desvio padrão, o modelo se mostraria ineficiente.

Além disso, é útil avaliar o RMSE em relação à amplitude dos dados. Para o carbono, a variação observada vai de 0,31 a 4,95; enquanto para o nitrogênio vai de 0,03 a 0,39. Isso demonstra que, embora os dados estejam relativamente concentrados em um intervalo reduzido, os erros absolutos podem representar uma proporção significativa do intervalo total, especialmente no caso do nitrogênio, onde pequenas diferenças podem impactar diretamente na interpretação agrônômica do solo.

5.2.2 Regressão: Experimento 2

No Experimento 2, foi utilizada a mesma base de dados do Experimento 1, porém com uma abordagem metodológica distinta. Em vez de realizar predições diretamente sobre as janelas extraídas das imagens de solo, optou-se por calcular a mediana dos valores preditores de cada conjunto de janelas pertencente a uma mesma amostra. Essa mudança representa um

Tabela 7 – Resumo de dados de Teste.

	Carbono (C)	Nitrogênio (N)
<i>count</i>	3843	3843
<i>mean</i>	2,9248	0,2296
<i>std</i>	1,2971	0,1086
<i>min</i>	0,3100	0,0300
25%	1,7800	0,1400
50%	3,1900	0,2400
75%	4,1600	0,3400
<i>max</i>	4,9500	0,3900

retorno à representação unitária de cada amostra, agora baseada na medida estatística mais robusta em relação a valores extremos — a mediana.

Essa estratégia visou reduzir a influência de variações locais e pontuais do solo, frequentemente presentes nas janelas individuais. Ao considerar a mediana, busca-se uma estimativa mais estável e representativa das propriedades químicas (carbono e nitrogênio) da amostra como um todo.

Os resultados indicam uma melhora significativa no desempenho do modelo em relação ao Experimento 1. O coeficiente de determinação (R^2) aumentou para 0,7425 para o carbono e 0,7774 para o nitrogênio, conforme apresentado na Tabela 8. Isso demonstra que o modelo passou a explicar aproximadamente 74% e 78% da variância dos dados, respectivamente, refletindo uma capacidade consideravelmente maior de capturar padrões reais associados às concentrações desses elementos no solo.

Tabela 8 – Métricas do Experimento 2 (mediana das janelas)

	Carbono (C)	Nitrogênio (N)
R^2	0,7425	0,7774
RMSE	0,6634	0,0510

Adicionalmente, os valores do erro quadrático médio (RMSE) foram reduzidos para 0,6634 no caso do carbono e 0,0510 para o nitrogênio, o que representa uma queda expressiva na magnitude média dos erros de predição em comparação ao Experimento 1 (RMSE de 0,9160 e 0,0755, respectivamente). Essa redução indica maior precisão nas estimativas e contribui para uma maior confiabilidade do modelo em aplicações práticas.

Essa melhora pode ser atribuída ao uso da mediana como técnica de agregação, que tende a minimizar os efeitos de janelas ruidosas, heterogêneas ou atípicas. Em contextos de solos naturalmente heterogêneos, essa abordagem pode representar uma alternativa eficaz para consolidar predições mais coerentes e alinhadas à realidade laboratorial.

A superioridade do modelo no Experimento 2 foi substancialmente amplificada pela adoção da estratégia baseada na mediana das janelas por amostra. Essa abordagem foi fundamental para atenuar os *outliers* e as flutuações locais intrínsecas às janelas individuais, conforme detalhado nas Tabelas 9 e 10. Com a mediana servindo como a representação unificada de

cada amostra, as previsões tornaram-se notavelmente mais consistentes e robustas. Este aprimoramento refletiu-se diretamente na elevação dos coeficientes de determinação (R^2) e na expressiva redução dos erros quadráticos médios (RMSE).

Tabela 9 – Resultados de carbono e nitrogênio Experimento 1
Amostras com melhores e piores previsões sobre as janelas

Melhores resultados para Carbono			
Amostra unit.	% Real	% Predito	% de Erro
C26	1,9400	1,9400	0,0000
C8	3,3600	3,3594	0,0179
C9	3,3000	3,2990	0,0303
Piores resultados para Carbono			
Amostra unit.	% Real	% Predito	% de Erro
C51	0,3100	4,2209	1261,5806
C51	0,3100	4,2740	1278,7097
C51	0,3100	4,3769	1311,9032
Melhores resultados para Nitrogênio			
Amostra unit.	% Real	% Predito	% de Erro
L12	0,0800	0,0800	0,0000
C24	0,3900	0,3899	0,0256
C9	0,2200	0,2201	0,0455
Piores resultados para Nitrogênio			
Amostra unit.	% Real	% Predito	% de Erro
C51	0,0300	0,3723	1141,00
C51	0,0300	0,3819	1173,00
C51	0,0300	0,3969	1223,00

Sigla: (C) Cambissolo; (L) Latossolo

A análise detalhada das melhores e piores previsões também reforça essa constatação. Na Tabela 9, referente ao Experimento 1, observam-se erros extremamente elevados para algumas amostras específicas, como a amostra C51, cujos erros ultrapassaram 1300% para carbono e 1200% para nitrogênio. Tais discrepâncias decorrem da variação entre janelas internas da mesma amostra, o que demonstra como o uso direto das janelas comprometeu a capacidade de generalização do modelo, deteriorando o desempenho global (impacto direto sobre o R^2).

A análise detalhada das melhores e piores previsões também reforça essa constatação. Na Tabela 9, referente ao Experimento 1, observam-se erros extremamente elevados para algumas amostras específicas, como a amostra C51, cujos erros ultrapassaram 1300% para carbono e 1200% para nitrogênio. Tais discrepâncias decorrem da variação entre janelas internas da mesma amostra, o que demonstra como o uso direto das janelas comprometeu a capacidade de generalização do modelo, deteriorando o desempenho global (impacto direto sobre o R^2). Cabe destacar que a mesma amostra C51 também apresentou os piores resultados no modelo de classificação baseado em janelas (Tabela 4), sendo classificada incorretamente em grande parte das tentativas. Esse comportamento recorrente sugere que a amostra pode conter características visuais e químicas incomuns ou ruidosas, destoando significativamente

do padrão observado nas demais amostras da base. É possível que fatores como iluminação irregular na captura da imagem, mistura de horizontes do solo, presença de impurezas visuais ou até erro de etiquetagem durante o preparo tenham contribuído para sua baixa performance em ambos os modelos (classificação e regressão), configurando-a como um possível *outlier*.

**Tabela 10 – Resultados de carbono e nitrogênio Experimento 2
Amostras com melhores e piores predições pela mediana**

Melhores resultados para Carbono pela Mediana			
Grupo Amostra	% Real	% Predito	% de Erro
L7	1,4400	1,4375	0,1736
C12	3,1900	3,2977	3,3762
L20	3,2800	3,4313	4,6128
Piores resultados para Carbono pela Mediana			
Grupo Amostra	% Real	% Predito	% de Erro
C37	1,0900	1,4445	32,5229
C23	3,3000	1,9137	42,0091
L5	0,7800	1,4226	82,3846
Melhores resultados para Nitrogênio pela Mediana			
Grupo Amostra	% Real	% Predito	% de Erro
C26	0,2000	0,2028	1,4000
L17	0,3200	0,3089	3,4688
C9	0,2200	0,2286	3,9091
Piores resultados para Nitrogênio pela Mediana			
Grupo Amostra	% Real	% Predito	% de Erro
C23	0,2700	0,1646	39,0370
C8	0,2000	0,2810	40,5000
L5	0,0600	0,1049	74,8333

Sigla: (C) Cambissolo; (L) Latossolo

Por outro lado, a Tabela 10 evidencia um cenário muito mais equilibrado após a agregação por mediana. Ainda que existam erros mais elevados em algumas amostras, como L5 para carbono 82,38% e L5 para nitrogênio 74,83%; esses valores são significativamente menores que os observados no Experimento 1. Além disso, os melhores resultados, como os obtidos para as amostras L7 e C12 (carbono), e C26 e L17 (nitrogênio), apresentam erros inferiores a 3,5%, indicando predições altamente fiéis aos valores reais.

Um ponto importante a ser destacado é que, no Experimento 2, a pior predição de carbono foi aproximadamente 16 vezes menos errática que no Experimento 1, reduzindo de 1311,9032% para 82,3846%. No caso do nitrogênio, a melhora foi ainda mais expressiva, com uma queda de erro aproximada de 94%, reduzindo de 1223% para, no pior caso, 74,83%.

Adicionalmente, observa-se que algumas amostras aparecem entre os melhores resultados em ambos os experimentos, como é o caso da amostra C9. Isso pode indicar que tais amostras possuem características mais homogêneas internamente, ou ainda, que estão bem representadas no espaço amostral de treinamento, facilitando a tarefa de regressão do modelo.

Por fim, a estratégia baseada na mediana demonstrou ser uma solução eficaz para lidar com a heterogeneidade intra-amostral, promovendo uma melhora substancial na estabilidade,

precisão e robustez do modelo de predição. A análise dos extremos (melhores e piores casos) reforça a necessidade de abordagens que considerem a estrutura dos dados e que mitiguem o impacto de ruídos locais no desempenho global do modelo.

5.3 Limitações do Estudo

Embora os resultados sejam promissores, algumas limitações devem ser destacadas. Primeiramente, o estudo foi restrito a dois tipos de solos (Latosolos e Cambissolos). Não é possível garantir o mesmo desempenho para outros tipos de solos ou para amostras de diferentes regiões geográficas com composições variadas. Além disso, o sistema de captura de imagens foi padronizado, utilizando uma câmera específica e condições controladas de iluminação. Alterações nesses parâmetros podem impactar significativamente os resultados.

Outro ponto relevante é o tamanho limitado da base de dados (51 Cambissolos e 40 Latossolos), que pode não representar toda a variabilidade dos solos. Por fim, as redes pré-treinadas utilizadas foram adaptadas para este estudo, mas o desenvolvimento de arquiteturas específicas para solos pode trazer melhorias significativas no desempenho.

6 CONCLUSÃO

A classificação confiável de solos e a predição de suas propriedades químicas são etapas fundamentais para diversas áreas. Este trabalho apresentou abordagens que utilizam métodos modernos de aprendizado profundo para, respectivamente, classificar solos e prever teores de carbono e nitrogênio a partir de imagens. Os resultados obtidos demonstraram a viabilidade e o potencial dessas técnicas, destacando a classificação com probabilidade maior de sucesso na implementação, já para regressão, entende-se que necessita de uma melhor performance para uma real aplicação, contudo, ambos métodos destacam desafios e oportunidades para futuras pesquisas.

6.1 Classificação de Solos

A abordagem proposta para a classificação de Latossolos e Cambissolos, baseada em transferência de aprendizado com a rede ResNet50, alcançou resultados expressivos, com acurácia balanceada de 100% no conjunto de teste ao utilizar a votação majoritária. Esses resultados destacam a robustez do modelo, mesmo considerando a limitação do conjunto de dados, composto por apenas 91 amostras de solo.

O método apresentado representa uma alternativa promissora aos métodos tradicionais de classificação de solos, que são complexos, demorados, de custo elevado e dependem de análises em laboratório. A utilização de imagens RGB capturadas com *smartphones* comuns e analisadas por redes neurais profundas, permite uma abordagem mais rápida, acessível e não destrutiva, com grande potencial para aplicações em larga escala.

No entanto, para consolidar a aplicabilidade prática do método, é necessário expandir o estudo para incluir outros tipos de solos, amostras de diferentes regiões geográficas e variações nas condições de captura de imagens. Essa ampliação permitirá avaliar a capacidade de generalização do modelo proposto e sua eficácia em cenários mais diversos.

6.2 Predição de Carbono e Nitrogênio

No âmbito da predição de carbono e nitrogênio, onde é mais complexo a aproximação de valores devido a natureza de modelos de regressão, ainda assim, tivemos resultados promissores, especialmente ao aplicar a estratégia por mediana das janelas. No experimento 2, o modelo baseado no EfficientNetV2-S alcançou $R^2 = 0,7425$ para carbono e $R^2 = 0,7774$ para nitrogênio, superando os resultados do experimento 1, que avaliou todas as janelas individualmente. Esses achados ressaltam a importância da aplicação de outras estratégias, como exemplo a mediana, com o intuito de redução de ruído, para capturar as propriedades globais das amostras de solo.

Apesar dos bons resultados, o tamanho reduzido do conjunto de dados e as limitações no processo de captura de imagens, podem ter restringido o desempenho do modelo. Futuras

pesquisas podem explorar maior variabilidade nos dados, métodos alternativos de preparação e captura de amostras, e arquiteturas de redes mais especializadas.

6.3 Limitações e Perspectivas Futuras

Embora os métodos propostos tenham demonstrado resultados significativos, algumas limitações devem ser destacadas:

- A restrição aos tipos de solos analisados (Latosolos e Cambissolos) limita a generalização do modelo para outros tipos de solos ou condições geográficas.
- A base de dados utilizada, embora ampliada pelo particionamento em janelas, é pequena em termos de amostras originais, o que pode impactar a robustez do modelo.
- O sistema de captura de imagens, baseado em *smartphones* e iluminação controlada, pode não refletir as condições reais de campo.
- A arquitetura do modelo, embora eficiente, pode ser aprimorada com redes especializadas para análise de solos ou abordagens híbridas que combinem informações espectrais e visuais.

Apesar da melhoria nos resultados de regressão observada no Experimento 2 — especialmente com o uso da mediana das janelas, que elevou o coeficiente de determinação (R^2) para 0,7425 no caso do carbono e 0,7774 no caso do nitrogênio — os valores de erro absoluto ainda são consideráveis em determinadas amostras. Foram observadas predições com desvios superiores a 70%, o que inviabiliza, neste momento, a aplicação prática da técnica em sistemas de suporte à decisão agrícola. Dessa forma, embora os resultados sejam promissores, o modelo ainda requer aprimoramentos substanciais para ser utilizado em ambientes reais.

As perspectivas futuras incluem a ampliação do conjunto de dados, a inclusão de novos tipos de solos, o uso de câmeras e condições de iluminação mais sofisticadas, e a exploração de novas arquiteturas de aprendizado profundo. Além disso, estudos comparativos com outros métodos de análise, como espectroscopia ou análise química tradicional, podem fornecer *insights* valiosos sobre a eficácia e as limitações da abordagem proposta.

6.4 Considerações Finais

Este trabalho demonstrou que a combinação de aprendizado profundo e análise de imagens pode ser uma ferramenta poderosa para a classificação e predição de propriedades de solos. Os resultados obtidos são encorajadores e apontam para o potencial de desenvolver produtos automatizados baseados em visão computacional, capazes de acelerar o processo de análise de solos, reduzir custos e ampliar as aplicações em áreas como agricultura e manejo ambiental.

6.5 Produções Técnicas e Científicas

Como resultado deste trabalho de dissertação, foram desenvolvidas e submetidas as seguintes produções técnico-científicas:

Artigo premiado em evento científico: O trabalho intitulado *A New Approach for Soil Carbon and Nitrogen Assessment through Image Analysis: A Case Study with Oxisols and Inceptisols* foi apresentado no XIX Workshop de Visão Computacional (WVC 2024), realizado de 6 a 8 de novembro de 2024, onde recebeu o prêmio de Melhor Pôster na Categoria Apresentação.

Artigo publicado na revista científica RITA: O mesmo trabalho foi publicado na Revista de Informática Teórica e Aplicada (RITA), periódico qualis B2 na área de Ciência da Computação. A publicação está disponível no seguinte endereço:

- <https://seer.ufrgs.br/index.php/rita/article/view/143392>

Artigo submetido para revista científica *Applied Computing and Geosciences* (em avaliação): Além dos estudos de regressão, foi submetido um segundo artigo com foco na classificação automática dos solos Latossolos e Cambissolos por meio de redes neurais convolucionais, intitulado *Automatic Soil Classification Using CNN: A Case Study with Oxisol and Inceptisol*. Esse artigo encontra-se atualmente em processo de avaliação por periódico científico.

Essas produções atestam a relevância científica, prática e acadêmica da presente dissertação, evidenciando sua contribuição ao estado da arte na interseção entre visão computacional, aprendizado profundo e ciências do solo.

6.6 Declaração sobre o uso de IA generativa e tecnologias assistidas por IA no processo de escrita

Durante a preparação deste trabalho, o autor utilizou ferramentas de IA generativa (*Large Language Models*) para auxiliar na escrita. Após o uso destas ferramentas, o autor revisou e editou o conteúdo conforme necessário e assume total responsabilidade pelo conteúdo da publicação.

REFERÊNCIAS

- AI, X. *et al.* Prediction of soil organic carbon content using machine learning based fuzzy c-means clustering. *In: 2024 THIRD INTERNATIONAL CONFERENCE ON DISTRIBUTED COMPUTING AND ELECTRICAL CIRCUITS AND ELECTRONICS (ICDCECE)*. 2024. **Anais [...] IEEE**, 2024. p. 1–4. Disponível em: <https://bit.ly/4dk9HCl>.
- ANDRADE, R. *et al.* Tropical soil order and suborder prediction combining optical and x-ray approaches. **Geoderma Regional**, Elsevier v. 23,, p. e00331, 2020.
- BARMAN, U.; CHOUDHURY, R. D. Soil texture classification using multi-class support vector machine. **Information Processing in Agriculture**, v. 7, n. 2, p. 318–332, 2020.
- BEUCHER, A. *et al.* Interpretation of convolutional neural networks for acid sulfate soil classification. **Frontiers in Environmental Science**, „ p. 679, 2022.
- BRADY, N.; WEIL, R. R. **The Nature and Properties of Soils**. 15th. ed. Harlow, England: Pearson, 2016.
- CHAPELLE, O.; SCHOLKOPF, B.; ZIEN EDS., A. Semi-supervised learning (chappelle, o. et al., eds.; 2006) [book reviews]. **IEEE Transactions on Neural Networks**, v. 20, n. 3, p. 542–542, 2009.
- CHOLLET, F. **Deep Learning with Python**. Second edition. New York, NY: Manning Publications Co., 2021. ISBN 9781617296864.
- DENG, J. *et al.* Imagenet: A large-scale hierarchical image database. *In: 2009 IEEE CONFERENCE ON COMPUTER VISION AND PATTERN RECOGNITION*. 2009. **Anais [...] IEEE**, 2009. p. 248–255. Disponível em: <https://bit.ly/4dPew6D>.
- DEPARTMENT, A. **Keys to Soil Taxonomy**. United States Department of Agriculture, 2014. (Compilation of United States Trade Statutes Series). ISBN 9780160923210. Disponível em: <https://books.google.com.br/books?id=jaQmsrXypz8C>.
- DIECKOW, J. *et al.* Comparison of carbon and nitrogen determination methods for samples of a paleudult subjected to no-till cropping systems. **Scientia Agricola**, v. 64, n. 5, p. 532–540, 2007.
- FELIX, J. C. **Espectroscopia de Infravermelho Próximo na Predição do Carbono, Nitrogênio e Fósforo em Solos Derivados de Basalto**. 2015. Dissertação (Dissertação de Mestrado em Agronomia) — Universidade Estadual de Londrina Londrina 2015.
- FONTANA, A.; BALIEIRO, F. de C.; PEREIRA, M. G. **Classes de solos do Brasil: Sistema Brasileiro de Classificação de Solos**. Brasília, DF: Embrapa Solos & UFRRJ, 2020.
- GONÇALVES, T. D.; LOHE, C.; CAMPOS, J. E. G. Hydraulic characterization from porous aquifers of the Brazilian Federal District. **Brazilian Journal of Geology**, SciELO Brasil v. 45,, p. 259–271, 2015.
- GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep Learning**. WWW: MIT Press, 2016. <Http://www.deeplearningbook.org>.
- GOOGLEPLAY. **Aplicativo Open Camera**, . Acessado Dez. 2024. Disponível em: <https://bit.ly/3P5uAao>.

- GORDON, D. C.; SUTCLIFFE, W. H. A new dry combustion method for the simultaneous determination of total organic carbon and nitrogen in seawater. **Marine Chemistry**, v. 1, n. 3, p. 231–244, 1973. ISSN 0304-4203. Disponível em: <https://bit.ly/3Ufdee6>.
- HARLIANTO, P. A.; ADJI, T. B.; SETIAWAN, N. A. Comparison of machine learning algorithms for soil type classification. *In*: PROC. IEEE 3RD INTERNATIONAL CONFERENCE ON SCIENCE AND TECHNOLOGY - COMPUTER (ICST). 2017, Yogyakarta, Indonesia. **Anais [...]** Yogyakarta, Indonesia: IEEE, 2017. p. 7–10.
- HE, K. *et al.* Deep residual learning for image recognition. *In*: PROC. IEEE CONFERENCE ON COMPUTER VISION AND PATTERN RECOGNITION (CVPR). 2016, Las Vegas, NV, USA. **Anais [...]** Las Vegas, NV, USA: IEEE, 2016. p. 770–778.
- J., P.; T., S. Deep learning based multi-labelled soil classification and empirical estimation toward sustainable agriculture. **Engineering Applications of Artificial Intelligence**, v. 119, p. 105690, 2023.
- KANG, Y.-G. *et al.* Prediction of soil carbon contents using smartphone images and multiple regression analysis. **Korean Journal of Soil Science and Fertilizer**, v. 55, n. 3, p. 228–238, 2022. ISSN 0367-6315. Disponível em: <https://doi.org/10.7745/KJSSF.2022.55.3.228>.
- KUMAR, A. **Hold-out Method for Training Machine Learning Models**, . 2022. Disponível em: <https://vitalflux.com/hold-out-method-for-training-machine-learning-model>.
- LANJEWAR, M. G.; GURAV, O. Convolutional neural networks based classifications of soil images. **Multimedia Tools and Applications**, v. 81, n. 7, p. 10313–10336, 2022.
- LECUN, Y. *et al.* Backpropagation applied to handwritten zip code recognition. **Neural Computation**, MIT Press v. 1, n. 4, p. 541–551, 1989. Disponível em: <https://doi.org/10.1162/neco.1989.1.4.541>.
- MORAIS, P. A. d. O. *et al.* Avaliando a fertilidade do solo com imagens digitais. **Revista Processos Químicos**, v. 14, n. 27, p. 9–16, set. 2020. Disponível em: <https://bit.ly/40sduL1>.
- O'SHEA, K.; NASH, R. Department of Computer Science, Aberystwyth University and School of Computing and Communications, Lancaster University **An Introduction to Convolutional Neural Networks**. Lancashire: , 2015.
- PINTO, L. C. *et al.* Role of inceptisols in the hydrology of mountainous catchments in southeastern Brazil. **Journal of Hydrologic Engineering**, American Society of Civil Engineers v. 21, n. 2, p. 05015017, 2016.
- RUSSAKOVSKY, O. *et al.* Imagenet – large scale visual recognition challenge. **International Journal of Computer Vision**, v. 115, n. 3, p. 211–252, 2015.
- SANTOS, H. G. dos *et al.* **SiBCS - Sistema Brasileiro de Classificação de Solos**. Brasília, DF: EMBRAPA, 2018. v. 5. ed.
- SCIKIT-LEARN. **Balanced Accuracy Score — scikit-learn Documentation**, . 2025. https://scikit-learn.org/dev/modules/model_evaluation.html#balanced-accuracy-score. Accessed: 2025-06-10.
- SILVA, F. M. *et al.* Using proximal sensors to assess pedogenetic development of inceptisols and oxisols in Brazil. **Geoderma Regional**, Elsevier v. 28, p. e00465, 2022.
- SIQUEIRA, G. M. *et al.* The use of quick soil survey and gis tools for land degradation monitoring in a rural municipality in south-eastern brazil. **Journal of Global Agriculture and Ecology**, v. 4, n. 4, p. 199–209, 2016.

- SKORUPA, A. L. *et al.* Similar soils but different soil-forming factors: converging evolution of inceptisols in Brazil. **Pedosphere**, Elsevier v. 27, n. 4, p. 747–757, 2017.
- SRIVASTAVA, P.; SHUKLA, A.; BANSAL, A. A comprehensive review on soil classification using deep learning and computer vision techniques. **Multimedia Tools and Applications**, v. 80, n. 20, p. 14887–14914, 2021.
- SRUNITHA, K.; PADMAVATHI, S. Performance of SVM classifier for image-based soil classification. *In*: PROC. IEEE INTERNATIONAL CONFERENCE ON SIGNAL PROCESSING, COMMUNICATION, POWER AND EMBEDDED SYSTEMS (SCOPE). 2016, Paralakhemundi, India. **Anais [...]** Paralakhemundi, India: IEEE, 2016. p. 411–415.
- SUDDARTH, S. R. *et al.* Can humic substances improve soil fertility under salt stress and drought conditions? **Journal of Environmental Quality**, Wiley Online Library v. 48, n. 6, p. 1605–1613, 2019.
- SUTTON, R. S.; BARTO, A. G. **Reinforcement Learning: An Introduction**. Second, in progress. Cambridge, Massachusetts; London, England: A Bradford Book, The MIT Press, 2015.
- TARSAIA, P.; KASPRZYK, R. K. Deep learning algorithms in computer vision. *In*: PROCEEDINGS OF THE 37TH INTERNATIONAL BUSINESS INFORMATION MANAGEMENT ASSOCIATION. 2021, Cordoba, Spain. **Anais [...]** Cordoba, Spain: IBIMA, 2021. p. 11147–11155. ISBN 978-0-9998551-6-4.
- TEIXEIRA, P. C. *et al.* (Ed.). **Manual de métodos de análise de solo**. 3. ed. Brasília, DF: Embrapa, 2017. 393-396 p.
- United States Soil Conservation Service. **A Basic System of Soil Classification for Making and Interpreting Soil Surveys – Handbook No. 436**. Washington (DC), USA: United States Dept. of Agriculture, 1975.
- VASQUES, G. *et al.* Soil classification using visible/near-infrared diffuse reflectance spectra from multiple depths. **Geoderma**, Elsevier v. 223, p. 73–78, 2014.
- WRB, I. W. G. **World Reference Base for Soil Resources. International soil classification system for naming soils and creating legends for soil maps. 4th edition**. Vienna, Austria: International Union of Soil Sciences (IUSS), 2022. ISBN 979-8-9862451-1-9.
- ZHAN, L. tong *et al.* An efficient classification system for excavated soils using soil image deep learning and tdr cone penetration test. **Computers and Geotechnics**, v. 155, p. 105207, 2023.