

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

Uma Nova Abordagem para Avaliação de Carbono e Nitrogênio do Solo por Análise de Imagem: Um Caso de Estudo com Latossolos e Cambissolos

Juliano T. Rinaldi^{1*}, Dalcimar Casanova¹, Larissa M. Tonial², Marcelo Teixeira¹, Heitor S. Lopes³

Abstract: This paper presents a new method for predicting carbon and nitrogen content in Oxisols and Inceptisols soils using image analysis. The dataset comprises 40 Oxisols images and 51 Inceptisols images collected in southern Brazil. The images were segmented to isolate the soil area, resulting in the extraction of 12,744 windows. A pre-trained EfficientNetV2-S model was fine-tuned for regression, adding five layers at the end. The model was evaluated using RMSE and R^2 metrics. Two experiments were conducted: one predicting carbon and nitrogen content for each window and another predicting the median values of the windows for each soil sample. The results show that the median-based prediction significantly improved model performance, achieving an R^2 of 0.7425 for carbon and 0.7774 for nitrogen. This method offers a faster, non-destructive alternative to laboratory analysis for estimating soil carbon and nitrogen content, contributing to sustainable agricultural practices.

Keywords: Soil — Carbon — Nitrogen — Transfer-Learning — Deep Learning

Resumo: Este artigo apresenta um novo método para predição de teor de carbono e nitrogênio em solos Latossolo e Cambissolo por meio de análise de imagens. O conjunto de dados inclui 40 imagens de Latossolo e 51 imagens de Cambissolo coletadas no sul do Brasil. As imagens foram segmentadas para isolar a área do solo, resultando na extração de 12.744 janelas. Um modelo EfficientNetV2-S pré-treinado foi ajustado para regressão, com a adição de cinco camadas ao final. O modelo foi avaliado utilizando as métricas RMSE e R^2 . Foram realizados dois experimentos: um prevendo o teor de carbono e nitrogênio para cada janela e outro prevendo os valores medianos das janelas para cada amostra de solo. Os resultados mostram que a predição baseada na mediana melhorou significativamente o desempenho do modelo, alcançando um R^2 de 0,7425 para o carbono e 0,7774 para o nitrogênio. Este método oferece uma alternativa mais rápida e não destrutiva à análise laboratorial para estimar o teor de carbono e nitrogênio do solo, contribuindo para práticas agrícolas sustentáveis.

Palavras-Chave: Solo — Carbono — Nitrogênio — Transferência de Aprendizado — Aprendizado Profundo

¹PPGEEC, Universidade Tecnológica Federal do Paraná (UTFPR), Brasil

²PPGAG, Universidade Tecnológica Federal do Paraná (UTFPR), Brasil

³CPGEI, Universidade Tecnológica Federal do Paraná (UTFPR), Brasil

*Corresponding author: julianorinaldi@gmail.com

DOI: <http://dx.doi.org/10.22456/2175-2745.143392> • Received: 21/10/2024 • Accepted: 03/01/2025

CC BY-NC-ND 4.0 - This work is licensed under a Creative Commons Attribution-NonCommercial-NoDerivatives 4.0 International License.

1. Introdução

Entre os solos do Brasil, os Latossolos e Cambissolos ocupam uma vasta extensão territorial [1], sendo comum encontrarmos estes solos em toda América do Sul [2].

Originados por processos pedogenéticos, os Latossolos são caracterizados por sua textura argilosa e coloração predominantemente avermelhada ou amarelada, como ilustrado

na Figura 1. Apresentam estrutura granular que proporciona alta porosidade e permeabilidade, mesmo em condições de elevada concentração de argila. Sua composição química revela teores significativos de cálcio e fósforo, contudo, a disponibilidade de outros nutrientes essenciais para o desenvolvimento vegetal é limitada. Apesar desta característica, estes solos demonstram elevado potencial produtivo para culturas de grande importância econômica na agricultura, como

soja, milho, sorgo e algodão [3].

Os Cambissolos são solos frágeis, frequentemente encontrados em relevos acidentados, com características de densidade elevada e pequena profundidade, restringindo o desenvolvimento das raízes vegetais em profundidade [4]. A Figura 2 ilustra a variação entre os horizontes dos Cambissolos, particularmente em relação à cor e textura. Embora a fertilidade natural seja limitada, considerando o manejo adequado destes solos, promovem alta produtividade das culturas, sendo amplamente utilizados para agricultura e pecuária [1].




Figure 1. Tipos de latossolos.
(a) vermelho (b) vermelho-amarelo
(c) amarelo (d) marrom. [5].




Figure 2. Tipos de cambissolos: (a) húmico (b) háplico (c) fúlvico. [5].

Em comum, os solos possuem variações naturais nos teores de carbono e nitrogênio, que são elementos de grande importância para a saúde e produtividade do solo. O carbono, está presente em formas orgânicas e inorgânicas, desempenha papel fundamental na estrutura do solo, retenção de água e nutrientes, além de atividade microbiana. Já o nitrogênio é um macronutriente essencial para as plantas, influencia diretamente o crescimento vegetal e a produção de clorofila.

Na agricultura, é essencial conhecer a relação carbono e nitrogênio, pois é um indicador chave da qualidade do solo e de produtividade, ou seja, através desta análise, é possível realizar escolhas certas em termos de culturas sustentáveis, rotação e fertilização. [6]

Nesse contexto, os métodos mais comuns para estimar

carbono e nitrogênio no solo são: 1) Análise Elementar (combustão via seca); 2) Análise Kjeldahl (para nitrogênio); 3) Análise de Combustão por via Úmida (para carbono orgânico); 4) Métodos Espectroscópicos (NIR - *Near Infrared Reflectance*). Esses métodos tradicionais requerem equipamentos especializados, reagentes caros e comumente destrutivos. Além disso, alguns não diferenciam entre as diversas formas de carbono e nitrogênio (orgânico vs inorgânico) e podem ser afetados por interferências de outros componentes do solo. Isso destaca a necessidade de métodos mais rápidos, precisos e não destrutivos. Nessa perspectiva, métodos que sejam simples e rápidos, estão ganhando interesse, especialmente para uso em campo e em situações onde a rapidez é essencial.

A análise de imagens RGB apresenta-se como uma alternativa, e alguns trabalhos nessa linha já vem sendo desenvolvidos (e.g. [7, 8]). Ainda que os resultados sejam encorajadores, esses trabalhos estimam apenas o valor de carbono e são aplicados a solos extremamente diferentes (i.e. areia, argila, silte), facilitando assim obtenção de bons resultados.

Com esse cenário em mente, nosso trabalho propõe um novo método de predição do teor de carbono e nitrogênio em Latossolos e Cambissolos via análise de imagens RGB. Essa análise pode ajudar a obter estimativas mais acuradas e úteis para práticas agrícolas sustentáveis e manejo do solo.

2. Trabalhos Relacionados

Dentre os trabalhos que tem objetivo estimar as propriedades químicas do solo, temos [7], que desenvolveu uma metodologia para determinação do teor de carbono orgânico e textura, utilizando imagens digitais. Analisadas 177 amostras de solos de diferentes regiões do Brasil, os autores correlacionaram as imagens obtidas por um *scanner* de mesa com parâmetros de fertilidade, como teor de carbono orgânico e textura do solo (areia, argila e silte). Utilizando métodos de calibração multivariada, o estudo demonstrou que a técnica LSSVM apresentou os melhores resultados com R^2 de 0,9287.

O trabalho de [8], propôs combinar o PCA com o agrupamento Fuzzy C-Means (FCM) e a Regressão de Mínimos Quadrados Parciais (PLSR) para prever o conteúdo de carbono orgânico do solo. Usando o conjunto de dados LUCAS, a técnica envolveu a seleção aleatória de centros de clusters iniciais com o FCM e a utilização do PCA apenas para o processo de agrupamento. A PLSR foi então aplicada para prever efetivamente o carbono orgânico do solo, como resultado, foi obtido um Root Mean Square Error (RMSE) de 1,20; e R^2 de 6,80.

Esse trabalho se diferencia dos demais por: 1) estimar o teor de carbono e nitrogênio em única análise e 2) estimar os teores de carbono e nitrogênio em 2 tipos de solo, que em teoria, deve produzir um modelo mais confiável em comparação a modelos que não consideram o tipo de solo na análise.

3. Materiais e métodos

3.1 Aquisição de imagem

O conjunto de dados utilizado neste estudo compreende 40 imagens de Latossolos e 51 de Cambissolos, coletadas em diferentes localidades da região sul do Brasil.

As Figuras 3 e 4 ilustram amostras representativas das imagens utilizadas, cada qual correspondendo a aproximadamente 20cm^3 de solo. Para obter as imagens, foi realizada uma preparação metódica do ensaio, fundamentada em estudos que destacam a relevância de tratar adequadamente as amostras de solo. Entre os processos recomendados estão a moagem e o peneiramento, que contribuem significativamente para a precisão e a confiabilidade de modelos preditivos utilizados no diagnóstico das propriedades do solo [9]. Diante disso, as amostras foram submetidas à secagem ao ar, moídas, peneiradas em malha de 2 mm e dispostas em placas de Petri com 9 cm de diâmetro. As amostras de Latossolos foram coletadas predominantemente na faixa de 0 a 10 cm de profundidade, com algumas amostras adicionais provenientes de trincheiras com mais de 1 m. Já as amostras de Cambissolos, por sua vez, foram coletadas em profundidades que variaram de 0 a 20 cm.




Figure 3. Amostra Latossolo.




Figure 4. Amostra Cambissolo.

O sistema de aquisição de imagens consistiu em dois componentes principais: uma câmera de *smartphone* (Samsung SM-J415G), e uma caixa de papelão de dimensões: 30 cm × 22 cm × 12 cm, conforme ilustrado na Figura 5.

A caixa foi completamente pintada de preto para minimizar reflexos internos e vedada de forma a isolar a luz externa. Para garantir uma iluminação controlada durante a captura das imagens, utilizou-se o *flash* da câmera. O sistema incluiu uma área designada para a placa de Petri e uma abertura específica para a câmera, posicionada a uma distância fixa de 12 cm.

A câmera do *smartphone* SM-J415G apresenta uma abertura focal de f/1.9, permitindo uma excelente entrada de luz, o que é ideal em situações de iluminação limitada, como acontece com nosso método. Com uma distância focal de 28 mm, a câmera oferece um campo de visão amplo, capaz de capturar eficientemente a área da placa de Petri mesmo a uma curta distância de 12 cm. Além disso, conta com recursos como foco automático e estabilização de imagem digital, assegurando que as imagens sejam nítidas e bem definidas [10]. Para a captura das fotos, priorizamos a compatibilidade entre

os aplicativos para uso futuro, e optamos por não utilizar o aplicativo padrão do *smartphone*. Em vez disso, escolhemos o Open Camera [11], um aplicativo gratuito disponível na Google Play Store. Durante o processo de captura, utilizamos as configurações padrão do Open Camera, garantindo uma resolução de 4128×3096 pixels para as imagens.

O *smartphone* utilizado para a aquisição das imagens é um dispositivo popular, lançado em 2018 e com um preço inferior a R\$ 1000,00. Atualmente não é considerado um modelo de prestígio, com sistema operacional Android 9 já defasado, sendo possível encontrar atualmente opções superiores em *hardware* e *software* pelo mesmo valor de investimento. No entanto, o uso de um dispositivo acessível traz benefícios significativos, pois facilita a replicação dos experimentos por outros pesquisadores, promovendo o aprimoramento da pesquisa científica.




Figure 5. Representação ilustrativa do sistema construído para a captura de imagens

3.2 Análise Laboratorial

Diante das amostras dos solos já processadas (secas, moídas, e peneiradas), foi realizada análise química em laboratório especializado, seguindo procedimentos de avaliação do teor de carbono e nitrogênio em duplicata pelo método de combustão a seco [12], utilizando um analisador elementar modelo Flash EA1112 (Thermo Electron Corporation, Milão, Itália).

O analisador elementar submete as amostras a altas temperaturas, e o CO_2 gerado pela combustão dos compostos orgânicos é quantificado por meio de uma célula detectora de infravermelho. Assim, ao final do processo, é calculado a proporção em porcentagem de carbono e nitrogênio que compõe o solo.

3.3 Particionamento de amostras

As Figuras 3 e 4 ilustram que as imagens, além do solo (objeto de interesse), contêm elementos adicionais, como o fundo texturizado da caixa (cor escura) e a borda do recipiente de vidro (cor branca). Esses elementos são irrelevantes para a análise dos solos, portanto, foram removidos por meio de técnicas de segmentação e processamento de imagem explicados a seguir, assim, foi possível isolar a área de interesse e garantir que apenas o solo fosse considerado na etapa de treinamento e teste.

Para isolar o objeto de interesse (solo) e otimizar a análise, um método sistemático foi empregado para recortar subamostras,

denominadas "janelas", da imagem original (4128×3096 pixels). Cada janela, com dimensões de 256×256 pixels, abrangeu uma fatia específica da área do solo.

Um total de 12.744 janelas de 256×256 pixels foram extraídas das imagens originais. Este conjunto foi então particionado em dois subconjuntos: um conjunto de treinamento, e validação (36 cambissolos, 28 latossolos), contendo 8.901 imagens (aproximadamente 70% das janelas), e um conjunto de teste (15 cambissolos, 12 latossolos), com 3.843 imagens (aproximadamente 30% das janelas), é importante ressaltar que diferentes janelas de uma mesma amostra de solo ficaram agrupadas ou no subconjunto de treino ou no subconjunto de teste, eliminando assim qualquer forma de contaminação nos dados de treinamento (i.e. a Figura 6 oferece uma visualização representativa das duas classes de solos latossolos e cambissolos presentes no estudo, ilustrando a diversidade de padrões e características encontradas nas imagens).




Figure 6. Exemplos de janelas Latossolos e Cambissolos.

3.4 Modelo de previsão

Para esse trabalho, uma rede do tipo deep learning será utilizado. Trata-se de um modelo de aprendizado *end-to-end* capaz de aprender a representação dos dados de entrada, desde a imagem bruta até a predição de percentagens de carbono e nitrogênio. Essa estratégia é especialmente vantajosa quando a extração manual de características relevantes se mostra complexa ou desconhecida. Com modelos *end-to-end*, a própria rede neural aprende a identificar e extrair as características mais discriminantes das imagens.

Em vez de criar um modelo do zero, optou-se por utilizar um modelo pré-treinado. Nesse trabalho será utilizado um modelo com camadas congeladas pré-treinadas, e agregou-se ao final do modelo apenas 5 camadas, utilizando os pesos

pré-definidos do ImageNet, que é uma base de dados visual de grande escala amplamente utilizada no treinamento de modelos de redes neurais convolucionais para tarefas de reconhecimento de imagens [13]. As principais vantagens de usar a transferência de aprendizado são: economia de tempo de treinamento, desempenho aprimorado em comparação com o treinamento do zero (na maioria dos casos) e, possivelmente o mais importante, não precisar de muitos dados [14].

Nesse estudo, a quantidade de dados disponíveis para treinamento está longe de ser suficiente para treinar uma grande rede neural do zero. Com a transferência de aprendizado, um modelo sólido de aprendizado de máquina pode ser usado para extrair características de imagens, e agregar na saída poucas camadas, considerando a última, uma simples camada densa de 2 neurônios para obter resultado da regressão de teor de carbono e teor de nitrogênio do solo. Para treinar estas camadas, poucos dados são necessários. No geral, o esforço computacional para criar um modelo eficiente de predição é relativamente pequeno usando um modelo pré-treinado [15]. Vários modelos serão testados na fase de seleção de modelo 3.5, e o melhor será utilizado para os experimentos finais.

3.5 Seleção do modelo

Para avaliação do modelo utilizamos o *hold-out* em conjunto com um *5-fold* para seleção dos hiperparâmetros, como mostrado na Figura 7. Neste método, usamos 70% das amostras disponíveis para o conjunto treinamento/validação (seleção do modelo) e 30% para testar o modelo (i.e. conjunto azul escuro e verde na Figura 7 respectivamente). Nesta divisão, o cuidado foi tomado para garantir que as janelas da mesma amostra de solo permanecessem exclusivamente no conjunto de treinamento ou no conjunto de teste. Tal procedimento garante que o conjunto de teste contenha apenas amostras não incluídas na seleção do modelo.

Do conjunto de treinamento, 70% das janelas foram selecionadas para treinamento e 30% para validação (conjunto azul claro e o conjunto rosa claro na Figura 7 respectivamente). Uma série de redes pré-treinadas sobre o ImageNet, hiperparâmetros padronizados e formas de pré-processamento foram testados a saber:

- Redes: ConvNeXtBase, ConvNeXtXLarge, DenseNet169, EfficientNetV2L, EfficientNetV2S, InceptionResNetV2, ResNet101, ResNet152, ResNet50, VGG19;
- Hiperparâmetros:
 - camada de classificação treinada do modelo padrão removida, devido ao uso como *transfer-learning*.
 - pesos pré-definidos sobre o ImageNet.
 - camada de *pooling* (AVG) para agregar as características da imagem em um único vetor antes de adicionar camadas posteriores.




Figure 7. Ilustração do método de 3 vias hold-out. Adaptado de [16].

- Congelamento de camadas: as camadas pré-treinadas são congeladas para preservar o aprendizado sobre pesos do ImageNet e usar o modelo padrão apenas como extrator de características.
- Adição de novas camadas:
 - Camada densa 128 neurônios com ativação ReLU.
 - Camada *dropout* configurado em 0,5 para regularização e evitar *overfitting*.
 - Camada densa 64 neurônios com ativação ReLU.
 - Camada de saída 2 neurônios com ativação linear.
- Otimizador: RMSprop configurado com valores *default* para atualizar os pesos durante o treinamento.
- *Loss*: função de perda com uso do erro quadrático médio (MSE).
- Métrica de avaliação: erro absoluto médio (MAE).
- Normalização dos dados:
 - Sem normalização.
 - MinMaxScaler: escala os dados entre 0 e 1.
 - RobustScaler: remove a mediana e escala os dados com base no intervalo interquartil.
 - StandardScaler: remove a média e escala os dados para que tenham variância unitária.
- Pré-processamento das imagens:
 - Sem pré-processamento.
 - Normalização pelo modelo: ajusta os valores dos pixels para uma faixa de 0 e 1 ou -1 e 1.
 - Centralização pelo modelo: subtrai a média dos canais de cor.

- Escalonamento pelo modelo: divide os valores dos pixels pelo desvio padrão dos canais de cor.

Com base nos resultados obtidos sobre uma validação cruzada do tipo *5-fold*, o modelo EfficientNetv2S teve resultados superiores aos demais, se destacando sem a necessidade de processamento de imagem ou normalização dos dados. A configuração final do modelo é mostrado na Tabela 1.

Camada	Saída	Parâmetros	Treinável?
efficientnetv2-s	1280	20331360	não
denso	128	163968	sim
<i>dropout</i>	128	0	não
denso	64	8256	sim
denso	2	130	sim

T. parâmetros: 20503714 Parâmetros treináveis: 172354

Table 1. Resumo do modelo de *transfer-learning* sobre o EfficientNetv2S

3.6 Avaliação do modelo

Foram realizados dois experimentos com o conjunto de teste, da seguinte forma:

- Experimento 1: Utilizou as fatias obtidas pelo particionamento (janelas) das imagens originais descrito no tópico 3.3. Após realizado treinamento, e aplicado as predições sobre o conjunto de janelas não conhecidas pelo modelo (teste), extraímos as métricas RMSE e R^2 para estimar a performance do modelo. No tópico 4 apresenta-se os valores de cada métrica, bem como, alguns resultados preditos.
- Experimento 2: Trabalhamos com os dados obtidos no experimento 1, contudo, neste, aplicamos cálculo da

média ou mediana sobre o agrupamento das janelas, para formar o conjunto real da amostra do solo. Como as métricas da mediana se destacaram superior, seguiremos o experimento 2 apenas com a mediana, para assim, obtermos outra visão sobre os resultados, procurando responder como se comporta a predição sobre as imagens originais dos solos.

Por se tratar de um processo de regressão, que envolve a predição numérica aproximada dos resultados reais, seguiremos análise com apenas as métricas a seguir:

- **RMSE:** Raiz do Erro Quadrático Médio, é a raiz quadrada do MSE, o que significa que ele também mede a discrepância média entre os valores preditos e os valores reais. No entanto, ao calcular o RMSE, retorna à mesma unidade de medida dos dados originais, tornando-o mais interpretável do que o MSE. Assim como o MSE, o RMSE é sensível a outliers e é frequentemente utilizado para otimizar modelos de regressão, minimizando o erro de predição [17].
- **R²:** Coeficiente de determinação, é uma métrica estatística que avalia a qualidade do ajuste de um modelo em regressão linear. Indica o quanto o modelo consegue explicar a variabilidade nos dados observados. Um R² de valor muito próximo a 1, indica que o modelo se ajusta perfeitamente aos dados, por outro lado, um R² de valor muito próximo a 0 indica que o modelo não explica nenhuma da variabilidade nos dados, ou seja, não é melhor do que simplesmente usar a média da variável dependente como previsão [18].

4. Resultados e Discussões

Nesta seção, os resultados dos dois experimentos serão analisados e discutidos, com base na metodologia e abordagem contextualizada apresentadas anteriormente. O objetivo é estabelecer relações, identificar padrões e explorar as implicações dos achados para o problema da pesquisa em questão.

4.1 Experimento 1

No experimento 1 tentou-se estimar os teores de carbono e nitrogênio de cada uma das janelas de texturas obtidas das amostras originais (tópico 3.3). Foram no total 8.901 janelas de imagens para treino/validação e 3.843 para teste.

Analisando os resultados, obteve-se um R² de 0,5012 para Carbono (C) e 0,5201 para Nitrogênio (N) (Tabela 2), demonstrando que o modelo não está capturando todas as nuances dos dados. Contudo, a avaliação é feita sob o ponto de vista de janelas ou fatias extraídas das amostras originais do solo. Essa abordagem granular permite analisar a performance do modelo em diferentes partes da amostra (i.e. janelas), mas pode ser influenciada por variações locais e heterogeneidades dentro da amostra.

Utilizando a métrica RMSE, que é mais simples de avaliar do que o MSE, pois traz a métrica de volta para a mesma

unidade dos dados, indica que, em média, os resíduos do modelo têm uma magnitude de aproximadamente 0,9160 unidades de (C) e 0,0755 de (N). Novamente, considerando as médias e desvio padrão dos dados de teste (Tabela 3), os valores de RMSE são considerados insatisfatórios, traduzindo em um modelo de baixo desempenho nas previsões.

	Carbono (C)	Nitrogênio (N)
R2	0,5012	0,5201
RMSE	0,9160	0,0755

Table 2. Resultados experimento 1. Avaliação realizada sobre as janelas de textura.

	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

Table 3. Resumo de dados de Teste.

A Tabela 4 apresenta alguns resultados das amostras que obtiveram as melhores e piores predições. Conclui-se pelos resultados que ao prever os teores de carbono e nitrogênio nas janelas de textura, o modelo enfrenta o desafio da variabilidade inerente a cada pedaço do solo uma vez que tais valores são preditos sobre apenas uma pequena porção do solo, oferecendo uma visão limitada do todo.

4.2 Experimento 2

Para o Experimento 2, trabalhou-se apenas com dados gerados do Experimento 1, sendo assim, calculamos a mediana das janelas de uma mesma amostra de solo, vale diferenciar do Experimento 1 que tratou efetivamente das predições. Na estratégia do Experimento 2, a representação de cada amostra de solo torna-se unitária novamente devido a mediana das janelas de mesma amostra, resultando no teor de carbono e nitrogênio desta amostra.

Os resultados foram superiores em comparação ao Experimento 1 (4.1), conseguindo capturar informações mais precisas e representativas quando consideradas sobre a mediana (Tabela 5).

Em comparação com o Experimento 1, um R² maior, de 0,7425 (C) e 0,7774 (N); indica que o modelo se tornou mais eficiente em capturar a variabilidade dos dados reais do solo na janela que representa a mediana. Valores inferiores para métrica RMSE (Tabela 5), indica que os erros na predição da janela que representa a mediana são menores, resultando em previsões mais precisas e confiáveis. Isso é crucial para a aplicação prática, onde a precisão dos dados de carbono

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

Table 4. Resultados de carbono e nitrogênio Experimento 1. Amostras com melhores e piores previsões sobre as janelas. Sigla: (C) Cambissolo; (L) Latossolo

	Carbono (C)	Nitrogênio (N)
R2	0,7425	0,7774
RMSE	0,6634	0,0510

Table 5. Resultados experimento 2. Avaliação realizada sobre a mediana das janelas de solo.

e nitrogênio são fundamentais para o manejo do solo e a agricultura. Por fim, constatou-se a melhoria de performance do modelo pela mediana, observando as melhores e as piores previsões deste experimento na Tabela 6.

4.3 Limitações do Estudo

Apesar dos resultados promissores alcançados neste estudo, algumas limitações devem ser consideradas. A principal delas é a restrição a dois tipos de solo, latossolos e cambissolos. Não é possível afirmar se a abordagem utilizada teria o mesmo desempenho em outros tipos de solo, ou mesmo em amostras do mesmo tipo coletadas em regiões geográficas distantes, que podem apresentar variações em sua composição e estrutura. Além disso, a coleta e o tratamento das amostras foram realizados seguindo um método específico, incluindo secagem, moagem, peneiramento com malha de 2 mm e armazenamento em placas de Petri. Alterações nesses procedimentos, como o uso de peneiras com diâmetro diferente ou outros métodos de preparação, poderiam impactar os resultados obtidos.

Outro ponto a ser destacado é o sistema de aquisição de imagens, que contou com uma câmera de *smartphone* específica

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

Table 6. Resultados de carbono e nitrogênio Experimento 2. Amostras com melhores e piores previsões pela mediana. Sigla: (C) Cambissolo; (L) Latossolo

e iluminação controlada em uma caixa pintada de preto. Não se sabe se mudanças na configuração da câmera, como o uso de um modelo mais avançado ou com especificações diferentes, poderiam produzir resultados superiores ou inferiores. Adicionalmente, o uso de outro método de iluminação ou uma variação no ambiente de captura pode afetar diretamente a qualidade das imagens e, consequentemente, o desempenho do modelo. Por fim, o estudo se baseou em redes de aprendizado por transferência específicas e contou com uma base limitada de amostras de solo (51 cambissolos e 40 latossolos). O impacto de um conjunto de dados mais robusto ou de metodologias alternativas de aprendizado, como redes específicas desenvolvidas para características de solos, permanece desconhecido, abrindo espaço para investigações futuras.

5. Conclusão

Concluímos que as previsões pela mediana se demonstraram uma estratégia eficaz para melhorar significativamente os resultados dos teores de carbono e nitrogênio quando se utiliza o particionamento (janelas) das amostras de solo. A análise dos resultados sugere que a mediana reduz o ruído e a variabilidade das previsões em relação às fatias da amostra, permitindo que o modelo capture padrões mais lineares e gere estimativas mais precisas. No entanto, o tamanho reduzido do conjunto de dados, com apenas 91 amostras de solo, embora tenha gerado 12.744 janelas de imagens, pode ter sido insuficiente para treinar um modelo verdadeiramente robusto. Um conjunto

de dados maior, com maior variabilidade, poderia melhorar a capacidade de generalização do modelo.

Além disso, a qualidade das imagens e o processo de captura com um *smartphone* em condições de iluminação controlada de forma simples, pode ter contribuído para o baixo desempenho. A iluminação é um fator crucial na padronização das capturas, podendo influenciar diretamente a extração de características.

As limitações observadas neste trabalho abrem espaço para diversas linhas de pesquisa futura, como o método de preparação das amostras: que seguiu procedimentos padronizados com peneiras de 2 mm e armazenamento em placas de Petri, pode ser expandido para testar outras abordagens, uso de peneiras com diâmetros diferentes ou métodos alternativos de preparação do solo.

Em relação aos tipos de solo, há uma ampla oportunidade de aprimoramento deste trabalho, ou seja, incluir outros tipos de solos na pesquisa e verificar se o método mantém sua eficácia em diferentes composições e características. Além disso, investigar o impacto de amostras coletadas em locais geograficamente distantes poderia revelar a influência da heterogeneidade regional nos resultados.

Outra linha promissora seria explorar diferentes metodologias de captura de imagens, testando câmeras com especificações variadas e condições de iluminação mais sofisticadas. Experimentos com outros métodos de segmentação e extração de sub-amostras também poderiam trazer avanços significativos.

No âmbito do aprendizado de máquina, a arquitetura do modelo, baseada no EfficientNetV2S com apenas cinco camadas adicionais, pode ter limitado o desempenho. Há diversos cenários de aperfeiçoamento, como: adição de mais camadas, troca por modelos desenvolvidos especificamente para análise de solos, ou aplicação de novas técnicas mais profundas de *machine-learning*, poderia aumentar a capacidade do modelo de capturar as nuances dos dados de solo, resultando em previsões mais acuradas.

Embora o método proposto tenha demonstrado resultados promissores na análise de solos, comparações diretas com outras técnicas de análise ou modelos alternativos de aprendizado de máquina não foram realizadas no presente estudo. Essa decisão foi motivada por limitações de tempo e recursos disponíveis.

Essas propostas, combinadas com a ampliação do conjunto de dados e o uso de amostras mais diversas, podem levar a avanços significativos na compreensão e predição das propriedades do solo, consolidando este estudo como uma base sólida para pesquisas futuras.

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

Durante a preparação deste trabalho, os autores utilizaram ferramentas de *Large Language Model* para auxiliar na escrita. Após o uso desta ferramenta/serviço, os autores revisaram e

editaram o conteúdo conforme necessário e assumem total responsabilidade pelo conteúdo da publicação.

Author contributions

Juliano Tiago Rinaldi: Conceptualization, Methodology, Software, Validation, Formal analysis, Investigation, Data Curation, Writing - Original Draft, Writing - Review & Editing, Visualization; Dalcimar Casanova: Conceptualization, Methodology, Validation, Formal analysis, Resources, Writing - Original Draft, Writing - Review & Editing, Supervision, Project administration, Funding acquisition; Larissa Macedo dos Santos Tonial: Conceptualization, Formal analysis, Investigation, Resources, Writing - Original Draft, Writing - Review & Editing; Heitor Silvério Lopes: Methodology, Validation, Formal analysis, Writing - Review & Editing; Marcelo Teixeira: Methodology, Validation, Formal analysis, Writing - Review & Editing.

Referências

- [1] SILVA, F. M. et al. Using proximal sensors to assess pedogenetic development of inceptisols and oxisols in brazil. *Geoderma Regional*, v. 28, p. e00465, 2022. ISSN 2352-0094. Disponível em: <https://bit.ly/3zZKkYL>.
- [2] SKORUPA, A. L. et al. Similar soils but different soil-forming factors: Converging evolution of inceptisols in brazil. *Pedosphere*, v. 27, n. 4, p. 747–757, 2017. ISSN 1002-0160. Disponível em: <https://bit.ly/3Yw8tyr>.
- [3] GONÇALVES, T. D.; LOHE, C.; CAMPOS, J. E. G. Hydraulic characterization from porous aquifers of the brazilian federal district. *Brazilian Journal of Geology*, SciELO, v. 45, n. 2, p. 259–271, 2015. Disponível em: <https://bit.ly/3BPllqn>.
- [4] PINTO, L. C. et al. Role of inceptisols in the hydrology of mountainous catchments in southeastern brazil. *Journal of Hydrologic Engineering*, v. 21, n. 2, p. 05015017, 2016. Disponível em: <https://bit.ly/3NvHY6U>.
- [5] FONTANA, A.; BALIEIRO, F. de C.; PEREIRA, M. G. *Classes de solos do Brasil: Sistema Brasileiro de Classificação de Solos*. [S.l.]: Embrapa Solos & UFRRJ, 2020.
- [6] SCIENTIFICA, V. *Carbon and Nitrogen Analysis in Soil for Sustainable Agriculture and Farming*. 2021. Disponível em: <https://bit.ly/3LKacdh>.
- [7] 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>.
- [8] 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)*. [s.n.], 2024. p. 1–4. Disponível em: <https://bit.ly/4dk9HCl>.
- [9] BARRA, I.; MOATASSEM, T. E.; KEBEDE, F. Soil particle size thresholds in soil spectroscopy and its effect on the multivariate models for the analysis of soil properties. *Sensors*, v. 23, n. 22, 2023. ISSN 1424-8220. Disponível em: <https://bit.ly/4iP11rt>.
- [10] TUDOCCELULAR. *Ficha técnica do Samsung Galaxy J4 Plus*. Acessado Dez. 2024. Disponível em: <https://bit.ly/3BB9Kg4>.
- [11] GOOGLEPLAY. *Aplicativo Open Camera*. Acessado Dez. 2024. Disponível em: <https://bit.ly/3P5uAao>.
- [12] 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>.
- [13] DENG, J. et al. Imagenet: A large-scale hierarchical image database. In: *2009 IEEE Conference on Computer Vision and Pattern Recognition*. [s.n.], 2009. p. 248–255. Disponível em: <https://bit.ly/4dPew6D>.
- [14] GUTOSKI, M. et al. A comparative study of transfer learning approaches for video anomaly detection. *International Journal of Pattern Recognition and Artificial Intelligence*, v. 35, n. 05, p. 2152003, 2021. Disponível em: <https://bit.ly/3YtUJW7>.
- [15] AQUINO, M. R. et al. A study of the influence of data complexity and similarity on soft biometrics classification performance in a transfer learning scenario. *Learning and Nonlinear Models*, v. 18, p. 56–65, 06 2021. Disponível em: <https://bit.ly/40aoTPs>.
- [16] KUMAR, A. *Hold-out method for training machine learning models*. 2022. Disponível em: <https://bit.ly/3LP0KFm>.
- [17] CHAI, T.; DRAXLER, R. R. Root mean square error (rmse) or mean absolute error (mae)? – arguments against avoiding rmse in the literature. *Geoscientific Model Development*, v. 7, p. 1247–1250, 2014. Disponível em: <https://bit.ly/4doeL8O>.
- [18] KVÅLSETH, T. O. Cautionary note about r 2. *The American Statistician*, ASA Website, v. 39, n. 4, p. 279–285, 1985. Disponível em: <https://bit.ly/4d1wR0y>.