

JÔ VINÍCIUS BARROZO CHAVES

**APRENDIZADO DE MÁQUINA APLICADO NA ANÁLISE DE
AGREGADOS DE SOLOS AGRÍCOLAS EM REGIÕES TROPICAIS**

Sorocaba

2025

PROGRAMA DE PÓS-GRADUAÇÃO em

*ciências
ambientais*



unesp
Sorocaba

JÔ VINÍCIUS BARROZO CHAVES

**APRENDIZADO DE MÁQUINA APLICADO NA ANÁLISE DE
AGREGADOS DE SOLOS AGRÍCOLAS EM REGIÕES TROPICAIS**

Tese apresentada como requisito para a obtenção do título de Doutor em Ciências Ambientais da Universidade Estadual Paulista "Júlio de Mesquita Filho" na Área de Concentração Diagnóstico, Tratamento e Recuperação Ambiental

Orientador: Prof. Dr. Admilson Írio Ribeiro

Coorientadoras: Prof.^a Dr.^a Lia Toledo Moreira
Mota; Prof.^a Dr.^a Regina Márcia Longo

Sorocaba

2025

C512a Chaves, Jô Vinícius Barrozo
Aprendizado de máquina aplicado na análise de agregados de solos agrícolas em regiões tropicais / Jô Vinícius Barrozo Chaves. – Sorocaba, 2025.
110 p. : il., tabs., fotos, mapas

Tese (Doutorado) – Universidade Estadual Paulista, Instituto de Ciência e Tecnologia, Sorocaba
Orientador: Admilson Írio Ribeiro
Coorientadora: Lia Toledo Moreira Mota
Coorientadora: Regina Márcia Longo

1. Solos – Agregação. 2. Física do solo. 3. Aprendizagem profunda (Aprendizado do computador). 4. Agricultura de precisão. 5. Agricultura sustentável. I. Título.

CDD 631.4

IMPACTO POTENCIAL DESSA PESQUISA

A análise da agregação do solo pode colaborar diretamente para o fortalecimento de uma agricultura mais sustentável e para o desenvolvimento de manejos regenerativos. A presente pesquisa apresenta potencial de impacto social positivo, alinhando-se a diferentes Objetivos de Desenvolvimento Sustentável (ODS).

Com relação aos ODS 1 (Erradicação da pobreza) e 2 (Fome zero e agricultura sustentável), a proposta busca fomentar o entendimento da agregação do solo como um indicador da qualidade do solo agrícola, cuja formação está diretamente relacionada às dinâmicas da atividade biológica e aos aspectos químicos e físicos do solo. Esse entendimento contribui para o aprimoramento das propriedades físicas, para o aumento da resistência à erosão e para a prevenção da perda de áreas férteis, aspectos fundamentais à segurança alimentar e à manutenção da produtividade agrícola.

A promoção de ambientes regenerativos e biodiversos, por sua vez, colabora para o sequestro de carbono no solo e para a melhoria da qualidade das culturas, estando diretamente relacionada à mitigação das mudanças climáticas, conforme previsto no ODS 13 (Ação contra a mudança global do clima).

A utilização do imageamento digital para a análise de agregados surge como uma alternativa inovadora para a compreensão da agregação do solo, permitindo avaliar sua capacidade de suporte e o impacto de diferentes práticas de manejo. Esse tipo de avaliação pode subsidiar a tomada de decisão em relação às práticas agrícolas, indicando aquelas que favorecem a regeneração do solo e identificando as que, ao contrário, contribuem para sua degradação. Condição essas que pode causar a redução da biodiversidade e o aumento da suscetibilidade à erosão, conforme previsto pelo ODS 15 (Vida terrestre).

Dessa forma, os resultados obtidos neste estudo podem colaborar para a tomada de decisão em implantações de práticas agrícolas mais resilientes, regenerativas e compatíveis com a conservação dos recursos naturais, promovendo benefícios ambientais e sociais em médio e longo prazo.

POTENTIAL IMPACT OF THIS RESEARCH

Soil aggregation analysis plays a critical role in advancing sustainable agriculture and supporting the development of regenerative land management practices. This research aligns with several United Nations Sustainable Development Goals (SDGs) and holds potential for positive environmental and social impact.

In the context of SDG 1 (No Poverty) and SDG 2 (Zero Hunger and Sustainable Agriculture), this study emphasizes soil aggregation as a key indicator of agricultural soil quality. Aggregate formation reflects complex interactions among biological activity, chemical composition, and physical structure of the soil. Improved aggregation contributes to enhanced physical properties, increased resistance to erosion, and the preservation of fertile topsoil, which are essential factors for food security and agricultural productivity.

Furthermore, the promotion of regenerative and biodiverse systems supports carbon sequestration in soils and enhances crop quality, directly contributing to SDG 13 (Climate Action) by mitigating the effects of climate change.

The incorporation of digital image analysis for evaluating soil aggregates represents an innovative methodological advance. This approach enables a detailed assessment of soil structural integrity and the impacts of different agricultural practices. Such insights inform evidence-based decision making, guiding the adoption of practices that promote soil regeneration and identifying those that accelerate degradation. These degradation processes reduce biodiversity and increase susceptibility to erosion, as addressed by SDG 15 (Life on Land).

In summary, the outcomes of this research can support the design and implementation of resilient and regenerative agricultural strategies that prioritize the conservation of natural resources, promoting environmental and social benefits over the medium and long term.

CERTIFICADO DE APROVAÇÃO

TÍTULO DA TESE: Aprendizado de Máquina Aplicado na Análise de Agregados de Solos Agrícolas em Regiões Tropicais

AUTOR: JÔ VINÍCIUS BARROZO CHAVES

ORIENTADOR: ADMILSON IRIO RIBEIRO

COORIENTADORA: REGINA MÁRCIA LONGO

COORIENTADORA: LIA TOLEDO MOREIRA MOTA

Aprovado como parte das exigências para obtenção do Título de Doutor em Ciências Ambientais, área: Diagnóstico, Tratamento e Recuperação Ambiental pela Comissão Examinadora:

Prof. Dr. ADMILSON IRIO RIBEIRO (Participação Presencial)
Departamento de Engenharia Ambiental / Unesp Campus Sorocaba

Prof. Dr. AFONSO PECHE FILHO (Participação Presencial)
Centro de Engenharia e Automação (CEA) / Instituto Agrônomo de Campinas (IAC)

Prof. Dr. EDSON LUIZ BOLFE (Participação Presencial)
EMBRAPA – Agricultura Digital

Prof. Dr. ZIGOMAR MENEZES DE SOUZA (Participação Presencial)
Departamento de Água e Solo / Universidade Estadual de Campinas (UNICAMP) - Campinas/SP

Prof. Dr. FELIPE HASHIMOTO FENGLER (Participação Presencial)
Engenharia Agrônômica / Centro Universitário FACENS

Sorocaba, 26 de maio de 2025

AGRADECIMENTOS

Agradeço primeiramente ao Instituto de Ciência e Tecnologia de Sorocaba/UNESP pela oportunidade e infraestrutura que permitiram a execução deste estudo, bem como a todos os colaboradores com os quais convivi no decorrer desses anos de doutorado.

Agradeço ao meu orientador Prof. Dr. Admilson Írio Ribeiro, pelo acompanhamento ao longo dos pouco mais de quatro anos de pós-graduação, que sempre esteve presente, abrindo portas com apoios e oportunidades inimagináveis que tive neste período de doutorado.

Às Prof.^a Dr.^a Lia Toledo Moreira Mota e Regina Márcia Longo, que me acompanharam e apoiaram por toda a minha carreira acadêmica, e que abriram minhas visões sobre as ciências ambientais para diferentes áreas de estudos e entendimento do meio em que vivemos.

Aos meus companheiros do Laboratório de Recuperação de Áreas Degradadas (RAD), que contribuíram para a consolidação deste trabalho, mas, para além disso, estiveram sempre presentes nos meus momentos mais alegres e, também, nos mais difíceis desse trajeto incrível de formação enquanto doutor.

À Ludmila Demartini Bernardo, essa mulher maravilhosa que me acompanha desde o início deste trajeto acadêmico, que me apoiou independentemente das nossas dificuldades e sempre esteve comigo meus momentos de maior alegria. Agradeço, também, por todo o suporte da família Demartini Bernardo, que me ajudou muito e me permitiu fazer parte da família de vocês.

Por fim, ao Antônio Casimiro Barrozo Chaves, Ieda Maria Campiol Chaves e Jean Victor Barrozo Chaves, por me apoiar e acreditar na minha jornada. Obrigado por serem o meu maior exemplo de vida.

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

O presente trabalho foi realizado com apoio em parceria com a Microbiol Indústria e Comércio S.A. (Microgeo) e da Fundação para o desenvolvimento da Unesp (Fundunesp) – do processo 3458/2023.

CHAVES, J. V. B. **Aprendizado de máquina aplicado na análise de agregados de solos agrícolas em regiões tropicais**. 2025. 110 f. Tese (Doutorado em Ciências Ambientais) – Instituto de Ciência e Tecnologia, Universidade Estadual Paulista, Sorocaba, 2025.

RESUMO

A análise de agregados do solo, fundamental para a qualidade estrutural de solos agrícolas, apresenta-se como um atributo diretamente influenciado pelas práticas de manejo agrícola. Dessa forma, estratégias de conservação de precisão vêm sendo desenvolvidas com foco em práticas de manejo adequado do solo agrícola. Nesse contexto, a avaliação da agregação configura-se como um indicador da condição solo, compreendido como um produto das dinâmicas física, química, biológica e também antrópica do meio. A identificação e análise de atributos como tamanho, forma e outras características dos agregados possibilitam a compreensão das dinâmicas do solo, contribuindo para a tomada de decisão e para a orientação de manejos mais adequados. Ressalta-se, no entanto, a complexidade morfológica dos agregados, a qual impõe desafios metodológicos e demanda abordagens mais ágeis e precisas. Diante desse cenário, o processamento de imagens digitais de alta resolução, aliado a modelos de deep learning, destaca-se como procedimento promissor para a análise da agregação solos agrícolas. Abordagens como essas favorecem a segmentação e classificação de características relevantes da agregação, contribuindo para diagnósticos detalhados e subsidiando práticas de manejo sustentável e regenerativo. Com base nesse panorama, estabeleceu-se como objetivo do trabalho, o desenvolvimento de um método baseado em sistema autônomo para subsidiar a análise de agregados de solos agrícolas de regiões tropicais, por meio da manipulação de imagens digitais e da aplicação de redes neurais convolucionais (RNC). O método de estudo proposto foi configurado em três etapas: (i) amostragem de solos e procedimentos laboratoriais, os quais viabilizaram o preparo adequado das amostras e a obtenção de ampla diversidade amostral; (ii) aquisição e processamento de imagens digitais de fragmentos visíveis dos solos, por meio da fotografia de macroagregados retidos na peneira de 4 mm, com posterior elaboração do banco de imagens e aplicação de processamentos digitais para composição dos bancos de treinamento; (iii) aplicação dos modelos de redes neurais convolucionais (CNN), etapa em que foi proposta uma CNN de baixa complexidade para classificação morfométrica de agregados, enquanto se utilizou a arquitetura U-Net para a segmentação de características representativas de perturbações físicas e biológicas. Os modelos empregados permitiram a condução de abordagens de avaliação e breves análises dos agregados, possibilitando a compreensão das características dos solos agrícolas a partir da análise de imagens digitais, com uso de modelos de deep learning. A classificação morfológica demonstrou desempenho satisfatório nas classes extremas, e a segmentação com U-Net apresentou boa precisão, mesmo diante de desafios ópticos e morfológicos. Os modelos desenvolvidos evidenciaram potencial para análises automatizadas, sobretudo em solos tropicais, com contribuições relevantes para as ciências ambientais no meio físico solo, no contexto da agricultura regenerativa e sustentável.

Palavras-chave: Deep Learning, Agregado do Solo, Morfometria dos Agregados, Bioturbação, Manejo do Solo.

CHAVES, J. V. B. **Machine learning applied to aggregate analysis of agricultural soils in tropical regions**. 2025. 110 p. Doctoral dissertation (Doctorate in Environmental Sciences) – Institute of Science and Technology, São Paulo State University, Sorocaba, 2025.

ABSTRACT

Soil aggregate analysis, which is fundamental to the structural quality of agricultural soils, is directly influenced by land management practices. In response to this, precision conservation strategies have been developed with a focus on appropriate agricultural soil management. Within this context, the evaluation of aggregation serves as an important indicator of soil condition, as it reflects the physical, chemical, biological, and anthropogenic dynamics acting upon the environment. The identification and characterization of attributes such as aggregate size, shape, and structural features enhance the understanding of soil functioning and support decision making for more effective and sustainable management practices. However, the inherent morphological complexity of soil aggregates presents methodological challenges that demand more efficient and accurate analytical approaches. In this scenario, the integration of high-resolution digital image processing with deep learning techniques has emerged as a promising solution for the analysis of soil aggregation. These approaches facilitate the segmentation and classification of relevant aggregation features, enabling detailed assessments and supporting the development of regenerative and sustainable management strategies. Based on this rationale, the objective of this study was to develop a method grounded in an autonomous system for the analysis of agricultural soil aggregates in tropical environments, using digital image processing and convolutional neural networks. The proposed methodology was structured into three main stages: (i) soil sampling and laboratory procedures, which ensured the preparation of a diverse and representative sample set; (ii) acquisition and processing of digital images of soil macroaggregates retained on a 4 millimeter sieve, followed by the construction of an image database and the application of digital processing techniques to generate training datasets; and (iii) implementation of convolutional neural network models, where a low complexity model was applied for morphometric classification of aggregates, and the U-Net architecture was used to segment features indicative of physical and biological disturbances. The models employed enabled targeted evaluations and preliminary analyses of soil aggregate morphology, providing insights into the structural characteristics of agricultural soils through the interpretation of digital images via deep learning algorithms. The classification model achieved satisfactory performance in distinguishing extreme morphological classes, while the U-Net architecture demonstrated strong segmentation accuracy, even under conditions of optical and morphological variability. These results highlight the potential of the proposed approach for automated analysis of soil aggregates, particularly in tropical regions, with relevant contributions to environmental science and sustainable agriculture.

Keywords: Deep Learning, Soil Aggregates, Aggregate Morphometry, Bioturbation, Soil Management.

LISTA DE FIGURAS

Figura 1 - Organograma de apresentação de Capítulos da Tese.....	17
Figura 2 - Agregado e suas estruturas internas.....	20
Figura 3 - Exemplo de imagem Raster.....	25
Figura 4 - Faixas espectral	26
Figura 5 - Fluxograma de processamentos da imagem digital	26
Figura 6 - Distribuição de cenas e a capacidade de detecção dos pepinos do mar. 33	
Figura 7 – Etapas laboratoriais.....	42
Figura 8 – Etapas de atividades da elaboração do modelo.....	43
Figura 9 – Regiões de coleta de dados no Brasil.	44
Figura 10 – Representação esquemática do quarteamento da amostra de solo agrícola	46
Figura 11 - Apresentação do modelo montado para aquisição de imagens.....	48
Figura 12 - Estrutura de bancada.....	49
Figura 13 – Representação da classificação de agregados redondos	52
Figura 14 – Representação da classificação de agregados prismáticos	53
Figura 15 – Ilustração do funcionamento do modelo de classificação da forma do agregado.....	54
Figura 16 – a) Imagem original; b) Resultado do Gabor; c) Máscara final.	58
Figura 17 – a) Área de Codificador (Encoder) da U-Net; b) Área de decodificador (Decoder) da U-net.....	60
Figura 18 - Abrasão em agregado de solos.....	65
Figura 19 – Gráfico Boxplot do Diâmetro Médio Ponderado (DMP).	68
Figura 20 – Gráfico Boxplot do Diâmetro Médio Geométrico (DMG).....	69
Figura 21 – Exemplo de interações com agregados escuros.....	72
Figura 22 – Exemplo de interação de agregados arenosos e elevada reflectância..	73
Figura 23 – Exemplo de interação de agregados rugosos e borramento.	73

Figura 24 – Evolução da função de perda (A) e da acurácia (B) nos conjuntos de treinamento e validação durante o processo de treinamento da RNC.	74
Figura 25 – Matriz de confusão do modelo de classificação pela morfometria dos agregados de solo.	76
Figura 26 – (A) Evolução da função de perda (loss) e validação do modelo de segmentação; (B) Evolução da acurácia (accuracy) e validação do modelo de segmentação.	80
Figura 27 – (A) Evolução da curva da precisão e recall do modelo de segmentação; (B) Evolução da métrica F1-Score do modelo de segmentação	81
Figura 28 – A) Segmentação Fatia 1; B) Segmentação Fatia 2.	82

LISTA DE TABELAS

Tabela 1 - Composição das camadas e levantamento de parâmetros treináveis do modelo ...	55
Tabela 2 - Composição das camadas e respectivos parâmetros treinados.	62
Tabela 3 – Relação das características de cada amostra de solo.	66
Tabela 4 – Avaliação da significância da diferença entre regiões e tipos de amostra.	70
Tabela 5 – Métricas de desempenho para avaliação da acurácia do modelo de classificação	77
Tabela 6 – Teste para validação da acurácia do modelo de classificação.....	78
Tabela 7 – Métricas de desempenho para avaliação da acurácia do modelo de segmentação	81
Tabela 8 - Informações gerais do peneiramento das amostras de solos agrícolas	101
Tabela 9 – Validação da classificação de agregados da amostra de Solo 1.	105
Tabela 10 – Validação da classificação de agregados da amostra de Solo 2.	107
Tabela 11 – Validação da classificação de agregados da amostra de Solo 3.	109

SUMÁRIO

1. INTRODUÇÃO	14
1.1. ESTRUTURA DE APRESENTAÇÃO DA TESE.....	17
2. OBJETIVOS E HIPÓTESE	18
2.1. HIPÓTESE BÁSICA	18
2.2. OBJETIVO GERAL	18
2.3. OBJETIVOS ESPECÍFICOS	18
3. REVISÃO BIBLIOGRÁFICA.....	19
3.1. ESTUDOS DEDICADOS A ESTRUTURA DE SOLOS E MANEJO CONSERVACIONISTA.....	19
3.1.1. Estrutura e agregação de solos agrícolas tropicais.....	20
3.1.2. Manejos e práticas conservacionistas de solos agrícolas.....	23
3.2. O USO DE IMAGENS COMO INFORMAÇÕES DE APOIO PARA AVALIAÇÕES E ANÁLISES NA AGRICULTURA	24
3.2.1. A imagem digital e seu processamento digital	25
3.2.2. A aquisição e processamento de imagens digitais aplicada a análises de solos agrícolas.....	28
3.3. ESTUDOS DEDICADOS A ESTRUTURA DE SOLOS E FERRAMENTAS DIGITAIS DE ANÁLISE.	30
3.3.1. <i>Breve apresentação do aprendizado de máquinas.....</i>	<i>30</i>
3.3.2. <i>Aplicação de aprendizado de máquina em estudo de solos agrícolas.....</i>	<i>32</i>
3.4. ANÁLISE DA BIBLIOGRÁFICA A PARTIR DE LEVANTAMENTO SISTEMÁTICO DE ESTUDOS¹	35
3.4.1. <i>Aprendizado de máquina na agricultura digital.....</i>	<i>35</i>
3.4.2. <i>Tendências das aplicações de sistemas de autônomos.....</i>	<i>38</i>
3.5. CONSIDERAÇÕES FINAIS DA REVISÃO BIBLIOGRÁFICA.....	39
4. MATERIAL E MÉTODOS	41
4.1 ETAPA I: COLETA E MANIPULAÇÃO DAS AMOSTRAS DE SOLO EM LABORATÓRIO	43

4.1.1. Amostragem de solo	44
4.1.2. Tamisação do solo	45
4.1.3. Avaliação por Estabilidade do Agregado	46
4.2 ETAPA II: AQUISIÇÃO DE IMAGENS E CONFECÇÃO DO BANCO DE DADOS BRUTO	48
4.2.1. <i>Aquisição da imagem digital</i>	48
4.2.2. <i>Adequação da iluminação da bancada</i>	49
4.3. ETAPA III: APLICAÇÃO DOS MODELOS DE REDES NEURAI CONVOLUCIONAIS.....	50
4.3.1. <i>Modelo de classificação da morfometria de agregados de solos agrícolas em regiões tropicais</i>	50
4.3.2. <i>Modelo de segmentação de perturbações visíveis de agregados de solos agrícolas em regiões tropicais</i>	57
5. RESULTADOS E DISCUSSÃO	64
5.1. CONDIÇÃO GRANULOMÉTRICA E ÍNDICE DE ESTABILIDADE DE SOLOS AGRÍCOLAS TROPICAIS	64
5.1.1 <i>Condição da amostra após peneiramento do solo</i>	64
5.1.1 <i>Condição da estabilidade de agregados de solos agrícolas</i>	65
5.2. PROCESSO DE AQUISIÇÃO DAS IMAGENS DIGITAIS	71
5.3. CLASSIFICAÇÃO DOS AGREGADOS DE SOLOS POR MEIO DA MORFOMETRIA	74
5.4. SEGMENTAÇÃO DE PERTURBAÇÕES VISÍVEIS EM AGREGADOS DE SOLOS AGRÍCOLAS TROPICAIS	79
6. CONSIDERAÇÕES FINAIS	84
REFERÊNCIAS.....	86
APÊNDICE A – INFORMAÇÕES GERAIS DO PENEIRAMENTO DAS AMOSTRAS DE SOLO UTILIZADAS	101
APÊNDICE B – VALIDAÇÃO DA CLASSIFICAÇÃO DE AGREGADOS DE SOLO	105

1. INTRODUÇÃO

Com o aumento da produção agrícola, observa-se uma intensificação da exploração do solo, potencializada pelos avanços tecnológicos principalmente na mecanização. Esse processo, característico do modelo agrícola atual, afeta diretamente a dinâmica natural e biológica do solo, promovendo desequilíbrios em sua estrutura funcional (Mikha et al., 2024). Como consequência, há impactos negativos sobre a capacidade do solo em prover serviços ecossistêmicos essenciais, tais como a manutenção da biodiversidade, a retenção de nutrientes, a estabilidade química e a resistência à erosão (Lal, 2015; IPCC, 2019; FAO, 2015; UNCCD, 2022).

Nesse contexto, a característica física do solo, em especial sua capacidade de formar e manter agregados estáveis, emerge como um ponto crítico afetado pelas práticas intensivas de uso da terra (Six et al., 2000; Bronick; Lal, 2005). Considerando-se a possibilidade de perda de áreas efetivas para produção, associada à preocupação com a segurança alimentar. Os Objetivos de Desenvolvimento Sustentável (ODS) destacam a necessidade de conservação dos recursos hídricos e conservação do solo na agricultura (Nações Unidas, 2020; IPCC, 2022).

Frente aos desafios contemporâneos da agricultura, seja pela expansão das áreas cultiváveis, pela complexidade dos processos de plantio, cultivo e manejo adequado do solo, avanços tecnológicos têm surgido em diversas frentes. O desenvolvimento de novos maquinários agrícolas, de ferramentas para aquisição de informações e de instrumentos de gestão, no contexto da agricultura de precisão, tem possibilitado uma tomada de decisão mais assertiva, baseada em dados objetivos e na análise espacial e temporal das condições agrícolas (Zhang et al., 2021; Sharma; Dadheech, 2024; Kazemi-Garajeh et al., 2023).

Nesse sentido, os avanços na conservação do solo têm sido marcados pela busca de práticas de manejo mais sustentáveis, voltadas para a proteção do solo e a atenuação dos processos erosivos. No início do século XXI, surgiram propostas de conservação de precisão como alternativas que visam não apenas o aumento da produção, mas também a adoção de abordagens de manejo mais sustentáveis (Berry, 2003).

Diferentemente da agricultura de precisão, que se concentra no monitoramento de variáveis físico-químicas para a aplicação de insumos e incremento da produtividade, as estratégias de conservação de precisão, associadas ao uso de

tecnologias da informação e automação, têm como objetivo a promoção de manejos sustentáveis e regenerativos (Ribeiro et al., 2020; Delgado; Berry, 2008).

A avaliação do processo de degradação do solo ou da resposta a práticas de manejo pode ser realizada por meio da agregação do solo, sendo um indicador relevante da qualidade estrutural do solo (Peché-Filho, 2018; Totsche et al., 2017). Os agregados, também denominados partículas secundárias, correspondem a aglomerações de areia, silte, argila, minerais e materiais aglutinantes de origem orgânica ou inorgânica, configurando-se como produtos da dinâmica física, química e biológica do solo (Freire, 2006). A estabilidade desses agregados, que formam a estrutura física do solo, é fundamental para a manutenção da estabilidade estrutural e para o suporte à dinâmica biológica que habita o solo (Yudina et al., 2018; Li et al., 2022; Young; Crawford, 2004).

Dessa forma, o direcionamento de estudos voltados à análise da agregação do solo como indicador funcional contribui para o desenvolvimento de manejos agrícolas mais regenerativos (Hernani, 2021). A melhoria e a manutenção da qualidade da agregação, bem como da estabilidade dos agregados, impactam diretamente na preservação da estrutura do solo, promovendo a redução da erosão, o aumento da infiltração e do armazenamento de água, a melhoria da aeração e a retenção de nutrientes e insumos no perfil do solo.

Esses fatores, em conjunto, favorecem a intensificação da atividade biológica e a produção de matéria orgânica, aspectos essenciais para a manutenção da qualidade e sustentabilidade dos solos agrícolas (Sampat, 1976; Bronick; Lal, 2005).

Dessa maneira, a identificação de variáveis como o tamanho e a forma dos agregados permite a compreensão da estruturação do solo e da configuração dos vazios (Ribeiro et al., 2020). Nesse contexto, o entendimento das dinâmicas de perturbações biológicas que ocorrem nos agregados ainda representa um desafio, dada a complexidade dos processos envolvidos e a necessidade de métodos de estudo ágeis e precisos.

Essas variáveis exigem atenção rigorosa na análise, uma vez que contribuem para a compreensão da morfologia e da dinâmica da agregação, aspectos fundamentais para a manutenção da qualidade estrutural do solo. A instabilidade estrutural dos agregados constitui um indicador de degradação, refletindo a fragilidade da estrutura e resultando na supressão do crescimento de plantas, e na biodiversidade edáfica (Freire, 2006; Yudina et al., 2018; Filippova et al., 2019; Jensen et al., 2020).

A aplicação de ferramentas para análise e avaliação de solos, de plantas, de raízes e das bioturbações têm se desenvolvido na última década, associados às possibilidades de processamento de imagens digitais e nas melhorias em equipamentos de aquisição de fotografias. O uso de imagens digitais ganhou espaço em diversas áreas de estudo agrícolas, permitindo acompanhamento de crescimento de raízes, detecção de bioturbações em perfis de solo ou em estruturas consolidadas, na classificação de uso do solo e na seleção de agregados por formas (Totsche *et al*, 2018; Azizi *et al*, 2020a; Smith, *et al.*, 2020; Li *et al.*, 2022).

A melhoria na qualidade e resolução das imagens são fundamentais para o desempenho eficaz de modelos de deep learning na análise de solos, plantas e raízes. Dessa forma, a melhoria de resolução da imagem pode aprimorar os resultados obtidos de segmentações e classificações de elementos de interesse numa imagem de solos, plantas ou raízes (Ruiz-Muñoz *et al.*, 2020; Zou *et al.*, 2024). Além disso, a combinação de redes neurais convolucionais com métodos de filtragem e técnicas de aumento de banco de dados convencionais tem se mostrado eficaz na segmentação de raízes em imagens de baixa qualidade (Teramoto & Uga, 2024; Smith *et al.*, 2021).

O uso de ferramentas de *Deep Learning* tem se mostrado relevante para a agricultura, sendo amplamente aplicado em diferentes contextos devido ao seu elevado potencial de gestão e integração com instrumentos de *Internet das Coisas* (Kazemi-Garajeh *et al.*, 2023; Attri *et al.*, 2023). Nesse cenário, têm se tornado comuns os estudos baseados em imagens de satélites e drones, combinadas a outros tipos de dados adquiridos em campo, possibilitando abordagens de classificação do uso do solo, predição da umidade e monitoramento de múltiplos indicadores que visam a qualidade da lavoura (Selvanarayanan *et al.*, 2024; Sami *et al.*, 2022).

Adicionalmente, observa-se uma expansão das aplicações de *deep learning* dedicadas à detecção e segmentação de pragas, à avaliação da qualidade de plantas e à análise da textura do solo (Ribeiro *et al.*, 2020; Azizi *et al.*, 2020b; Ruigrok *et al.*, 2023; Yousif *et al.*, 2023). Nesse contexto, a utilização de imagens digitais associada a modelos de *deep learning* configura-se como uma estratégia promissora para a análises de grandes volumes de dados, especialmente no estudo da agregação de solos agrícolas, possibilitando a observação detalhada de aspectos físicos e biológicos, como atividades de microrganismos e efeitos de processos físicos sobre os agregados.

1.1. Estrutura de apresentação da tese.

A estrutura da tese está organizada conforme ilustrado na **Figura 1**, iniciando-se pela Introdução, a qual expõe a motivação e a justificativa do trabalho, seguida pela apresentação da hipótese e dos objetivos gerais e específicos. Na sequência, apresenta-se o referencial teórico que fundamenta o estudo e orientou a construção da metodologia adotada.

Posteriormente, são expostos os resultados obtidos, que foram discutidos de forma integrada ao longo de sua exposição. Dessa maneira, para fechar o conteúdo do trabalho, destaca-se os principais desfechos e a apresentação de sugestões para pesquisas futuras na seção de conclusões.

Por fim, divulga-se todas as referências bibliográficas e os apêndices. Os apêndices foram divididos em duas partes: (A) refere-se aos resultados do ensaio de tamisação das amostras de solo; (B) apresenta o processo de validação dos resultados do modelo utilizado.

Figura 1 - Organograma de apresentação de Capítulos da Tese.



Fonte: Autoria Própria, 2025.

2. OBJETIVOS E HIPÓTESE

2.1. Hipótese básica

A utilização de redes neurais convolucionais, combinado com o processamento de imagens digitais, contribui para a avaliação da agregação de solos agrícolas por meio da análise de agregados de forma autônoma e expedita.

2.2. Objetivo geral

O objetivo geral deste trabalho consiste em propor uma metodologia baseada em modelos autônomos para a análise de agregados de solos agrícolas tropicais, a partir da manipulação de imagens digitais e da aplicação de redes neurais convolucionais.

2.3. Objetivos específicos

- Realizar o tamisamento da amostra de solo conforme a granulometria e analisar a heterogeneidade das amostras;
- Selecionar a granulometria dos agregados de solo para composição do banco de dados;
- Propor um protocolo para a aquisição de imagens digitais de agregados de solos agrícolas;
- Processar e organizar as imagens digitais destinadas ao treinamento das Redes Neurais Convolucionais.
- Desenvolver e treinar uma Rede Neural Convolucional para a classificação dos agregados de solo com base na morfometria;
- Desenvolver e treinar uma Rede Neural Convolucional para a segmentação de perturbações biológicas e físicas em agregados de solo;
- Exportar planilhas de dados e realizar a análise do desempenho das Redes Neurais Convolucionais em tarefas de classificação;
- Aplicar as Redes Neurais Convolucionais treinadas para a análise de amostras de solo, interpretando os resultados obtidos.

3. REVISÃO BIBLIOGRÁFICA

A apresentação da revisão bibliográfica foi elaborada e organizada em cinco etapas. A primeira etapa (**3.1**) tem como objetivo introduzir os conceitos relacionados aos estudos dedicados à compreensão do solo agrícola e ao seu manejo. Essa etapa abordou os fundamentos necessários para compreender as bases conceituais do tema e sua relevância para as práticas agrícolas.

Na segunda etapa (**3.2**), estão apresentados os conceitos de aquisição e processamento de imagens digitais no contexto dos estudos sobre solos agrícolas. Essa discussão enfatizou a importância dessas ferramentas como suporte para análises mais detalhadas e precisas, destacando seu papel no monitoramento e na caracterização de solos.

A terceira etapa (**3.3**) explora o conceito de redes neurais artificiais, abordando suas aplicações na realidade rural. Nessa etapa, destacaram-se as contribuições dessas tecnologias para o setor agrícola, especialmente no que diz respeito à análise de dados complexos e à otimização de processos ligados ao manejo do solo.

Na quarta etapa (**3.4**), relata-se os resultados de um levantamento sistemático de estudos que abordam a aplicação de ferramentas de informática em atividades relacionadas a solos agrícolas. Essa análise teve como objetivo compreender as tendências associadas à implementação de ferramentas de deep learning na agricultura.

Por fim, a quinta etapa (**3.5**) apresenta as considerações finais sobre a revisão detalhada, sintetizando as convergências entre os três grandes temas abordados: inteligência artificial, agricultura e estudos de solos. Essa etapa permitiu consolidar as informações discutidas e destacar os avanços e desafios identificados na literatura.

3.1. Estudos dedicados a estrutura de solos e manejo conservacionista.


Nesta primeira etapa, o texto foi organizado com o objetivo de compreender a agregação do solo, suas dinâmicas e variáveis de análise. Em seguida, buscou-se identificar como o manejo integrado, conservacionista e regenerativo contribui para a estrutura do solo e no fomento da agregação do solo agrícola.

3.1.1. Estrutura e agregação de solos agrícolas tropicais.

O entendimento da estrutura do solo é fundamental para a avaliação e análises da qualidade edáfica, seja na recuperação da vegetação nativa, recomposição biológica, armazenamento de água e nutrientes, no desenvolvimento radicular e melhoria da aeração do solo. O solo é formado por propriedades físicas, químicas, físico-químicas, morfológicas e mineralógicas, cuja interação define seu comportamento funcional (Baretta et al., 2010; Brady; Weil, 2013; Pereira et al., 2019).

A formação da estrutura do solo ocorre pelo arranjo de partículas, ou seja, de areia, silte, argila, matéria orgânica e minerais (partículas primárias), que formam os agregados, também denominados partículas secundárias (Freire, 2006; Mesquita; Dias Júnior, 2013). Esses agregados são resultado não apenas de reações físicas, químicas ou biológicas isoladas, mas de sua dinâmica conjunta, envolvendo cultura, clima, atividades biológicas e forças atuantes no ambiente (Bartz et al., 2013; Yudina et al., 2018). A **Figura 2** ilustra a composição do agregado, onde identifica-se a aglutinação de minerais, coloides, matéria orgânicas e etc.

Figura 2 - Agregado e suas estruturas internas.



Fonte: Adaptado de Yudina *et al.*, 2018

Compreender que a agregação e a estabilidade dos agregados estão suscetíveis a alterações é essencial para a análise a estrutura do solo e avaliar os impactos das atividades de manejo. Solos tropicais, por sua vez, apresentam

particular fragilidade, dado seu intemperismo avançado e menor teor de matéria orgânica (Freire, 2006; Totsche et al., 2017), tornando-os altamente sensíveis a práticas inadequadas que aceleram processos de desagregação, compactação e erosão (Blanco-Canqui; Lal, 2004).

A presença de um solo bem agregado proporciona benefícios, tais como maiores infiltrações de água, melhor aeração, maior retenção de nutrientes e melhor desenvolvimento radicular, devido à menor presença de barreiras físicas que possam restringir o crescimento das plantas. Nesse contexto, a agregação do solo apresenta-se como um indicador relevante da qualidade do solo por ser um produto resultante das dinâmicas edáficas (Jastrow et al., 1996; Six et al., 2000).

Dessa maneira, afirma-se que a agregação promove benefícios à fertilidade e à biodiversidade do solo, entretanto é uma camada susceptível a danos decorrentes de chuvas intensas, exaustão de nutrientes e perda de biodiversidade em função de práticas econômicas inadequadas e manejo incorreto do solo (Freire, 2006; Mikha et al., 2023).

Desse modo, a camada superficial do solo tende a sofrer processos de desagregação, com consequente alteração na morfologia e no tamanho dos agregados, além da perda de suas características estruturais. Esses processos resultam no aumento da proporção de partículas finas e na redução da porosidade, devido ao preenchimento dos poros por esses finos (Hénin et al., 1976; Brady; Weil, 2013)

Quando o solo tende para a agregação, o arranjo dos agregados de solo responde de maneira sensível às variações nas condições de umidade, especialmente em ambientes tropicais. Por exemplo, os ciclos de expansão e contração resultantes do umedecimento da partícula do solo e da secagem, que promovem alterações físicas como a formação de fendas, fissuras e expansão dos poros (Bronick; Lal, 2005; Hénin et al., 1976).

Ao umedecer o solo, a camada superficial passa a ter o preenchimento de vazios e poros, o que leva a expansão da estrutura dos agregados, principalmente solos com maior teor de argila. Na perda de água (secamento), a retração do volume do solo gera tensões internas capazes de superar as forças coesivas entre as partículas, desencadeando a formação de microfissuras e a fragmentação de agregados (Horn; Dexter, 1989).

Essa dinâmica de expansão/contração interage diretamente com a estrutura e a estabilidade do agregado de solo, podendo beneficiar a porosidade e comprometer a resistência do agregado, a depender da intensidade e da frequência dos ciclos (Six et al., 2004).

Além dos processos físicos, a estrutura agregados do solo são alteradas a partir de perturbações biológicas (bioturbação), que desempenham papel de rearranjo da microestrutura dos agregados. O crescimento de raízes, a atividade de fungos micorrízicos e a movimentação da fauna edáfica (minhocas e invertebrados), favorecem a reorganização interna e formação de canais (Tisdall; Oades, 1982; Li et al, 2016; Bardgett; Van Der Putten, 2014).

Essas ações biológicas, em combinação com as variações físicas de umidade, ampliam a heterogeneidade estrutural e aumentam a complexidade das redes de poros e fissuras (Six et al., 2006; Yudina et al., 2018). Dessa forma, o solo tropical é continuamente moldado por uma interação sinérgica entre forças abióticas e bióticas, resultando em agregados com microestruturas, contribuindo para a dinâmica edáfica (Rabot et al., 2018; Freira, 2006).

Nesse contexto, fissuras, fendas e elementos de fragilidade, tradicionalmente vistos como indicativos de degradação, se apresentam como componentes essenciais para a funcionalidade ecológica do solo. Esses espaços atuam como nichos e habitats para microrganismos, promovendo a colonização radicular, a instalação de hifas micorrízicas e a formação de microambientes favoráveis à ciclagem de nutrientes (Young; Crawford, 2004; Erktan et al., 2020).

A utilização dessas estruturas pela biota edáfica pode levar à reestruturação dos agregados, reforçando a estabilidade física do solo a longo prazo e contribuindo para o seu funcionamento como um sistema vivo e resiliente (Bardgett & Van Der Putten, 2014). Assim, a presença de elementos de fragilidade nos agregados deve ser compreendida não apenas como uma manifestação de estresse físico, mas também como uma oportunidade para a regeneração biológica e o aumento da funcionalidade do solo (Six et al., 2004; Rabot et al., 2018).

Diante disso, evidencia-se a importância da manutenção da estrutura dos agregados, tanto para a conservação das funções ecológicas do solo quanto para seu aprimoramento em abordagens regenerativas na agricultura. Compreender os fatores que favorecem ou comprometem a agregação é essencial para subsidiar decisões

assertivas de manejo, contribuindo para a gestão sustentável do solo e para a melhoria de seus parâmetros de qualidade.

3.1.2. Manejos e práticas conservacionistas de solos agrícolas.

A adoção de práticas como rotação de culturas, cobertura vegetal, uso de palhada e manejo mínimo favorece a manutenção do estado de agregação dos solos (Devine et al., 2014), demonstrando sua importância não apenas como conceito teórico, mas como prática essencial à sustentabilidade agrícola. Ensaio laboratoriais, frequentemente baseados em tamisação, permitem avaliar distribuição e estabilidade dos agregados (Freire, 2006), enquanto análises mais recentes incorporam atributos morfométricos, texturais e biogênicos (Azizi et al., 2020; Peche-Filho, 2018; Mesquita e Dias Júnior, 2013).

Meta-análises indicam que, mais do que o clima, o tipo de cultivo exerce grande influência sobre a agregação e fixação de carbono, sendo os sistemas diversificados superiores às monoculturas (Li et al., 2022).

Nesse sentido, um estudo de avaliação do impacto do manejo do solo em pomares de figo elaborado em diferentes tratamentos de solo, observou impactos negativos na matéria orgânica e nos agregados estáveis em sistemas sem cobertura vegetal. Entretanto quando adotado práticas com cobertura de feno ou gramíneas promoveu melhorias na agregação, resultando em menor suspensão de partículas e redução da suscetibilidade à erosão, evidenciando a importância das práticas conservacionistas (Dugan et al., 2024).

Em outra aplicação de manejo do solo, abordados nos estudos de Novara et al. (2018) e Novara et al. (2014), investigaram vinhedos em terrenos com declividade superior a 10% e clima mediterrâneo semiárido. O manejo solo, quando inadequado inserido nessas condições apresentou severas perdas de solo por erosão em decorrência à baixa fixação de matéria orgânica e terreno acidificado.

Em sistemas de rotação de culturas, Truber (2013) avaliou a cultura de cana-de-açúcar em rotação com milho e milheto, apresentou aumento da glomalina, maior estabilidade dos agregados e incremento no diâmetro médio dos agregados. Apesar de não observar alteração nos teores de matéria orgânica, o sistema de rotação favoreceu a estruturação do solo e a melhoria do estado de agregação, em consonância com os resultados apresentados por Li et al. (2024).

Dessa maneira, observa-se, portanto, que a aplicação de práticas conservacionistas melhora as condições estruturais do solo, favorecendo a agregação, a retenção de nutrientes e o aumento da biodiversidade. Dessa maneira, destaca-se a importância da implementação de manutenção do solo e monitoramento das características físicas do solo e da agregação.

Nesse sentido, Peche-Filho (2018) apresentou um protocolo de avaliação da variabilidade de agregados, destacando a importância de parâmetros como forma, rugosidade e tamanho na determinação da consistência da agregação, permitindo a avaliação ativa da evolução agregação em solos agrícolas.

Além das características físicas da fixação de carbono do solo, identificou-se boa contribuição do manejo adequado para a fixação de nutrientes no solo. Dessa maneira, destaca-se o plantio direto e a lavoura mínima como melhores alternativas, promovendo aumento da estabilidade de agregados, fixação de nutrientes e intensificação da micro e mesofauna e aumento na retenção de matéria orgânica.

Além disso, trabalhos como o de Bossuyt et al. (2006) e Li et al. (2022) reforçam o papel crucial das interações entre a matéria orgânica e a biota edáfica na formação e manutenção de macro e microagregados, demonstrando que a combinação entre o manejo físico (ex: palhada) e biológico (ex: presença de anelídeos) promove a estabilidade estrutural do solo.

De modo geral, os estudos reunidos reforçam que a agregação do solo não deve ser tratada como um atributo fixo, mas como um processo dinâmico e multifatorial, que depende tanto do manejo humano quanto das interações biológicas intrínsecas ao sistema solos. Dessa maneira, enfatiza-se que a implementação do monitoramento da agregação mostra-se como uma atividade importante para controle, principalmente no entendimento da qualidade do manejo, mas também como suporte à tomada de decisão.


3.2. O uso de imagens como informações de apoio para avaliações e análises na agricultura

Nesta etapa, apresentam-se as imagens digitais, o que são e o campo do processamento de imagens digitais. Em seguida, busca-se identificar como o uso desses dados pode auxiliar na compreensão das dinâmicas e índices do solo, bem como nos levantamentos espaciais e temporais.

3.2.1. A imagem digital e seu processamento digital

A formação de uma imagem, seja pela percepção humana ou pela captação por sensores digitais, é resultado da interação da energia refletida ou absorvida pelo objeto observado. Quando se adapta esse conceito à representação de uma imagem digital bidimensional, considera-se uma função $f(x,y)$, em que x e y correspondem às coordenadas de uma matriz, e f representa a intensidade finita em uma localização finita (x,y) (Gonzalez; Woods, 2008). A **Figura 3** ilustra um exemplo básico de uma imagem bidimensional no formato raster.


Figura 3 - Exemplo de imagem Raster.



Fonte: Autoria Própria, 2025

Para a aquisição de imagens digitais, há diferentes fontes de captação, como energias acústicas, ultrassônicas, eletrônicas e, mais comumente, a energia proveniente do espectro eletromagnético (EM). De modo geral, imagens captadas em faixas do EM são amplamente utilizadas, principalmente nas regiões do visível, dos raios-X, do ultravioleta e do infravermelho (**Figura 4**).


Ao considerar o imageamento no espectro do visível, referem-se principalmente às bandas vermelho, verde e azul, correspondentes à sensibilidade da visão humana. No entanto, o imageamento pode tornar-se mais complexo, e a aquisição de informações em outras faixas do EM permite a geração de dados complementares e a realização de modelagens matemáticas e formulações de índices a partir dos dados imageados.



Fonte: Adaptado de Pedrini; Schwartz, 2008.

O processamento de imagem digital envolve uma variedade de situações e fatores que podem impactar a qualidade final da imagem. Em linhas gerais, pode-se ter como entrada uma imagem digital, e como saída, uma imagem processada ou atributos extraídos dessa imagem (Pedrini; Schwartz, 2008). A **Figura 5** ilustra, em forma de fluxograma, as etapas do processamento digital de imagens, desde a aquisição até o tratamento e a extração de informações.

Figura 5 - Fluxograma de processamentos da imagem digital



Fonte: Adaptado de Pedrini; Schwartz, 2008.

O contexto da aplicação a ser realizada define a estratégia de aquisição e processamento da imagem. Conhecer o objetivo final é fundamental para orientar desde a escolha da resolução da imagem até o tipo de fonte de aquisição, como a tomografia, a fotografia convencional, sensores multiespectrais ou scanners. Além da escolha dos instrumentos de aquisição, fatores ambientais, como iluminação, sombreamento, ângulo de incidência e isolamento de luz externa, também desempenham papel importante na qualidade da informação captada (Russ, 2016).

É comum que imagens, especialmente em grandes conjuntos, apresentem degradações relacionadas à iluminação, ao escurecimento ou a imperfeições do dispositivo de captura. Portanto, antes da aplicação de algoritmos de processamento, torna-se imprescindível a realização de etapas de pré-processamento, com o objetivo de corrigir essas distorções e realçar as características de interesse. Entre os principais pré-processamentos destacam-se a atenuação de ruído, a correção de contraste e brilho, e a suavização de detalhes da imagem (Gonzalez; Woods, 2008).

Após o pré-processamento, inicia-se a etapa de segmentação, que visa extrair e identificar detalhes de interesse nas imagens. Essa segmentação pode basear-se na detecção de descontinuidades (bordas) ou na similaridade de características (regiões). A extração pode ser complementada por mecanismos de representação e descrição, sendo a representação responsável pela organização dos objetos de interesse, e a descrição, pela extração de atributos que permitam a diferenciação entre classes, muitas vezes por meio de atributos numéricos ou vetorizados (Pedrini; Schwartz, 2008).

Finalmente, a etapa de reconhecimento ou interpretação é realizada. O reconhecimento consiste na atribuição de rótulos ou categorias aos objetos identificados, enquanto a interpretação visa atribuir significado ao conjunto de objetos, considerando o contexto em que estão inseridos (Gonzalez; Woods, 2008).

Tendo em vista a amplitude de aplicações do processamento de imagens digitais, destaca-se as possibilidades da utilização dessas ferramentas para auxiliar na composição de bancos de imagens digitais. Com base desse tipo informação, ressalta-se, também, ser um meio para realizar avaliações e análises de solos, por exemplo, a partir de imagens de solos.

3.2.2. A aquisição e processamento de imagens digitais aplicada a análises de solos agrícolas.

A aquisição de imagens digitais tem se destacado como um meio importante de obtenção de informações para análises espaciais e para a conversão de dados espaciais em variáveis tabulares de múltiplos tipos. Quando associadas a ferramentas de processamento digital de imagens, as aplicações tornam-se ainda mais versáteis, ampliando as possibilidades analíticas desses dados. Considerando as limitações da percepção e da captação de cores pela retina humana, determinadas pela frequência de irradiação, os softwares de processamento de imagens digitais não apenas manipulam pixels e extraem informações, como também permitem a análise de faixas do espectro eletromagnético além daquelas visíveis ao olho humano (Gonzalez; Woods, 2008).

Em aplicações voltadas à análise de solos, observa-se a existência de inúmeros estudos em diversas escalas de investigação. No âmbito da agricultura, identificam-se pesquisas que utilizam sistemas de informações geográficas e técnicas de manipulação de imagens digitais para selecionar áreas de solo exposto, elaborar índices espectrais, identificar áreas vulneráveis ou determinar pontos de estudo e monitoramento (Massruhá et al., 2020).

Mais recentemente, estudos envolvendo imageamento digital em escalas próximas à superfície do solo têm permitido a incorporação de imagens em análises de solos, folhas de plantas, raízes e atividades biológicas. Como exemplo, Zarebanadkouki et al. (2015) utilizaram imagens de tomografia de nêutrons para investigar o transporte de água em raízes de *Lupinus*. Contudo, a qualidade do imageamento proveniente da tomografia não apresentou precisão ideal para o desenvolvimento de análises de raízes e da dinâmica de transporte de água.

Buscando alternativas, Van Dusschoten et al. (2016) propuseram o uso de imagens obtidas por ressonância magnética, que possibilitaram a reconstrução tridimensional (3D) do sistema radicular, bem como análises de diâmetro, tamanho e crescimento das raízes. No entanto, o tipo de solo foi identificado como um fator de interferência relevante, gerando ruído no sinal e dificultando a obtenção de imagens de alta precisão.

No estudo de Bodner et al. (2018), foi explorado o uso do imageamento hiperespectral para a segmentação de raízes no solo. Diferentemente dos métodos

anteriores, esse trabalho evidenciou a dificuldade de separar a raiz do solo, dado que a impregnação de partículas do solo na superfície radicular gerou confusão na distribuição de cores dos pixels, dificultando a segmentação precisa.

Para o treinamento de redes neurais convolucionais voltadas à segmentação de raízes, Smith et al. (2020) precisaram realizar extensivos pré-processamentos das imagens, a fim de rotular adequadamente as estruturas de interesse. O desafio maior consistiu na variação de tons de cinza entre solo e raízes, decorrente da impregnação de partículas, o que levou à adoção de estimativas do trajeto das raízes em rizotrons como solução metodológica.

Ao buscar compreender as dinâmicas e desafios do processamento de imagens digitais aplicadas a raízes, destaca-se também a complexidade da distinção entre solo e elementos biogênicos durante a segmentação. Nesse sentido, Totsche et al. (2018) enfatizaram que a análise de bioturbação, o acompanhamento do fluxo de ar e água, o monitoramento do crescimento de raízes e os estudos de dinâmica de carbono no solo apresentam elevada complexidade, sobretudo pela interação de múltiplos elementos em uma única imagem e pela variabilidade dos padrões capturados.

Tendo em vista a importância da qualidade estrutural do solo e do estado de agregação como componentes essenciais para a manutenção da biodiversidade, Peche-Filho (2018) propôs um método de diagnóstico de solos agrícolas a partir do processamento de imagens digitais de agregados. A metodologia baseou-se na obtenção de imagens microscópicas dos agregados e no processamento dessas imagens para a extração de variáveis biofísicas do solo, destacando a relação entre o estado de agregação e a disponibilidade de nutrientes, água, ar e a resistência mecânica para o desenvolvimento radicular e da planta.

Embora menos recente, o estudo de Helliwell et al. (2014) também reforça o uso de imagens digitais, utilizando tomografia computadorizada para análises biofísicas de amostras de solo. Essa técnica viabilizou investigações em múltiplas escalas, mas os autores destacaram a limitação de acesso aos equipamentos de tomografia e a necessidade de avanços na qualidade dos dados imageados para viabilizar análises mais robustas.

No campo da análise de agregados de solo, Azizi et al. (2020) conduziram experimentos com solos cultivados com milho, preparando as amostras para imageamento da superfície revolvida. Diferentemente de estudos focados em uma

única planta ou agregado, o objetivo foi segmentar semanticamente os diferentes tamanhos de agregados na superfície do solo, ampliando as possibilidades de análise estrutural.

Destaca-se, assim, a crescente percepção da importância da agregação para a sustentabilidade estrutural do solo e o potencial do uso de imagens como fonte de informação para análises de macro e microporosidade.

O estudo de Piron et al. (2012) incorporou a utilização de imagens digitais para descrever morfologicamente padrões de bioturbação produzidos por anelídeos. Nesse trabalho, a luz ultravioleta foi empregada para aumentar o contraste entre o solo e as bioturbações, facilitando a segmentação e possibilitando a realização de análises estatísticas sobre os orifícios e rastros observados.

Finalmente, Li et al. (2016) investigaram o efeito da bioturbação promovida por anelídeos sobre o carreamento de sedimentos. Utilizando imagens de perfis de solo, foi possível monitorar a distribuição e a conectividade dos macroporos criados pelos organismos, bem como observar o aumento da rede de bioturbações ao longo do tempo.

3.3. Estudos dedicados a estrutura de solos e ferramentas digitais de análise.

Nesta etapa, o texto foi organizado com o objetivo de entender a importância de mecanismos autônomos baseados em redes neurais para o processamento de imagens digitais, com destaque para aplicações em imagens de solos, classificações e outras análises.

3.3.1. Breve apresentação do aprendizado de máquinas.

Nas últimas décadas, termos como Inteligência Artificial (IA), Aprendizado de Máquina (*Machine Learning* - ML), Aprendizado Profundo (*Deep Learning* - DL) e Redes Neurais Artificiais (RNAs) têm se difundido amplamente, tanto em publicações científicas quanto na prática cotidiana, em função de sua vasta aplicabilidade na automação de processos e análise de grandes volumes de dados (Goodfellow; Bengio; Géron, 2021). No contexto agrícola, a aplicação dessas ferramentas vem abrindo novos campos de estudo, proporcionando suporte à gestão agrícola de precisão e permitindo uma compreensão mais integrada e dinâmica da qualidade do solo e no manejo de solos agrícolas (El Behairy et al., 2024; Sharma; Dadheech, 2023).

O aprendizado de máquina representa um subcampo da inteligência artificial que busca desenvolver algoritmos capazes de aprender automaticamente a realizar tarefas a partir de dados, melhorando seu desempenho com a experiência acumulada. Diferentemente da programação tradicional, em que o comportamento do sistema é explicitamente codificado, em ML o conhecimento é extraído diretamente dos exemplos fornecidos, permitindo a adaptação a novos dados de maneira flexível (Samuel, 1959; Jordan; Mitchell, 2015).

As Redes Neurais Artificiais (RNAs) constituem uma das abordagens mais expressivas no âmbito do aprendizado de máquina. Segundo Pedrini e Schwartz (2008), RNAs podem ser descritas como grafos compostos por nós (neurônios artificiais) interconectados, inspirados na organização do sistema nervoso biológico. Cada neurônio artificial processa informações de forma simplificada, mas o conjunto de interações entre milhares de unidades possibilita a modelagem de relações complexas e não lineares entre os dados (Géron, 2021). O modelo computacional de McCulloch e Pitts (1943) estabeleceu os fundamentos teóricos das RNAs, utilizando lógica proposicional para simular o comportamento de um neurônio biológico.

Apesar de terem sido concebidas no início da era da computação, as RNAs só ganharam tração prática a partir dos anos 2000, impulsionadas pelos avanços em capacidade computacional (particularmente o uso de GPUs), algoritmos de otimização mais eficientes e pela disponibilidade massiva de dados (*big data*) (LeCun; 2015). Nesse novo cenário, surgiram arquiteturas mais profundas, como as redes de aprendizado profundo (*Deep Learning*), que hoje dominam aplicações em visão computacional, processamento de linguagem natural e análise de dados agrícolas (Kamilaris; Prenafeta-Boldú, 2018).

Entre as abordagens de aprendizado de máquina, destaca-se a distinção entre aprendizado supervisionado e não supervisionado. No aprendizado supervisionado, o modelo é treinado com um conjunto de dados rotulados, onde cada entrada possui uma resposta conhecida, permitindo que o algoritmo aprenda a associar padrões de entrada às saídas correspondentes (Géron, 2021; Cisek, 2021). Em contraste, no aprendizado não supervisionado, o modelo busca identificar estruturas ou agrupamentos ocultos nos dados sem a necessidade de rótulos prévios, sendo amplamente empregado em tarefas de clustering, redução de dimensionalidade e detecção de anomalias.

Além dessas duas categorias principais, emergem ainda paradigmas intermediários, como o aprendizado semi-supervisionado e o aprendizado por reforço. O aprendizado semi-supervisionado utiliza pequenas quantidades de dados rotulados em conjunto com grandes volumes de dados não rotulados, enquanto o aprendizado por reforço é baseado em um agente que aprende por meio da interação com o ambiente, recebendo recompensas ou penalidades conforme suas ações (Sutton; Barto, 2018).

Na agricultura, essas abordagens têm possibilitado avanços significativos na modelagem preditiva de variáveis edáficas, na classificação automática de tipos de solos, no monitoramento da saúde de culturas e na análise da qualidade estrutural do solo por meio de imagens digitais (Chaudhary et al., 2022). A incorporação de machine learning ao campo agrícola, portanto, transcende a mera automação, permitindo diagnósticos mais rápidos, decisões de manejo baseadas em dados e o desenvolvimento de sistemas de suporte à decisão que integram informações espaciais e temporais (Kamilaris; Prenafeta-Boldú, 2018).

Dessa maneira, a utilização de algoritmos de aprendizado de máquina aplicados ao imageamento de agregados de solos agrícolas representa uma estratégia promissora para ampliar a capacidade de análise da estrutura edáfica, identificando padrões sutis de alteração e degradação que poderiam passar despercebidos em métodos tradicionais.

3.3.2. Aplicação de aprendizado de máquina em estudo de solos agrícolas.

A crescente importância do imageamento digital para a agricultura é inegável, seja no contexto da digitalização de propriedades, no mapeamento espacial de dados, no aumento da produtividade ou na viabilização de projetos de manejo mais sustentável. Nesse sentido, identifica-se a tendência de expansão do uso de imagens digitais, com destaque para o emprego de veículos aéreos não tripulados (VANTs), impulsionados pelo aumento da base de dados temporais de alta resolução (Bolfe et al. 2020).

Paralelamente, o avanço na capacidade de imageamento no setor agrícola e pecuário tem favorecido a integração de técnicas de inteligência artificial, com ênfase nas redes neurais artificiais aplicadas ao processamento de dados espaciais e temporais. Essa convergência tecnológica amplia o potencial de monitoramento

dinâmico e personalizado das propriedades agrícolas, promovendo práticas de manejo mais eficientes e sustentáveis (Attri et al., 2023; Akkem et al., 2023).

Entre as técnicas de aprendizado profundo (*deep learning*), observa-se a ampla aplicação de modelos de detecção e segmentação de objetos em imagens digitais. No estudo de Li et al. (2021), a YOLOv3 foi empregada na detecção de pepinos-do-mar utilizando imagens capturadas por drones. O sistema identificou 11.462 indivíduos em um total de 12.956, evidenciando o potencial do aprendizado profundo para monitoramento de organismos de pequeno porte, contribuindo para esforços de conservação marinha (**Figura 6**).

Figura 6 - Distribuição de cenas e a capacidade de detecção dos pepinos do mar.



Fonte: Adaptado de Li et al., 2021.

De forma semelhante, o uso de Redes Neurais Convolucionais (RNCs) tem se expandido para uma ampla gama de aplicações, dada sua capacidade de capturar padrões espaciais complexos em imagens.

No campo da segmentação de imagens biomédicas, Ronneberger et al., (2015) propuseram a U-Net, uma arquitetura de RNC especialmente desenhada para realizar segmentação pixel a pixel em imagens de alta resolução, com aplicações iniciais em imagens microscópicas de células.

Essa abordagem inovadora foi posteriormente adaptada para o estudo de raízes agrícolas por Smith et al. (2020), que modificaram a U-Net para a segmentação de raízes estabilizadas em rizotrons utilizando imagens digitais comuns. Apesar da coerência geral dos resultados, o destacou-se as dificuldades na segmentação completa das raízes, atribuídas à complexidade da textura e à descontinuidade dos objetos de interesse no solo.

A aplicação de RNCs também se mostrou promissora em geociências. Ayranci et al. (2021) adaptaram a arquitetura AlexNet para a análise iconológica de perfis de

solo e rochas, focando na identificação de bioturbações. Com acurácia de 88,9%, o estudo demonstrou a viabilidade da abordagem mesmo em cenários com alta complexidade visual e sutis distorções estruturais, reforçando o potencial de redes profundas em tarefas de análise de imagens geológicas e edáficas.

No estudo conduzido por Azizi et al. (2020b), a utilização de RNCs foi voltada para a classificação de agregados de solo com base em imagens digitais da superfície do solo revolvido. A convolução foi empregada para realçar contornos e bordas, permitindo a segmentação e classificação dos agregados conforme distribuição, quantidade e tamanho, mesmo sob condições de variação tonal limitada.

Adicionalmente, Ribeiro et al. (2020) propuseram a utilização de RNCs para a classificação morfológica de agregados de solo, categorizando-os em classes como redondo, arredondado, sub-angular, angular e prismático. Essa abordagem contribui para a análise da consistência estrutural do solo, constituindo-se em ferramenta promissora para o monitoramento da qualidade edáfica.

Aplicações com essas características ilustram o potencial das redes neurais artificiais no processamento de imagens digitais voltadas à análise de solos e elementos estruturais e de agregação de solos agrícolas. Esses avanços tecnológicos podem subsidiar implementações de métodos automatizados de diagnóstico e monitoramento da qualidade física do solo, trazendo benefícios para uma agricultura sustentável e regenerativa.

3.4. Análise da bibliográfica a partir de levantamento sistemático de estudos¹

Nesta seção, apresentam-se alguns dos principais resultados do artigo “Soil Conservation and Information Technologies: A Literature Review”, recentemente publicado, o qual realizou um levantamento bibliográfico sistemático com o objetivo de identificar as aplicações de ferramentas de aprendizado de máquina na agricultura, com especial ênfase em solos agrícolas.

A descrição completa da metodologia e dos resultados pode ser consultada em Chaves et al. (2025). Para fins de objetividade e clareza, a exposição dos resultados foi estruturada em dois subcapítulos: o primeiro (3.4.1) dedicado a uma breve apresentação das principais áreas de aplicação agrícola; o segundo (3.4.2), voltado à discussão das tendências de desenvolvimento observadas na literatura recente.

3.4.1. Aprendizado de máquina na agricultura digital.

Estudos no âmbito da aplicação de ferramentas de machine learning em busca de avaliações e análises de solos agrícolas tem aumentado nos últimos anos, tendo variedade em abordagens da aquisição de informação até combinações de técnicas de combinação modelo.

Com destaque em aplicações de sensoriamento remoto estudos envolvendo o aprendizado profundo tem impulsionado significativamente o monitoramento agrícola, permitindo a segmentação, classificação e predição de variáveis relacionadas à qualidade do solo (Lee;Park, 2024; Kazemi Garajeh et al., 2023; Vos et al., 2020).

O uso desse tipo de dados tem sido empregado na previsão, identificação, segmentação e classificação do uso e da cobertura do solo, contribuindo para a avaliação da qualidade produtiva dos solos (Dyson et al., 2019; Habiboullah et al., 2023; Munaganuri; Rao, 2024). Para além das métricas de produtividade e manutenção do solo, essas investigações também têm possibilitado análises temporais e predições sobre potenciais perdas de capacidade produtiva, seja em

¹ Excertos deste capítulo foram publicados no artigo “Soil conservation and information technologies: a literature review” do periódico *Smart Agricultural Technology* (Elsevier), estando licenciado sob a Licença Creative Commons BY 4.0. A reprodução deste conteúdo foi realizada conforme as normas institucionais e as políticas editoriais da revista.

CHAVES, J. V. B.; ROSAS, C. L. G.; FERRAZ, C. P. A.; AIELLO, L. H. F.; PECHE FILHO, A.; MOTA, L. T. M.; LONGO, R. M.; RIBEIRO, A. I. Soil conservation and information technologies: a literature review. **Smart Agricultural Technology**, Amsterdam, v. 11, p. 1-11, 2025. DOI: <https://doi.org/10.1016/j.atech.2025.100935>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S2772375525001686>. Acesso em: 18 de abril de 2025.

decorrência de pressões antrópicas ou dos efeitos das mudanças climáticas, impactando diretamente a segurança alimentar (Kazemi Garajeh et al., 2023; Lee; Park, 2024; Vos et al., 2020).

Para além de estudo aplicados em escalas macro, identificou-se estudos focados em avaliações em campo e em laboratório, permitindo avanços significativos na confiabilidade e robustez de sistemas eletrônicos e de comunicação. Esses progressos viabilizaram a aquisição, o processamento e a utilização em tempo real e de forma economicamente viável (Benameur et al., 2024; Vasconcelos et al., 2023). Devido a miniaturização dos dispositivos, aliada à redução do consumo energético, impulsionou ainda mais essa evolução na agricultura digital e de precisão (Chen; Yang, 2019; Turolla et al., 2018).

Dispositivos eletrônicos e ferramentas de Tecnologias da Informação e Comunicação (TIC), como drones, espectroscopia de solos e sensores de temperatura, umidade, gases, radiação solar e vento, têm sido amplamente adotados tanto em pesquisas quanto em aplicações de agricultura inteligente (Dahane et al., 2022; Wu et al., 2023; Kaur et al., 2024). A integração desses dispositivos com modelos de deep learning têm otimizado da aquisição ao processamento de conjuntos de dados variados (Manikandan et al., 2022; Selvanarayanan et al., 2024; Sumathi et al., 2023).

Nesse contexto, modelos de deep learning vêm sendo aplicados para automatizar processos em lote envolvendo grandes volumes de dados, além de apoiar sistemas de predição e análises temporais (Singh; Jain, 2022, Munaganuri; Rao, 2024; Turolla et al., 2018). O aprendizado de máquina surge como uma ferramenta central para integrar diversas tarefas agrícolas, incluindo a captura, o processamento, a análise e a apresentação interativa de dados (Massruhá et al., 2020).

A integração de ferramentas da agricultura de precisão a sistemas autônomos abre um caminho promissor para o aumento da produtividade agrícola e a geração de benefícios econômicos expressivos para o Produto Interno Bruto (PIB) nacional. Essa abordagem, quando combinada com práticas avançadas de manejo, aquisição de dados e automação, tende a promover o aumento da produtividade, redução de custos, minimizar a degradação do solo e contribuir para a segurança alimentar global (Mohamed et al., 2021; Rose et al., 2016).

Entretanto, apesar da incorporação de sistemas digitais e inteligentes no setor agrícola, a qualidade da produção permanece vulnerável à degradação do solo, à perda estrutural e à diminuição da biodiversidade (Ribeiro et al., 2020). A simples otimização da produtividade e a gestão do uso de insumos, como a correção de nutrientes do solo, podem ser insuficientes para enfrentar os desafios da segurança alimentar, especialmente sob as pressões das mudanças climáticas e da instabilidade ambiental (Kazemi-Garajeh et al., 2023; Preskill, 2018; Alirezazadeh et al., 2022).

Pesquisas recentes têm explorado a estrutura e a agregação do solo por meio de técnicas de imageamento digital combinadas com redes neurais convolucionais (Kiran-Pandiri et al., 2024; Azizi et al., 2020a). Apesar de promissoras, essas abordagens frequentemente enfrentam desafios relacionados à qualidade das imagens, o que pode limitar a eficácia do treinamento e da validação das redes neurais. Métodos laboratoriais, por sua vez, têm apresentado resultados mais consistentes (Alirezazadeh et al., 2021; Azadnia et al., 2022; Kang et al., 2021).

A segmentação e a classificação de agregados do solo e de sistemas radiculares por meio de técnicas de aprendizado de máquinas, em especial abordagens de segmentação semântica configuram-se como uma direção de pesquisa promissora (Smith et al., 2020; Azizi et al., 2020b). Dessa maneira, modelos agrícolas inteligentes voltados para o manejo sustentável e a preservação da biodiversidade passam a ser desenvolvido, que contribuem para a criação de sistemas inteligentes destinados à reabilitação de solos degradados, promovendo práticas mais eficazes de conservação e restauração (Ribeiro et al., 2020; Alirezazadeh et al., 2021; Martínez et al., 2015).

Diante desse contexto, diversos estudos têm abordado múltiplos parâmetros do solo utilizando técnicas de deep learning (El Behairy et al., 2024), sendo inicialmente aplicado essas ferramentas para análise da umidade do solo, com o primeiro trabalho de pesquisa relatado por Song et al., 2016. Seguiu-se, em 2018, a análise de vários nutrientes, incluindo fósforo e nitrato (Dong et al., 2018; Yang et al., 2019), porosidade (Han et al., 2019), pH (Ren et al., 2020), classificação de agregados (Azizi et al., 2020b, Ribeiro et al., 2020), identificação de agregados de solo (Wang et al., 2020), erosão do solo (Samarin et al., 2020), emissões de gases de efeito estufa de solos agrícolas (Hamrani et al., 2020; Kosamkar et al., 2020), degradação de terras aráveis (Rukhovish et al., 2021), contaminantes como cromo no solo (Wang et al., 2021), salinidade (Wang et al., 2022), matéria orgânica (Ma et al., 2022), carbono

orgânico (Zhang et al., 2022), biodiversidade do solo (Pruvost et al., 2022), textura (Azadnia et al., 2022), estrutura do solo (Sumathi et al., 2023) e mudanças climáticas (Kazemi Garajeh et al., 2023).

Em geral, a maioria dos estudos concentrou-se na análise da umidade do solo, com o objetivo principal de otimizar a irrigação e o manejo de nutrientes para a melhoria dos rendimentos agrícolas. A partir de 2020, observa-se um crescimento no número de investigações voltadas à análise de agregados do solo, às condições edáficas e à interação desses fatores com as mudanças climáticas (Chandraprabha; Dhanraj, 2023; Custódio; Prati, 2024).

3.4.2. Tendências das aplicações de sistemas de autônomos.

Considerando o panorama geral da aquisição de dados em múltiplas escalas, desde informações derivadas de satélites até dados provenientes de equipamentos de TIC e imagens obtidas em campo ou laboratório, verifica-se um potencial promissor para o desenvolvimento de sistemas integrados que interconectem informações entre essas diversas escalas (Patrizi et al., 2022; Selvanarayanan et al., 2024; Alirezazadeh et al., 2021). A busca por metodologias que combinem Internet das Coisas (IoT) e imageamento para análises de solo e plantas vem crescendo e tende a se expandir ainda mais, impulsionada pelo suporte de redes neurais artificiais aplicadas à análise da estrutura do solo, raízes e folhas (Smith et al., 2020; Azizi et al., 2020a; Mohamed et al., 2021; Kamarudin et al., 2021).

Tendo em vista os avanços das práticas de monitoramento, gestão de propriedades agrícolas e bases de dados baseadas em imagens digitais, observa-se, portanto, a consolidação do aprendizado de máquina como um novo campo de pesquisa na agricultura. Esse movimento tende a viabilizar a incorporação de metodologias de avaliação, classificação, identificação e predição aplicadas a culturas de frutas e hortaliças, principalmente com foco no monitoramento da qualidade dos produtos (Lee; Park, 2024; Kamagate et al., 2024; Trentin et al., 2024; Venkatanaresh; Kullayamma, 2024).

A agricultura digital e de precisão evoluiu no sentido de identificar perdas na qualidade do solo e orientar a aplicação de insumos produtivos, como fertilizantes, corretivos e herbicidas (Sirsat et al., 2018; Sujatha; Jaidhar, 2023). No entanto, a análise da capacidade suporte do solo, considerando aspectos como estrutura,

agregação, atividade biológica e processos enzimáticos, mostra-se igualmente fundamental para a avaliação da qualidade edáfica e do potencial de regeneração dos sistemas agrícolas (Ribeiro et al., 2020; Alirezazadeh et al., 2021; Azizi et al., 2020a; El Behairy et al., 2024).

Além disso, com o avanço dos modelos de aprendizado de máquina, como a utilização de aprendizado por transferência (transfer learning) e a integração de dados provenientes de sistemas IoT, espera-se que análises e classificações de solos mais complexas se tornem viáveis. Por consequência espera-se que tais avanços possam permitir aprofundar a compreensão das dinâmicas e dos padrões do solo agrícola, além de otimizar práticas de manejo regenerativo e de conservação dos ambientes agrícolas (Padmavathi et al., 2024; Raju et al., 2024).

Frente a esse contexto, quando a conservação é integrada às tecnologias de precisão, propõe-se uma nova estrutura para a agricultura contemporânea. Essa abordagem ultrapassa a visão tradicional de produtividade baseada apenas na adição de insumos, valorizando práticas de manejo racional do solo e promovendo a transformação das atividades antrópicas em sistemas produtivos sustentáveis, baseados na estabilidade natural das condições físicas e biológicas do solo (Ribeiro et al., 2020; Habeeb; Mustafa, 2024. Nalwanga et al., 2021).

Esse movimento promove uma compreensão a partir de sistemas integrados, digitais e inteligentes que priorizam a conservação associada à produtividade, visando aumentar a produção agrícola ao mesmo tempo em que mitiga danos ambientais. A adoção de modelos de produção orientados pela conservação representa um enriquecimento das discussões acadêmicas e um avanço para decisões mais sustentáveis no âmbito das práticas agrícolas (El Behairy et al., 2024; Jain et al., 2024).

3.5. Considerações finais da revisão bibliográfica.

A revisão bibliográfica desenvolvida neste trabalho evidenciou a crescente complexidade e interdisciplinaridade das abordagens relacionadas ao estudo da estrutura do solo, ao manejo do solo e à aplicação de tecnologias digitais na agricultura. Ao longo dos grandes eixos pesquisados, estrutura do agregado em solo agrícola, processamento de imagens digitais e aprendizado de máquina, foi possível

estabelecer uma sólida base conceitual que fundamenta as discussões metodológicas subsequentes.

Dessa forma, a análise sobre a aquisição e o processamento de imagens digitais demonstrou o avanço tecnológico que vem permitindo novas formas de análise do solo. As imagens digitais, combinadas com técnicas de processamento avançado, têm se apresentado como abordagem promissora, principalmente para subsidiar o monitoramento da qualidade de variáveis edáficas, embora desafiador tecnicamente quando associado à qualidade de aquisição e segmentação de elementos biogênicos.

No campo do aprendizado de máquina, consolidou-se o entendimento de que essas ferramentas representam uma nova fronteira para a análise agrícola, com potencial para extrair padrões complexos a partir de grandes volumes de dados. Essa capacidade pode acelerar não apenas a interpretação de informações adquiridas por sensores remotos e imagens de satélite, mas também análises laboratoriais tradicionais, otimizando o diagnóstico edáfico.

Tendo em vista que aplicação de práticas de manejo do solo contribuem para a preservação da estrutura edáfica. Estudos reforçaram a importância de práticas que favoreçam o aumento da macroagregação, da atividade biológica e da retenção de matéria orgânica. Nesse momento em que a possibilidade de implementações de monitoramento autônomos podem contribuir para a manutenção do solo.

A estrutura física do solo, com ênfase no papel da agregação como indicador de qualidade edáfica e elemento essencial para a sustentabilidade dos sistemas agrícolas tropicais. Identificou-se que a manutenção da agregação e de sua estabilidade depende do equilíbrio dinâmico entre forças físicas, químicas e biológicas, sendo fortemente influenciada por práticas de manejo

Por fim, a análise sistemática da literatura recente revelou que o uso de inteligência artificial, particularmente modelos de deep learning, tem se encaminhado a otimização da produtividade agrícola. Cabe ressaltar que tem sido identificado um movimento crescente da aplicação dessas tecnologias na integração de práticas de adequadas de manejo do solo e aliar tecnologia de ponta à conservação das funcionalidades ecológica dos solos.

4. MATERIAL E MÉTODOS

A apresentação do método foi estruturada em três etapas principais, conforme ilustrado na **Figura 7**, que representam os processos laboratoriais de bancada, enquanto na **Figura 8**, descreve-se os procedimentos associados à elaboração dos modelos computacionais e ao tratamento estatístico dos dados.

A primeira etapa compreendeu a organização dos cuidados com a amostragem de solos agrícolas, a manipulação das amostras e a elaboração de índices resultantes da tamisação (**Capítulo 4.1**).

Em cada propriedade em que se realizou a amostragem, foram coletadas duas amostras de solo: uma sem a aplicação de biofertilizante (testemunha) e outra com a adição do biofertilizante. A coleta seguiu o método de amostragem simples, realizada no horizonte A do solo (0–15 cm), diretamente na linha de cultivo, independentemente das condições climáticas ou do tempo local. Para cada amostra, registraram-se informações como cultura atual, cultura anterior, localização geográfica e identificação da propriedade.

A manipulação das amostras seguiu o protocolo de tamisamento a seco, utilizando peneiras com aberturas de 6,3 mm, 4 mm, 2 mm, 1 mm, 0,5 mm e bandeja de fundo. O processo de peneiramento foi conduzido durante 3 minutos, a uma rotação de 2.400 vpm. Após o peneiramento, os agregados retidos em cada peneira foram armazenados em potes plásticos, devidamente separados e identificados conforme a granulometria.

Com todas as amostras organizadas por frações granulométricas, foi realizada uma análise visual para seleção da fração mais representativa a ser utilizada na composição do banco de dados digital. Selecionaram-se os agregados retidos na peneira de 4 mm para o processo de imageamento.

Tendo as amostras selecionadas, elaborou-se um protocolo de aquisição de imagens digitais (**Capítulo 4.2**). Para garantir a padronização da iluminação e minimizar interferências externas, foi construída uma estrutura de bancada dedicada, proporcionando um ambiente controlado. As imagens foram capturadas utilizando um microscópio, equipado com recursos para redução de borramentos por foco e lentes polarizadas para controle da claridade e da refletância da luz sobre os agregados.

Figura 7 – Etapas laboratoriais



Fonte: Autoria Própria, 2025.

Após a aquisição das imagens, iniciou-se a segunda etapa, correspondente à seleção das arquiteturas de Redes Neurais Convolucionais a serem empregadas (**Capítulo 4.3**), bem como a organização e o refinamento do banco de dados digital para treinamento dos modelos. Foram utilizados dois tipos de modelos baseados em aprendizado supervisionado, conforme ilustrado na **Figura 8**.


Em cada modelo, estabeleceu-se a formulação de métricas específicas para a organização do banco de treinamento e validação, respeitando as condições e os objetivos distintos de cada abordagem. Em sequência, definiu-se a arquitetura das redes e os mecanismos de avaliação da acurácia, considerando as particularidades de classificação ou segmentação envolvidas.

No primeiro modelo, desenvolveu-se uma Rede Neural Convolucional simples para a classificação de agregados de solo segundo suas formas morfológicas. A metodologia adotada previu a seleção e pré-classificação manual do banco de imagens, organizando as classes da seguinte forma:

- **Bom:** Agregados Redondos e Arredondados;
- **Regular:** Agregados Sub-angulares e Angulares;
- **Ruim:** Agregados Prismáticos.

O segundo modelo teve como objetivo a segmentação de perturbações biológicas e físicas presentes nos agregados de solo. Para esse propósito, adotou-se a arquitetura U-Net, reconhecida por sua eficácia em segmentações de estruturas complexas e com baixa separabilidade espectral, como é o caso dos agregados de solos tropicais.

Figura 8 – Etapas de atividades da elaboração do modelo



Fonte: Autoria Própria, 2025.

4.1 ETAPA I: Coleta e manipulação das amostras de solo em laboratório


A apresentação do método de coleta das amostras de solos e tratamentos foram devidamente descritos nos tópicos a seguir.

- **4.1.1** – Amostragem de solo;
- **4.1.2** – Tamisação do Solo;
- **4.1.3** – Verificação da variabilidade das amostras.

4.1.1. Amostragem de solo

As amostras de solo utilizadas neste estudo foram fornecidas por meio de uma parceria público-privada entre a Fundunesp e a Microgeo®, empresa do setor de biotecnologia agrícola. As coletas foram realizadas em 22 propriedades em estados localizados nas regiões Sul e Centro-Oeste do Brasil, abrangendo uma diversidade de características de solos, clima e culturas (**Figura 9**).

Figura 9 – Regiões de coleta de dados no Brasil.



Fonte: Autoria Própria, 2025.

A coleta foi padronizada para todas as propriedades, independentemente do tipo de solo, cultura agrícola ou região. Em cada local, foram coletadas duas amostras distintas: (i) uma amostra com a aplicação de biofertilizante, utilizado com o objetivo de estimular a atividade biológica e a presença de microrganismos no solo e (ii) uma amostra controle (“testemunha”), sem a adição do biofertilizante.

Adotou-se o protocolo de amostragem simples, em que se coleta uma porção única de solo por gleba, sem o processo de compostagem ou mistura entre pontos (Page et al., 1986). As amostras foram retiradas na linha de cultivo, na camada superficial do solo correspondente ao horizonte A (0–15 cm), independentemente das condições climáticas ou da umidade no momento da coleta (Teixeira et al., 2017). Em função disso, algumas amostras chegaram ao laboratório com teores variáveis de umidade.

4.1.2. Tamisação do solo

O processo de tamisação seguiu protocolos consolidados na literatura (Teixeira et al., 2017), com adaptações específicas para este estudo, com o objetivo de minimizar o desgaste mecânico, abrasão, dos agregados de solo pelas peneiras. As modificações envolveram desde a divisão proporcional das amostras para tamisamento e ensaio de umidade, até o ajuste na frequência e no tempo de peneiramento.

O preparo das amostras seguiu o procedimento padrão. As amostras foram transferidas das embalagens plásticas para recipientes de alumínio, em seguida foi realizado o destorroamento manual e as amostras foram deixadas para secagem em temperatura ambiente. Em casos específicos, especialmente para amostras coletadas durante o período chuvoso, foi necessário estender o tempo de secagem por aproximadamente sete dias, até a estabilização por gravimetria, devido ao elevado teor de umidade amostra recebida (Teixeira et al., 2017).

Considerando que o objetivo do estudo se trata da análise de agregados por meio de imagens digitais, optou-se pelo peneiramento a seco, por este permitir a obtenção de um maior volume de agregados íntegros e por ser possível de adquirir mais agregado retidos na peneira de 4mm.


A utilização do peneiramento úmido foi descartada devido à possibilidade de deformações estruturais nos agregados, provocadas pela redução da resistência mecânica do solo submerso. Adicionalmente, a exposição do agregado ao tratamento úmido pode gerar danos nos agregados que causaria perda de informação das estruturas como raízes, hifas fúngicas e demais formas de bioturbação (Freire, 2006; Caputo, 1923). Para complementar, segundo os estudos de Peche-Filho (2018) e Carvalho (2021), recomenda-se o peneiramento a seco para fins morfológicos e estruturais.

Nesse sentido, para o tamisamento a seco, a literatura propõe um pré-peneiramento utilizando peneiras de 4 mm, 2 mm e fundo para a seleção inicial das frações (Teixeira et al., 2017; Carvalho, 2021). Entretanto, para o presente estudo, a seleção da amostra destinada a cada análise foi realizada por meio de quarteamento manual, respeitando a preservação da estrutura dos agregados.

A divisão consistiu em destinar aproximadamente 50% da amostra para o tamisamento a seco, 25% para a determinação do teor de umidade, e 25% para o

peneiramento via úmida. Tal estratégia de subdivisão segue a recomendação de preservação dos agregados e representatividade da amostra, conforme orientado por Kemper e Rosenau (1986) e respaldado pelas discussões sobre estabilidade de agregados propostas por Márquez et al. (2004). A **Figura 10** ilustra de forma esquemática o procedimento de quarteamento adotado.

Figura 10 – Representação esquemática do quarteamento da amostra de solo agrícola



Fonte: Autoria Própria, 2025.

Após selecionar a quantidade de amostras, então inicia-se o processo de peneiramento. Para esse ensaio utilizou-se as peneiras 6mm, 4mm, 2mm, 1mm, 0,500mm e fundo. Todas as amostras, independentemente de sua textura, foram peneiradas a uma intensidade de 2400vpm por 3min.

Após finalizado o peneiramento, os agregados foram armazenados cada em potes plásticos e devidamente identificados. Entretanto, para esse estudo, foi utilizado apenas os agregados de solo retidos pelas peneiras de 2 e 4mm. Segundo os resultados de Carvalho (2021), Peche-Filho (2018) e Ribeiro et al., (2020), os agregados retidos nessas peneiras apresentam bom indicador para análise da estabilidade, visualização de matéria orgânica e desenvolvimento de trabalho com os agregados.

4.1.3. Avaliação por Estabilidade do Agregado

A partir da distribuição das massas retidas em cada classe granulométrica obtida via peneiramento seco, foram calculados os seguintes índices: Diâmetro Médio Geométrico (DMG) e Diâmetro Médio Ponderado (DMP). Esses índices foram elaborados para expressar a granulometria de cada amostra coletada e permitir uma pré-visualização das características das amostras.

Diâmetro Médio Ponderado (DMP)

O Diâmetro Médio Ponderado representa a média aritmética ponderada das classes de agregados, considerando a distribuição de massa em cada faixa de tamanho, portanto expressa a tendência central da distribuição dos tamanhos dos agregados. Segue descrito a fórmula do DMP conforme a **Equação 1**:

$$DMP = \sum_{i=1}^n x_i \cdot w_i \quad (1)$$

em que:

x_i = diâmetro médio da classe i (calculado como a média entre os diâmetros superior e inferior da peneira),

n = número de classes (peneiras)

w_i = Proporção da massa total retida em i . Dessa maneira, w_i pode ser pensado como peso relativo (m_i), expresso pela **Equação 2**:

$$w_i = \frac{m_i}{\sum_{j=1}^n m_j} \quad (2)$$

Diâmetro Médio Geométrico (DMG)

O Diâmetro Médio Geométrico é obtido pela média geométrica ponderada dos diâmetros das classes. Esse índice é mais sensível à distribuição das frações menores, refletindo com maior precisão a fragmentação dos agregados. O índice é baseado na **Equação 3**.

$$DMG = \exp \left(\sum_{i=1}^n w_i \cdot \ln(x_i) \right) \quad (3)$$

x_i = diâmetro médio da classe i (calculado como a média entre os diâmetros superior e inferior da peneira),

n = número de classes (peneiras)

$\ln$ = logaritmo natural

w_i = Proporção da massa total retida em i . Dessa maneira, w_i pode ser pensado como peso relativo (m_i), expresso pela **Equação 2**.

4.2 ETAPA II: Aquisição de imagens e confecção do banco de dados bruto

Este capítulo foi organizado em duas partes complementares. A primeira parte descreve o processo de aquisição das imagens digitais, detalhando os procedimentos de captura e armazenamento dos dados. A segunda parte apresenta a estrutura da bancada desenvolvida, com ênfase nos aspectos técnicos adotados para o controle da iluminação e padronização das imagens obtidas.

4.2.1. Aquisição da imagem digital.

O processo de aquisição de imagens para a criação do banco de dados foi desenvolvido com base em imagens proximais de bancada. Trata-se de imagens capturadas com sensores posicionado próximo ao objetivo de interesse, em bancada e em ambiente controlado. A descrição sobre os aspectos relacionados à estrutura da bancada e iluminação encontram-se descritos no **subcapítulo 4.2.2.**

Para o imageamento foi utilizado o microscópio digital Dino-Lite AM7915MZTL para aquisição das imagens dos agregados de solo (**Figura 11**), o qual possui poder de ampliação de 10 à 140x, com resolução de 5 megapixels, sistema de foco ajustável e lente polarizada integrada. O uso da lente polarizada foi essencial para filtrar a luz incidente e minimizar o ruído visual causado por reflexos no agregado ou da superfície com vinil branco.

Figura 11 - Apresentação do modelo montado para aquisição de imagens



Fonte: Autoria Própria, 2025.

Tendo em vista a complexidade de um agregado em decorrência de sua irregularidade e diferentes níveis de altura foi necessário utilizar, também, a Extended Depth of Field (EDOF). Essa funcionalidade permite adquirir múltiplas camadas de fotos (planos focais) e, posteriormente, combinar em uma imagem composta.


Destaca-se que as imagens adquiridas buscam apresentar uma face do agregado de solo, portanto as análises foram pautadas a partir de fragmentos visíveis associadas à uma das faces do agregado.

4.2.2. Adequação da iluminação da bancada.

O ambiente de aquisição das fotografias foi padronizado devido a necessidade de controle de sombra e iluminação, em especial da iluminação externa. Esse controle permite manusear o ambiente e a iluminação de forma a facilitar no controle da aquisição da imagem e na captação dos detalhes de interesse na imagem (Kerp e Bomfleur, 2011).

Para isso, foi construída uma capela utilizando canos de policloreto de vinila (PVC) como estrutura e dupla camada de tecido preto fosco, o qual foi estendido sobre o suporte de PVC (**Figura 12**). Dentro da capela foi instalado o microscópio anexo ao suporte do RK-06 e uma placada de vidro revestida com adesivo de plástico vinil, o qual foi instalado sobre a base do RK-06 (**Figura 12**).

Figura 12 - Estrutura de bancada.



Fonte: Autoria Própria, 2025.

As configurações de bancada foram ajustadas conforme a variação de tamanho e rugosidade dos agregados selecionados. Dessa forma, o microscópio foi instalado a 2,8cm de altura com relação à placa de vidro revestida.

Com a bancada já estruturada, foi possível bloquear a luz externa direta, dando acesso apenas a contato com iluminação difusa, que não interferiu no controle de iluminação sobre o agregado. Dessa forma, a amostra ficou apenas sobre influência da luz emitida pelo microscópio.

Para auxiliar na aquisição da imagem, o modelo de microscópio AM7915MZTL contém duas ferramentas de controle da própria iluminação. A primeira está associada à tampa frontal que permite alterar o foco de luz, aumentar brilho e controle do direcionamento da luz. Dessa maneira, foi utilizada a proteção de lente (tampa) branca fosca, pois permitiu o foco direto ao centro da lupa do microscópio, independente do controle de LEDs de iluminação.

4.3. ETAPA III: Aplicação dos modelos de Redes Neurais Convolucionais

Nessa etapa encontra-se detalhado os modelos aplicados para realizar as tarefas de classificação da morfometria e segmentação das perturbações físicas e biológicas dos agregados.

Para cada um dos modelos descreve-se a organização dos bancos de dados de entrada para treinamento e validação, bem como a estruturação do modelo e os métodos estatísticos de avaliação. Destaca-se que em ambos os modelos foram treinados com imagens adquiridas pelo microscópio AM7915MZTL, portanto sendo imagens

4.3.1. Modelo de classificação da morfometria de agregados de solos agrícolas em regiões tropicais.

4.3.1.1 Normalização do banco de dados para treinamento e validação.

O banco de imagens utilizado para o treinamento do modelo de classificação encontra-se estruturado a partir de uma seleção manual sistemática, que permitiu a separação dos agregados em três grandes grupos associado à qualidade morfológica: *bom*, *regular* e *ruim*. Essa categorização visou representar diferentes estágios de qualidade estrutural dos agregados, conforme a observação de um fragmento visível do agregado. Dessa forma as categorias caracterizadas da seguinte forma:

- *Bom*: Composto por agregados de formas arredondadas e redondas, correspondendo ao estado estrutural considerado ideal, do ponto de vista morfométrico.
- *Regular*: Inclui agregados de morfologia angular e sub-angular, representando partículas que já passaram por fraturamento, tendo perdido o aspecto arredondado, mas que também podem estar em processo de recomposição estrutural.
- *Ruim*: Abrange agregados com morfologia prismática, identificados principalmente na fração retida na peneira de 4 mm, indicativos do estágio máximo de degradação estrutural.

Antes de iniciar o processo de classificação automatizada, realizou-se uma triagem preliminar em um conjunto de 4.873 imagens de agregados de solo, com o objetivo de eliminar fotografias que não representavam agregados propriamente ditos, como pedregulhos ou fragmentos minerais recobertos superficialmente por solo.

Essa etapa de curadoria assegurou que apenas imagens representativas fossem mantidas para o treinamento e validação dos modelos. Como resultado dessa triagem, descartou-se 448 imagens. Assim, a classificação morfológica foi realizada com base em um total de 4.425 imagens validadas.

A adoção dessa classificação baseou-se em critérios visuais definidos para o estudo, permitindo a padronização dos conjuntos de treinamento e validação empregados nos modelos de reconhecimento morfológico automatizado.

Com o objetivo de reduzir a subjetividade inerente à classificação visual dos agregados e formalizar o enquadramento das imagens em categorias morfológicas, estabeleceu-se um procedimento sistemático de qualificação das amostras.

Inicialmente, realizou-se uma triagem para identificar e selecionar os agregados com morfologia arredondada ou redonda, que foram atribuídos à classe *bom*. Em seguida, realizou-se a identificação dos agregados com formas prismáticas, sendo classificados como *ruim*.


Todas as imagens que não se enquadraram nessas duas categorias, por não apresentarem nem formas esféricas nem prismáticas, foram atribuídas à classe *regular*, que corresponde aos agregados com morfologia angular ou sub-angular. Dessa forma foi possível padronizar a classificação manual, assegurando mais

consistência e reprodutibilidade no banco de dados destinado ao treinamento dos modelos de aprendizado de máquina.

Com base no método proposto por Peche-Filho (2018), adotou-se um critério visual sistematizado para a identificação e o enquadramento dos agregados classificados como *bom*. A avaliação consistiu na divisão de cada agregado em quatro quadrantes simétricos, com análise individual de cada seção.

Os agregados considerados redondos foram aqueles que apresentaram ausência de ângulos visíveis e morfologia suavemente curva nos quatro quadrantes avaliados. Já os agregados classificados como arredondados deveriam atender aos critérios de suavidade de contorno em, no mínimo, três dos quatro quadrantes, sem a presença de ângulos proeminentes que comprometessem a continuidade da forma.


Na **Figura 13 e 14** encontra-se ilustrado o exemplo de classificação de um agregado redondo e arredondado, respectivamente.



Fonte: Autoria Própria, 2025

Para a caracterização de agregados prismáticos, assumiu-se um prisma agregados com largura três vezes maior que a altura (h) do agregado (**Figura 13**).

Figura 14 – Representação da classificação de agregados prismáticos



Fonte: Autoria Própria, 2025

Vale ressaltar que o banco de dados inicialmente ficou estruturado com seguintes quantidades de fotos por pasta: *bom* = 914; *regular* = 3.277; *ruim*: 234. Sendo assim, foi necessário realizar um reajuste na pasta de agregados classificados como *regular*, portanto, tornando a distribuição com a seguinte quantia: *bom* = 587; *regular* = 597; *ruim*: 234.

Com essa redistribuição, a discrepância entre as classes foi atenuada, contribuindo para mitigar o risco de sobreajuste (overfitting) do modelo ao conjunto de treinamento. A literatura destaca que o balanceamento das classes é uma etapa essencial para o desempenho estável de algoritmos de aprendizado supervisionado, especialmente em redes neurais (Géron, 2021).

4.3.1.2 Modelo de classificação da morfometria de agregados de solos.


Com banco de dados rotulados já estruturado, iniciou-se o processo de elaboração do modelo de classificação automática baseado na experiência e critérios definidos por um especialista. Para esta etapa, adotou-se uma arquitetura de Rede Neural Convolucional (CNN) de baixa complexidade, tendo adição de técnicas de regularizações com objetivo de evitar o sobreajuste da rede e melhor capacidade de generalização.

O modelo proposto tem como finalidade a classificação de agregados de solo em três categorias morfológicas distintas: *bom*, *regular* e *ruim*. As imagens de entrada foram padronizadas para uma resolução de 224x176 pixels, com três canais (RGB).

Considerado-se que a análise trata da morfologia dos agregados, a redução da resolução não compromete a representatividade das informações relevantes para a classificação.

A estrutura da rede selecionada apresenta uma arquitetura de baixa complexidade, sendo composta por camadas convolucionais intercaladas por funções de ativação, camadas de regularização e operações de subamostragem, resultando em uma camada densa responsável pela decisão final quanto à classe atribuída. O modelo encontra-se ilustrado na **Figura 15**

Figura 15 – Ilustração do funcionamento do modelo de classificação da forma do agregado.



Fonte: Autoria Própria, 2025

A *Camada Convolutiva (Conv2D)* consiste na aplicação de filtros convolucionais 3x3 com ativação não-linear ReLU (*Rectified Linear Unit*), a fim de extrair progressivamente características locais da imagem. A profundidade dos filtros aumenta em cada bloco (32, 64, 128 e 256 filtros), permitindo a modelagem hierárquica de padrões visuais.

Já na operação de *Subamostragem por Máximo (MaxPooling2D)*, a dimensionalidade espacial dos mapas de ativação reduz por meio de janelas de 2x2, o que contribui para a diminuição da complexidade computacional do modelo. Além disso, essa operação favorece a invariância local à translação, permitindo o reconhecimento de padrões visuais mesmo quando há deslocamentos espaciais na imagem de entrada.

Como técnica de regularização, foi adotado o *Dropout*, aplicado em cada bloco convolutivo com taxa de 10% (0.1) antes em todas as camadas, antes do Maxpooling. Essa técnica consiste na desativação aleatória de unidades durante o treinamento, promovendo robustez do modelo e prevenindo dependência entre os neurônios, o que contribui para evitar *overfitting*. O valor do dropout utilizado foi baixo para não penalizar o resultado do modelo (Srivastava et al., 2014).

Após a extração hierárquica de características, os mapas de ativação são achatados (Flatten) e conectados a uma camada densa com 128 unidades e ativação ReLU, responsável por integrar as informações extraídas ao longo da rede. Em seguida, aplica-se uma nova camada Dropout com 10% de taxa, como forma de reforçar a regularização antes da camada de decisão (Géron, 2021).

Para a camada de saída foi proposto o uso de três neurônios com função de ativação *softmax* para realizar a classificação de múltiplas classes. Enquanto como compilador do modelo foi utilizado o otimizador **Adam**, uma variante adaptativa do gradiente estocástico amplamente utilizada por sua estabilidade e eficiência. Como função de perda, empregou-se a **categorical crossentropy**, padrão para tarefas de classificação com rótulos codificados em *one-hot*. A métrica de avaliação utilizada durante o treinamento foi a acurácia (*accuracy*), mensurando a proporção de previsões corretas.

Por fim, a **Tabela 1** apresenta de forma detalhada a composição do modelo e a quantidade de parâmetros por cada uma das camadas, bem como a soma de parâmetros treináveis e não treináveis.

Tabela 1 - Composição das camadas e levantamento de parâmetros treináveis do modelo

Camada	Saída	Parametro
Convolução (conv2D)	(None, 222, 174, 32)	896
ReLU	(None, 222, 174, 32)	0
Dropout	(None, 222, 174, 32)	0
Subamostragem (Maxpooling)	(None, 111, 87, 32)	0
Convolução (conv2D)	(None, 109, 85, 64)	18496
ReLU	(None, 109, 85, 64)	0
Dropout	(None, 109, 85, 64)	0
Subamostragem (Maxpooling)	(None, 54, 42, 64)	0
Convolução (conv2D)	(None, 52, 40, 128)	73856
ReLU	(None, 52, 40, 128)	0
Dropout	(None, 52, 40, 128)	0
Subamostragem (Maxpooling)	(None, 26, 20, 128)	0
Convolução (conv2D)	(None, 24, 18, 256)	295168
ReLU	(None, 24, 18, 256)	0
Dropout	(None, 24, 18, 256)	0
Subamostragem (Maxpooling)	(None, 12, 9, 256)	0
Achatamento (Flatten)	(None, 27648)	0
Dense	(None, 256)	7078144
ReLU	(None, 256)	0
Dropout	(None, 256)	0
Dense	(None, 3)	771
Total Parametros: 7.467.331 (28,49MB)		
Parametros Treinaveis: 7.467.331 (28,49MB)		
Parametros Não Treináveis: 0 (0,00MB)		

Fonte: Autoria Própria, 2025

4.3.1.3 Avaliação da acurácia do modelo de classificação morfométrica do agregado de solos agrícolas.

Como forma de avaliar o desempenho do modelo de classificação, foram utilizados mecanismos de verificação baseados na acurácia, no F1-Score, na matriz de confusão e no índice Kappa-Cohen. Essa combinação de métricas visou proporcionar uma análise mais robusta, considerando tanto a performance geral do modelo quanto a distribuição dos acertos e erros entre as diferentes classes.

A *matriz de confusão* foi utilizada para identificar a distribuição dos acertos e dos erros por classe, evidenciando o desempenho do modelo em cada categoria morfológica de agregados de solo. A partir dela, foram extraídas métricas adicionais, como precisão (precision) e sensibilidade (recall), que subsidiaram o cálculo do *F1-Score*.

Para complementar, foi utilizado o índice do *F1-Score* para avaliação, que combina precisão e recall em um único valor. Essa abordagem é usualmente recomendada para cenários de desequilíbrio de obras. Seu cálculo é representado pela **Equação 4**.

$$F1\ Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (4)$$

Onde:

Precisão (Precision) = A proporção de predições corretas entre todas as predições positivas realizadas pelo modelo;

Sensibilidade (Recall) = A capacidade do modelo em identificar corretamente todos os exemplos positivos.

Para além da acurácia e do F1-Score, empregou-se o *índice Kappa-Cohen* como métrica complementar. O índice *Kappa* quantifica o grau de concordância entre as classificações previstas e as observadas, descontando o efeito do acaso (Cohen, 1960). Essa abordagem é considerada mais rigorosa do que a simples acurácia, especialmente em contextos de modelos exploratórios ou bases de dados moderadas, onde a distribuição entre as classes pode afetar a interpretação dos resultados (Powers, 2011; Sokolova; Lapalme, 2009).

Portanto, a integração da matriz de confusão, do *F1-Score* e do índice *Kappa* permitiu uma avaliação crítica e abrangente do desempenho do modelo de classificação automática de agregados de solo, assegurando maior confiabilidade nos resultados obtidos.

4.3.2. Modelo de segmentação de perturbações visíveis de agregados de solos agrícolas em regiões tropicais.

4.3.2.1 Normalização do banco de dados para treinamento e validação.

A organização do banco de dados utilizado no treinamento do modelo de segmentação das perturbações estruturais em agregados de solo foi configurada de forma distinta daquela adotada para a rede neural convolucional (CNN) de classificação morfológica. Para a implementação da arquitetura U-Net, foram necessárias etapas adicionais de pré-processamento voltadas à elaboração dos conjuntos de imagens, máscaras (rótulos) e seleção de conjuntos de imagens para compor o banco de validação.

Considerando que a U-Net exige o pareamento entre cada imagem e sua respectiva máscara binária, os arquivos foram organizados em pastas separadas, tanto para o banco de treinamento quanto para o banco de validação (Ronneberger et al., 2015). Uma das pastas contém as imagens originais (*pasta imagens*) e outra contém as respectivas máscaras segmentadas (*pasta máscara*).

O banco de 4.425 imagens digitais foi utilizado para a criação do conjunto de entrada, sendo que cada imagem foi convertida para o formato .PNG e submetida a um conjunto de técnicas de processamento digital que permitiram a identificação das regiões de interesse. As máscaras resultantes foram geradas em composição binária (preto e branco), nas quais os pixels em branco indicam as áreas associadas a perturbações físicas ou biológicas nos agregados de solo.

Para a geração das máscaras binárias destinadas à segmentação, foi adotado o uso de filtros de Gabor para identificação dos elementos escuros da imagem a partir da textura. A abordagem consistiu na aplicação de diversos filtros com diferentes combinações de parâmetros, incluindo quatro orientações (θ), dois valores de largura (σ), quatro comprimentos de onda (λ) e duas razões de aspecto (γ), totalizando 64 filtros distintos.

Cada filtro foi aplicado à imagem em escala de cinza por meio da função `filter2D` da biblioteca OpenCV, resultando em um conjunto de 64 imagens filtradas, cada uma enfatizando estruturas texturais específicas.


Para a seleção do filtro a ser utilizado, considerou-se a capacidade extração da informação de elementos escuros, fissuras, sombreamento de raízes e fraturas do agregado de solo. Portanto, essa decisão possibilita localizar áreas que sofreram

perturbações físicas, independente se promovida por ações biológica, expansão/contração do solo ou ação antrópica (Hénin et al., 1976; Tisdall; Oades, 1982; Li et al, 2016; Six, 2006). Tendo em vista que o produto final dessas perturbações esteja associado a essas texturas escuras, ressalta-se a importância para a formação de nichos e suporte à microfauna do solo, portanto sendo importante seu mapeamento (Young; Crawford, 2004).

Entre essas, selecionou-se as imagens correspondentes ao filtro de índice 16, associado aos seguintes parâmetros: orientação de 45° ($\theta = \pi/4$), largura $\sigma = 1$, comprimento de onda $\lambda = \pi/4$ e razão de aspecto $\gamma = 0,5$. Este filtro apresentou melhor resposta na detecção de estruturas alongadas e diagonais com contornos suaves, por exemplos identificação de fissuras em rochas e raízes em solos. Sendo assim, características como essas são relevantes para a morfologia dos agregados de solo em questão (Phalempin et al., 2021; Gabor, 1946; Jain; Farrokhnia, 1991).

Após a filtragem, aplicou-se uma binarização por limiar fixo (threshold) sobre a imagem selecionada, a fim de gerar a máscara binária. A segmentação final foi obtida por meio da aplicação lógica da máscara à imagem original. Esse procedimento permitiu realçar regiões com resposta textural relevante (**Figura 16**).

Figura 16 – a) Imagem original; b) Resultado do Gabor; c) Máscara final.



Fonte: Autoria Própria, 2025

Para a organização do banco de dados destinado ao treinamento da U-Net, implementou-se um procedimento automatizado de separação dos arquivos em conjuntos de treinamento e validação, com divisão estratificada aplicada a imagens e suas respectivas máscaras.

O algoritmo desenvolvido assegurou o pareamento entre arquivos de entrada (imagens) e seus rótulos (máscaras) ao realizar a leitura dos nomes de arquivos presentes nas respectivas pastas. Após ordenar ambas as listas para manter a correspondência exata, aplicou-se a função `train_test_split` do módulo

sklearn.model_selection, utilizando uma taxa de 30% para validação e uma semente aleatória (random_state=42) para garantir reprodutibilidade.

Por fim, os arquivos foram movidos automaticamente para quatro diretórios distintos: imagens de treino, máscaras de treino, imagens de validação e máscaras de validação. Portanto, finalizando a estrutura necessária para o carregamento da entrada dos dados para o treinamento do modelo.

4.3.2.2 Modelo de segmentação elementos sombreados e escuros de agregados de solos agrícolas.

Para a tarefa de segmentação semântica de elementos morfológicos em agregados de solo, foi implementado um modelo baseado na arquitetura U-Net, reconhecida por sua eficácia em tarefas de segmentação pixel a pixel (Ronneberger et al., 2015). Destaca-se, também, que a rede escolhida tem apresentado um bom histórico de identificação, segmentação e generalização de imagens de solos, por exemplo no estudo Smith et al., (2020).


Antes de iniciar a configuração do modelo, foi necessário realizar um processamento dos dados e preparar as imagens para o iniciar o treinamento. Esse pré-processamento das imagens de entrada incluiu: (i) recorte automático (*auto-crop*) guiado por limiar de intensidade para remoção de bordas irrelevantes; (ii) redimensionamento com preenchimento (*padding*) para a dimensão padronizada de 2560×1920 pixels; e (iii) divisão de cada imagem (*tiling*) em seis subimagens (*patches*), redimensionadas para 960×853 pixels.

Essa estratégia permitiu a preservação de detalhes morfológicos em diferentes regiões da imagem, assegurando compatibilidade com a arquitetura da rede e favorecendo o desempenho do treinamento em lote. Ainda que o conteúdo visual tenha sido fracionado, foram geradas instâncias independentes de regiões morfológicas distintas, configurando uma forma de *data augmentation* estrutural. Tal procedimento ampliou a variabilidade dos exemplos apresentados ao modelo, favorecendo a generalização e contribuindo para a redução do sobreajuste (Smith et al., 2020; Zou et al., 2024).

Após a consolidação do conjunto de entrada, procedeu-se à configuração da arquitetura U-Net. A arquitetura do modelo apresenta forma simétrica, composta por dois caminhos: um de codificação (ou contração) e outro de decodificação (ou expansão) (**Figura 17**).

No caminho de codificação, foram aplicadas convoluções sucessivas e operações de subamostragem (*max pooling*) com o objetivo de extrair e condensar características locais da imagem, reduzindo sua resolução e aprofundando a representação semântica, por meio da atribuição de rótulos (máscara) à classe de interesse em nível de pixel (**Figura 17a**). Já no processo de decodificação, realizou-se a recuperação da resolução espacial por meio de operações de *upsampling* e convoluções transpostas, possibilitando a reconstrução da segmentação detalhada (**Figura 17b**). Os parâmetros do modelam encontra-se descritos na **Tabela 2**.

Figura 17 – a) Área de Codificador (Encoder) da U-Net; b) Área de decodificador (Decoder) da U-net



Fonte: adaptado de Ronneberger et al., 2015

A presença de conexões de atalho (*skip connections*) entre camadas de mesma escala nos caminhos de codificação e decodificação permitiu a transferência direta de mapas de ativação iniciais para as camadas correspondentes da fase de expansão. Essa estratégia viabiliza a preservação e recuperação de detalhes espaciais finos perdidos durante o processo de downsampling (codificação), portanto sendo uma estratégia de melhoria da precisão da segmentação. (Ronneberger et al., 2015).

No percurso de codificação, observou-se o aumento progressivo da profundidade das ativações (64, 128, 256 e 512 filtros), enquanto no percurso de decodificação, a profundidade foi reduzida de forma simétrica (256, 128 e 64 filtros).

Cada bloco foi constituído por camadas convolucionais com ativação ReLU, normalização em lote (BatchNormalization) e subamostragem espacial (MaxPooling2D).

A extração de mapas de características locais foi realizada pelas camadas Conv2D, por meio da aplicação de filtros convolucionais com ativação ReLU (*Rectified Linear Unit*), responsável por introduzir não linearidade e mitigar problemas de gradiente desvanecido. A normalização das ativações internas foi executada por meio da camada BatchNormalization, a fim de estabilizar o treinamento e acelerar a convergência. A redução da resolução espacial, necessária para a extração de padrões em múltiplas escalas, foi realizada pelas camadas MaxPooling2D (Géron, 2021; Smith et al., 2020).

No caminho de decodificação, a recuperação da resolução foi realizada com o uso de camadas Conv2DTranspose, seguidas de redimensionamento (*resize*) e concatenação com os mapas de ativação do caminho de codificação, por meio das conexões de atalho. Após cada concatenação, foi aplicada nova convolução com ativação ReLU, com o objetivo de refinar a reconstrução da máscara segmentada.

A camada de saída foi configurada com um filtro convolucional 1×1 e ativação sigmoide devido a segmentação de apenas duas classes, gerando um mapa binário correspondente à segmentação final da imagem.

O modelo foi compilado com o otimizador *Adam* (taxa de aprendizado de $1e^{-4}$), utilizando a função de perda *binary_crossentropy* e as métricas *accuracy*, *recall* e *precision*. O treinamento foi conduzido com os recursos de *EarlyStopping*, para interrupção baseada na perda de validação, e *ModelCheckpoint*, destinado ao salvamento do melhor modelo.

O conjunto de dados foi estruturado com imagens e máscaras organizadas em diretórios distintos para treino e validação, sendo processado por meio da aplicação *tf.data.Dataset*, com leitura emparelhada e aplicação paralela das etapas de pré-processamento. Cada imagem foi dividida em seis *patches*, aumentando a quantidade de exemplos por época e favorecendo a estabilidade do treinamento.

Tabela 2 - Composição das camadas e respectivos parâmetros treinados.

Camada	Saída Estimada	Parâmetros
Input	(960, 853, 1)	0
Conv2D	(960, 853, 64)	640
BatchNormalization	(960, 853, 64)	256
MaxPooling2D	(480, 426, 64)	0
Conv2D	(480, 426, 128)	73856
BatchNormalization	(480, 426, 128)	512
MaxPooling2D	(240, 213, 128)	0
Conv2D	(240, 213, 256)	295168
BatchNormalization	(240, 213, 256)	1024
MaxPooling2D	(120, 106, 256)	0
Conv2D	(120, 106, 512)	1180160
BatchNormalization	(120, 106, 512)	2048
Dropout	(120, 106, 512)	0
Conv2DTranspose	(240, 213, 256)	1179904
Resize + Concatenate	(240, 213, 512)	0
Conv2D	(240, 213, 256)	1179904
Conv2DTranspose	(480, 426, 128)	295040
Resize + Concatenate	(480, 426, 256)	0
Conv2D	(480, 426, 128)	295040
Conv2DTranspose	(960, 853, 64)	73792
Resize + Concatenate	(960, 853, 128)	0
Conv2D	(960, 853, 64)	73792
Conv2D (final)	(960, 853, 1)	65
Total Parametros: 4.651.201 (17,74MB)		
Parametros Treinaveis: 4.649.281 (17,74MB)		
Parametros Não Treináveis: 1.920 (7,50KB)		

4.3.2.3 Avaliação da acurácia da segmentação gerada pela rede U-Net em agregados de solos agrícolas.

A avaliação do desempenho da arquitetura U-Net foi conduzida com base em um conjunto de *teste*, o qual foi composto por imagens e máscaras não utilizadas durante a etapa de treinamento. Cada imagem foi submetida ao mesmo protocolo de pré-processamento adotado na fase de treinamento, o qual incluiu: auto-corte orientado por limiar de intensidade, redimensionamento com preenchimento (*padding*) para dimensões padronizadas, conversão para escala de cinza, divisão em seis subimagens (*tiling*) e redimensionamento final para 960 × 853 pixels.

O modelo previamente treinado foi carregado com os pesos correspondentes à sua melhor performance durante o treinamento e aplicado ao conjunto de teste, com o objetivo de avaliar sua capacidade de generalização na tarefa de segmentação binária.

Nesse contexto, a avaliação da acurácia do modelo foi realizada com base em métricas estatísticas derivadas da matriz de confusão, a qual possibilita a comparação direta entre as máscaras preditas e as máscaras de referência. A partir dessa matriz,

foram extraídas as métricas de sensibilidade (*recall*), especificidade, além da contagem de falsos positivos (FP) e falsos negativos (FN).

A sensibilidade foi definida como a razão entre os verdadeiros positivos (VP) e a soma entre verdadeiros positivos e falsos negativos ($VP + FN$), refletindo a capacidade do modelo de identificar corretamente os pixels pertencentes à classe positiva (perturbações físicas).

A especificidade, por sua vez, foi calculada como a razão entre verdadeiros negativos (VN) e a soma entre verdadeiros negativos e falsos positivos ($VN + FP$), indicando a capacidade de reconhecer adequadamente os pixels da classe negativa (fundo).

Além dessas métricas proporcionais, foi realizada a contabilização absoluta da média de FP e FN por imagem, a fim de quantificar a magnitude dos erros cometidos pelo modelo em termos de número total de pixels incorretamente classificados.

A principal métrica adotada para quantificação do desempenho do modelo foi o *coeficiente de DICE* (*DICE Similarity Coefficient* – DSC), amplamente utilizado em tarefas de segmentação semântica por medir a similaridade entre a segmentação de referência e a predição binária obtida a partir do modelo (Smith et al., 2020).

Como complemento à análise quantitativa, foi realizada uma avaliação qualitativa visual, por meio da comparação lado a lado entre a imagem original, a máscara de referência e a máscara segmentada. A visualização simultânea das três representações, juntamente com os mapas de erro, contribuiu para a compreensão dos padrões de falha e da sensibilidade da rede frente às variações morfológicas observadas.

5. RESULTADOS E DISCUSSÃO

Para fins de apresentação, os tópicos foram organizados em quatro grandes eixos. O primeiro eixo dá destaque à análise da condição granulométrica e dos índices de estabilidade dos agregados, obtidos no primeiro contato com as amostras de solo.

Na sequência, realizou-se relatos e observações sobre os desafios enfrentados durante o processo de aquisição das imagens, os quais poderão ser otimizados em estudos futuros.

Posteriormente, são introduzidos e contextualizados os resultados obtidos a partir dos dois modelos empregados, sendo primeiramente apresentado o modelo de classificação morfológica dos agregados e, logo após, os resultados do modelo de segmentação das perturbações físicas e biológicas dos agregados.

5.1. Condição granulométrica e índice de estabilidade de solos agrícolas tropicais

5.1.1 Condição da amostra após peneiramento do solo.

A realização do peneiramento com frequência média de 2400 vpm durante três minutos permitiu a obtenção de agregados com menor evidência de abrasão superficial, além de contribuir para a redução da fratura dos agregados provocada durante o peneiramento do solo agrícola.

Conforme ilustrado nas Figuras **18A** e **18B**, observou-se menor desgaste aparente nos agregados retidos na peneira de 4 mm, com redução da tonalidade esbranquiçada frequentemente gerada durante a etapa de peneiramento das amostras. Na **Figura 18A**, o peneiramento foi realizado conforme os parâmetros metodológicos propostos. Em contraste, a **Figura 18B** apresenta uma amostra submetida a um processo de peneiramento mais agressivo, com vibração de 3.600 vpm durante o mesmo intervalo de tempo.

A diferença de coloração provocada pelo processo de abrasão durante o peneiramento pode afetar diretamente a qualidade da imagem final. Essa alteração introduz um novo elemento visual à representação do agregado, adicionando complexidade a um cenário que, por si só, já não é trivial para ser tratado por modelos de segmentação automática (Ronneberger et al., 2015; Ribeiro et al., 2020; Smith et al., 2020).

Figura 18 - Abrasão em agregado de solos



Fonte: Autoria Própria, 2025.

5.1.1 Condição da estabilidade de agregados de solos agrícolas

Com base na massa retida em cada peneira, foram aplicadas as fórmulas correspondentes para o cálculo dos índices de Diâmetro Médio Ponderado (DMP) e do Diâmetro Médio Geométrico (DMG). Esses indicadores são amplamente utilizados na caracterização da estabilidade estrutural dos agregados de solo, por fornecerem medidas quantitativas relacionadas à resistência à desagregação mecânica e à distribuição do tamanho das partículas (Kemper; Rosenau, 1986).

O DMP expressa a média ponderada dos diâmetros dos agregados, atribuindo maior peso às classes de maior massa, sendo frequentemente utilizado como referência para comparações entre tratamentos físicos ou químicos (Teixeira et al., 2017). O DMG, por sua vez, leva em consideração a distribuição geométrica dos tamanhos de partículas, sendo mais sensível à presença de agregados de menor diâmetro (Castro Filho et al., 1998).

Os resultados obtidos por meio desses cálculos encontram-se descritos na Tabela 3, permitindo uma avaliação comparativa da qualidade estrutural dos agregados de solo entre os diferentes tratamentos ou condições analisadas. Os dados brutos com as informações por peneira encontram-se no **Apêndice A**.

Tabela 3 – Relação das características de cada amostra de solo.

ID	Tipo	Estado	Cultura atual	Cultura anterior	Ciclos	Dosagem (L/ha)	DMP	DMG
1	Testemunha	Mato Grosso	Soja	Milho	0	0	1,8	0,9
	Biofertilizante	Mato Grosso	Soja	Milho	6	150	1,47	0,7
2	Testemunha	Mato Grosso	Soja	Milho	0	0	2,25	1,33
	Biofertilizante	Mato Grosso	Soja	Milho	4	150	1,96	1,13
3	Testemunha	Mato Grosso	Soja	Milho	0	0	2,22	1,41
	Biofertilizante	Mato Grosso	Soja	Milho	6	150	2,19	1,33
4	Testemunha	Mato Grosso	Soja	Milho	0	0	2,03	1,12
	Biofertilizante	Mato Grosso	Soja	Milho	5	150	2,04	1,16
5	Testemunha	Goiás	Soja	Milho	0	0	1,32	0,63
	Biofertilizante	Goiás	Soja	Milho	4	150	0,89	0,46
6	Testemunha	Goiás	Soja	Milho	0	0	2,22	1,39
	Biofertilizante	Goiás	Soja	Milho	4	150	1,69	0,98
7	Testemunha	Mato Grosso do Sul	Milho	Soja	0	0	2,61	1,78
	Biofertilizante	Mato Grosso do Sul	Milho	Soja	4	150	2,58	1,82
8	Testemunha	Goiás	Milho	Soja	0	0	1,72	0,96
	Biofertilizante	Goiás	Milho	Soja	4	150	1,38	0,74
9	Testemunha	Goiás	Soja	Milho	0	0	1,44	0,7
	Biofertilizante	Goiás	Soja	Milho	6	150	1,67	0,84
10	Testemunha	Mato Grosso do Sul	Cana de Açúcar	Cana de Açúcar	0	0	1,21	0,56
	Biofertilizante	Mato Grosso do Sul	Cana de Açúcar	Cana de Açúcar	3	300	1,13	0,54
11	Testemunha	Goiás	Cana de Açúcar	Cana de Açúcar	0	0	1,18	0,56
	Biofertilizante	Goiás	Cana de Açúcar	Cana de Açúcar	3	300	2,31	1,52
12	Testemunha	Santa Catarina	Macieira	Milho	0	0	2,44	1,78
	Biofertilizante	Santa Catarina	Macieira	Milho	4	300	1,77	1,22
13	Testemunha	Rio Grande do Sul	Trigo	Nabo	0	0	2,68	1,95
	Biofertilizante	Rio Grande do Sul	Trigo	Nabo	8	150	2,13	1,37
14	Testemunha	Rio Grande do Sul	Azevém (PASTAGEM)	Azevém (PASTAGEM)	0	0	2,16	1,44
	Biofertilizante	Rio Grande do Sul	Azevém (PASTAGEM)	Azevém (PASTAGEM)	5	150	2,38	1,56
15	Testemunha	Rio Grande do Sul	Canola	Canola	0	0	2,13	1,3
	Biofertilizante	Rio Grande do Sul	Canola	Canola	5	150	2,06	1,28
16	Testemunha	Rio Grande do Sul	Trigo	Soja	0	0	2,16	1,35


	Biofertilizante	Rio Grande do Sul	Trigo	Soja	4	150	2,3	1,55
17	Testemunha	Santa Catarina	Aveia Branca	Trigo	1	0	2,55	1,74
	Biofertilizante	Santa Catarina	Aveia Branca	Milho	5	150	3,34	2,87
18	Testemunha	Santa Catarina	Trigo	Trigo	0	0	2,63	1,97
	Biofertilizante	Santa Catarina	Trigo	Trigo	5	150	2,9	2,36
19	Testemunha	Paraná	Milho Safrinha	Soja	0	0	2,64	1,96
	Biofertilizante	Paraná	Milho Safrinha	Soja	6	150	2,31	1,62
20	Testemunha	Paraná	Soja	Milho Safrinha	0	0	2,72	2,06
	Biofertilizante	Paraná	Soja	Milho Safrinha	4	150	2,51	1,83
21	Testemunha	Paraná	Soja	Trigo	0	0	2,97	2,28
	Biofertilizante	Paraná	Soja	Trigo	5	150	2,61	1,88
22	Testemunha	Paraná	Soja	Milho Safrinha	0	0	2,32	1,45
	Biofertilizante	Paraná	Soja	Milho Safrinha	8	150	2,41	1,54

Fonte: Autoria Própria, 2025

Os resultados obtidos revelaram variações relevantes nos índices analisados, com comportamentos distintos entre as regiões. De forma geral, a região Sul do Brasil (Paraná, Santa Catarina e Rio Grande do Sul) apresentou os valores mais elevados para os índices de Diâmetro Médio Ponderado (DMP) e Diâmetro Médio Geométrico (DMG), o que sugere melhores condições estruturais dos agregados de solo nessas localidades. Esses índices, portanto, destacam os solos com maior resistência à erosão, melhor estabilidade hídrica e maior resiliência a práticas de manejo intensivo (Six et al., 2000; Castro Filho et al., 1998).

Em contraste, nas amostras provenientes da região Centro-Oeste, observou-se maior dispersão nos valores dos índices cujos resultados variaram bastante, evidenciando possível heterogeneidade estrutural nos agregados amostrados (**Tabela 3**).

Nesse sentido, observou-se uma diferença entre as amostras avaliadas, principalmente quando comparado os resultados das amostras coletadas no Sul com aquelas do Centro-Oeste brasileiro. Ao observar a distribuição conforme ilustrado nos Boxplot das **Figura 19 e 20**, percebe-se uma leve similaridade no comportamento em ambas as regiões e entre as regiões estudadas.

Figura 19 – Gráfico Boxplot do Diâmetro Médio Ponderado (DMP).

Fonte: Autoria Própria, 2025

No que se refere ao índice DMP, observou-se que nenhuma das regiões atingiu, de forma geral, a marca de 3 mm de diâmetro médio ponderado. No entanto, destaca-se a propriedade identificada pelo código ID 17 (**Tabela 3**), cuja amostra submetida ao tratamento com biofertilizante alcançou o valor de 3,34 mm, indicando uma condição estrutural favorável do solo nessa área específica, ao menos considerando a amostra analisada.

Esse resultado ilustra a integridade dos agregados, uma vez que maiores valores estão associados a sistemas bem estruturados e que podem apresentar resistentes à disrupção mecânica e hídrica (Tisdall & Oades, 1982; Six et al., 2000). Dessa maneira, espera-se para composição do banco de dados imageados uma enorme variedade de agregados, com condições variadas.

No que se refere ao Diâmetro Médio Geométrico (DMG), observa-se uma maior proporção de agregados com diâmetros superiores nas amostras provenientes da região Sul do Brasil, em comparação com aquelas do Centro-Oeste.

Para as amostras testemunhas da região Centro-Oeste, o DMG variou de 0,56 a 1,78 mm, com média aproximada de 1,00 mm. No caso das amostras tratadas com biofertilizante, a variação foi de 0,46 a 1,82 mm, também com média próxima de 1,00 mm.


Já na região Sul, os valores de DMG foram substancialmente superiores. As amostras testemunhas apresentaram granulometria variando de 1,30 a 2,28 mm, com

média de 1,75 mm. Para as amostras com adição de biofertilizante, o DMG oscilou entre 1,22 e 2,36 mm, com média de 1,73 mm.

Tais resultados sugerem que os agregados de solo da região Sul apresentam maior estabilidade estrutural e coesão interna, independentemente da aplicação de biofertilizante. Essa condição é evidenciada pelos maiores valores de Diâmetro Médio Geométrico (DMG), indicativo da predominância de agregados de maior dimensão e com maior resistência à desagregação física (Six et al., 1999; Bronick; Lal, 2005).

De acordo com Mikha et al. (2022), maiores valores de DMG estão associados a solos com melhor organização física e maior proteção contra processos erosivos. Ainda assim, para que se possa afirmar com maior precisão a estabilidade estrutural por propriedade, seriam necessárias análises mais detalhadas em nível individual, o que ultrapassa os objetivos deste trabalho. Dessa forma, o propósito aqui está em compreender padrões gerais entre as amostras, a fim de subsidiar melhor compreensão para a elaboração do banco de dados digital destinado ao treinamento do modelo de análise automática de agregados.

Figura 20 – Gráfico Boxplot do Diâmetro Médio Geométrico (DMG).



Fonte: Autoria Própria, 2025

Vale destacar também que, observou-se uma concentração significativa de agregados nas faixas granulométricas de 1 mm e 2 mm, correspondentes às peneiras de mesmo diâmetro. Essa predominância indica a necessidade de atenção especial a essas classes em análises futuras, uma vez que agregados com essas dimensões

podem apresentar comportamento estrutural diferenciado e maior suscetibilidade a alterações em função do manejo ou das condições ambientais.

Para encerrar a análise do entendimento sobre as amostras, foi realizado a análise estatística breve apenas para entender a significância das diferenças entre os tipos de amostragem e entre as regiões que se realizou o estudo (**Tabela 4**).

Tabela 4 – Avaliação da significância da diferença entre regiões e tipos de amostra.

Comparação	Variável	Teste	p-valor
CO-Testemunha vs CO-Biofertilizante	DMP	t-teste	0,9547
CO-Testemunha vs CO-Biofertilizante	DMG	t-teste	0,9951
Sul-Testemunha vs Sul-Biofertilizante	DMP	t-teste	0,1407
Sul-Testemunha vs Sul-Biofertilizante	DMG	t-teste	0,0901
CO-Testemunha vs Sul-Testemunha	DMP	t-teste	0,0169
CO-Testemunha vs Sul-Testemunha	DMG	t-teste	0,0108
CO-Biofertilizante vs Sul-Biofertilizante	DMP	t-teste	0,0275
CO-Biofertilizante vs Sul-Biofertilizante	DMG	t-teste	0,0044

Fonte: Autoria Própria, 2025

Os resultados demonstram que a aplicação do biofertilizante não apresentou diferenças estatisticamente significativas nas variáveis estudadas (DMP e DMG) dentro das regiões analisadas, com exceção de uma pequena tendência de aumento no DMG da região Sul ($p = 0,0901$). Isso sugere que, sob as condições experimentais e amostrais adotadas, o efeito do biofertilizante sobre a estrutura dos agregados não se mostrou expressiva.

Por outro lado, as comparações inter-regionais revelaram diferenças significativas ($p < 0,05$) em todas as variáveis testadas (DMP e DMG), tanto nas amostras testemunha quanto nas tratadas com biofertilizante. Esses resultados indicam que os solos da região Sul apresentam maior estabilidade estrutural, refletida por valores superiores nos índices de diâmetro médio ponderado, diâmetro médio geométrico e estabilidade dos agregados.

Essas diferenças regionais podem estar associadas a condições edafoclimáticas mais favoráveis, como maior teor de matéria orgânica, histórico de manejo mais conservacionista ou características intrínsecas dos solos do Sul do Brasil. Tais evidências corroboram a literatura que aponta que a formação e a estabilidade de agregados estão fortemente relacionadas às propriedades físicas, biológicas e à qualidade do manejo agrícola (Six et al., 2000; Bronick & Lal, 2005; Blanco-Canqui & Lal, 2004).

5.2. Processo de aquisição das imagens digitais

Com a definição do conjunto de agregados de solo a serem utilizados, iniciou-se o processo de aquisição das imagens digitais em luz visível (RGB) destinadas à composição do banco de dados. Durante essa etapa, identificaram-se limitações técnicas associadas à complexidade morfológica dos agregados, como a presença de formas irregulares e superfícies com elevada rugosidade.

Essas características físicas favoreceram a ocorrência de regiões sombreadas, borramentos ópticos causados por instabilidade no foco e excesso de brilho, especialmente em superfícies com elevado teor de quartzo ou compostos arenosos claros, que podem gerar saturação de pixels nas imagens adquiridas.

A **Figura 21** ilustra problemas observados durante a aquisição de imagens, especialmente relacionados ao escurecimento e ao sombreamento excessivo dos agregados.

O escurecimento pode estar associado à composição superficial dos agregados visualizados por microscopia, particularmente à presença de matéria orgânica e teores mais elevados de óxidos de ferro ou manganês. Esses compostos possuem alto potencial de absorção da radiação incidente na faixa do visível, resultando em baixa reflectância da superfície do agregado (Ben-Dor; Banin, 1995; Bartholomeus et al., 2008).

Essas condições favorecem a formação de áreas com saturação de sombra ou regiões uniformemente escuras, reduzindo o contraste interno das imagens e dificultando a distinção de detalhes dos limites entre uma estrutura e outra. Como consequência, observa-se perda de contraste interno nas imagens, dificultando a identificação de limites estruturais e comprometendo etapas posteriores de segmentação (Aitkenhead et al., 2018; Smith et al., 2020)

Figura 21 – Exemplo de interações com agregados escuros.



Fonte: Autoria Própria, 2025.

Em situações com rugosidade elevada ou iluminação direta sobre minerais claros adjacentes (como quartzo), observou-se também o efeito inverso, portanto com brilho excessivo e saturação de pixels (**Figura 22**). Assim, a abundância elementos com alta reflectância, como o quartzo na superfície dos agregados, pode incorporar limitações técnicas na obtenção de imagens de alta qualidade para análise automatizada.

No estudo de Tian e Philpot (2018) demonstrou-se que amostras de areia de quartzo seca apresentaram alta reflectância direcional, em especial na direção frontal, ângulo esse que foi utilizado neste estudo. Além disso, a reflectância diminuiu significativamente quando submetido a amostra à saturação hídrica, evidenciando a influência da umidade na reflectância do solo.

Dessa forma, ao realizar imageamento de solos arenosos com alto teor de quartzo, deve-se considerar ajustes na iluminação, ângulo de irradiação da iluminação e nas configurações do equipamento para melhorar a captura de imagens.

Figura 22 – Exemplo de interação de agregados arenosos e elevada reflectância.



Fonte: Autoria Própria, 2025.

Por fim, outra limitação identificada esteve relacionada à ocorrência de borramento óptico, parcialmente mitigada por meio do recurso *EDOF* (*Extended Depth of Field*), já implementado no software nativo do equipamento Dino-Lite. Essa funcionalidade permitiu a aquisição de imagens em diferentes planos de foco e o empilhamento automático das camadas, resultando em fotografias com maior profundidade de campo (**Figura 23**).

Apesar disso, em algumas amostras com rugosidade acentuada e variações expressivas de altura, observou-se a ocorrência de embaçamentos pontuais, atribuídos à limitação do próprio algoritmo de composição em situações de geometria extremamente irregular.

Figura 23 – Exemplo de interação de agregados rugosos e borramento.



Fonte: Autoria Própria, 2025.


Por fim, sinaliza-se neste capítulo, a complexidade das imagens que integraram o banco de dados utilizado para o treinamento dos modelos de classificação e segmentação. Cabe ressaltar que essa complexidade está associada, sobretudo, à heterogeneidade dos agregados e às limitações do sistema de iluminação intrínseco ao microscópio. No entanto, torna-se indispensável a utilização de iluminação externa ao microscópio e que possibilite diferentes ângulos de iluminação do agregado, desabilitando o controle das sombras e ressaltando detalhes na imagem (Kerp e Bomfleur, 2011).

5.3. Classificação dos agregados de solos por meio da morfometria

O treinamento da Rede Neural Convolucional (RNC), desenvolvida para a classificação dos agregados de solo conforme a morfometria, demandou, em média, 80 segundos por época, com tempo aproximado de 4 segundos por lote, considerando 19 lotes por época. O processo foi conduzido durante dez épocas, sem interrupções antecipadas por critérios de parada, dada a estabilidade observada no desempenho do modelo.

Observa-se uma trajetória decrescente ao longo das épocas, com redução contínua do erro em ambos os conjuntos. A proximidade entre as curvas de treinamento e validação sugere ausência de sobreajuste (overfitting), o que indica generalização adequada do modelo, conforme discutido por Géron (2021) (**Figura 24A**). Esse comportamento é desejável durante o processo de aprendizagem supervisionada, pois evidencia que o modelo foi capaz de aprender a partir dos dados sem memorizá-los de forma excessiva.

Figura 24 – Evolução da função de perda (A) e da acurácia (B) nos conjuntos de treinamento e validação durante o processo de treinamento da RNC.



Fonte: Autoria Própria, 2025

Ao observar o comportamento da curva da **Figura 24B**, visualiza-se a evolução da acurácia conforme o avanço das épocas do treinamento, partindo de 45% e alcançando 75,3%, sendo a acurácia de validação de 78,1%. Ambas as curvas apresentam uma tendência ascendente consistente, o que demonstra que o modelo foi capaz de aprender progressivamente, reduzindo os erros de classificação à medida que os pesos eram atualizados. A ausência de oscilações abruptas ou quedas expressivas na curva de validação ao longo do processo reforça que o modelo não sofreu degradação em sua capacidade de generalização.


Esse padrão de comportamento sugere que o modelo está em trajetória de aprendizado estável e ainda apresenta margem para aprimoramentos adicionais, como o aumento no número de épocas ou ajustes nos hiperparâmetros. A sincronia entre as curvas de acurácia e os indicadores globais reforça a robustez do modelo em tarefas de classificação multiclasse com dados visuais.

Tendo em vista o comportamento positivo do processo de treinamento da rede, observa-se um cenário promissor para a aplicação do modelo. Entretanto, a validação da acurácia permanece como etapa fundamental para garantir a consistência dos resultados obtidos e para nortear melhorias futuras no desempenho da rede.

Nesse sentido, para a validação do modelo, como já descrito a metodologia de avaliação, foi explorado abordagens com matriz de confusão, índice kappa e F1-Score. A **Figura 25** apresenta a matriz de confusão obtida a partir da classificação morfométrica dos agregados de solo em três categorias: *bom*, *regular* e *ruim*.

Observa-se que os agregados classificados como *bom* foram majoritariamente bem identificados, com 76 acertos e 11 casos confundidos com a classe *regular*. A classe *regular* apresentou maior dispersão nas classificações, com 60 acertos, 19 casos incorretamente classificados como *bom* e outros 10 como *ruim*. Já a classe *ruim* foi corretamente identificada em 28 ocasiões, com 6 casos classificados como *regular* e nenhum confundido com a classe *bom*.

Figura 25 – Matriz de confusão do modelo de classificação pela morfometria dos agregados de solo.



Fonte: Autoria Própria, 2025.

Com a análise matriz, nota-se que os principais erros do modelo se concentram na classificação entre os agregados da classe *regular* e as demais. Esse comportamento pode estar atribuído às características morfométricas intermediárias, que podem apresentar fronteiras com ambos os extremos. Em contraste, a separabilidade entre os extremos morfométricos (*bom* e *ruim*) mostrou-se assertiva, com poucos casos de confusão entre essas duas categorias.

Para subsidiar a interpretação da acurácia do modelo, bem como as respostas da matriz de confusão, a **Tabela 5** apresenta os resultados das métricas de avaliação do desempenho do modelo, incluindo os valores de precisão, recall e F1-Score por classe, além das médias macro e ponderada, acurácia geral e índice de Kappa.

Nesse sentido, observa-se que a classe *bom* apresentou os maiores valores em todas as métricas individuais, enquanto a classe *regular* apresentou os menores desempenhos, especialmente no recall. As médias macro e ponderada foram idênticas (77,9%), indicando equilíbrio na performance entre as categorias. A acurácia geral foi de 78,1% e o índice de Kappa foi de 0,65, refletindo boa concordância entre as classificações do modelo e os rótulos reais.

Tabela 5 – Métricas de desempenho para avaliação da acurácia do modelo de classificação

Classe	Precisão (%)	Recall (%)	F1-Score (%)
Bom	80,80	87,40	83,50
Regular	77,90	67,40	72,30
Ruim	73,70	82,40	77,80
Macro Média	-	-	77,90
Weithed Média	-	-	77,90
Acurácia Geral	78,10	-	-
Índice Kappa	65,10	-	-

Fonte: Autoria Própria, 2025

As métricas de desempenho por classe confirmam as tendências indicadas na matriz de confusão. A classe *bom* apresentou o melhor F1-Score (83,50%), reflexo de sua elevada precisão (80,80%) e recall (87,4%). A classe *ruim* também obteve desempenho satisfatório, com F1-Score de 77,80% e recall elevado (82,40%), embora com precisão de 73,70%, indicando uma leve tendência do modelo em superestimar a ocorrência dessa classe. Por sua vez, a classe *regular* apresentou o menor F1-Score (72,30%) e o menor recall (67,40%), revelando que uma parcela expressiva dos exemplos reais dessa classe não foi corretamente classificada pelo modelo.

As métricas globais reafirmam o bom desempenho geral. A acurácia do modelo foi de 78,1%, enquanto as médias macro e ponderada do F1-Score foram ambas de 77,9%, demonstrando equilíbrio entre as classes e valores muito próximos da acurácia indicada pela curva do treinamento.

Quanto ao índice de Kappa, por sua vez, foi de 0,65, valor considerado como indicativo de concordância substancial entre as previsões do modelo e as classificações reais, segundo a escala de Landis e Koch (1977). Entretanto, esse desempenho inferior pode estar associado à distribuição desbalanceada do banco de dados utilizado para treinamento da rede, fazendo o resultado do índice kappa mais conservador em relação aos demais (Cohen, 1960).

Para complementar a avaliação geral do desempenho do modelo, foi conduzida uma análise específica sobre o grau de acerto e divergência do modelo classificador para três propriedade, totalizando 6 amostras distintas de agregados de solo, somando 600 imagens. Os dados foram segmentados entre amostras de Testemunha e com aplicação de Biofertilizante, conforme apresentado na **Tabela 6**. As tabelas em apresentam as correções indicadas por um especialista encontra-se no **Apêndice B**.

Tabela 6 – Teste para validação da acurácia do modelo de classificação

	Solo 1	Solo 2	Solo 3
Divergência - Testemunha (%)	12	18	13
Divergência - Biofertilizante (%)	14	22	19
Acertos médio por Amostra (%)	87	80	84

Fonte: Autoria Própria, 2025.

Observa-se que os valores de acerto médio por amostra foram elevados, variando entre 80% e 87%, o que reafirma a capacidade do modelo em generalizar a classificação morfométrica para diferentes contextos de solo. A menor taxa de acerto foi registrada para o Solo 2 (80%), que também apresentou os maiores índices de divergência, tanto no tratamento Testemunha (18%) quanto no com Biofertilizante (22%).

A classe *regular* concentrou a maior parte dos erros na análise de saída do modelo. As classes extremas (*bom* e *ruim*) não foram confundidas entre si nas análises das imagens, o que reforça a consistência do modelo nas fronteiras classificatórias. Portanto, verifica-se que a atuação do modelo tem sido satisfatória, embora ainda seja recomendável reavaliar a estratégia arquitetural adotada e os procedimentos de pré-processamento empregados.

No geral, os resultados adquiridos indicam que o modelo apresenta desempenho consistente e adequado para a tarefa de classificação morfométrica dos agregados, especialmente no reconhecimento das classes extremas. No entanto, a classe *regular* ainda representa um desafio, sendo recomendável a busca por estratégias como aumento do banco de treinamento, seja por técnicas de *data augmentation* ou pela aquisição de mais dados (Zou et al., 2024).

O aprimoramento dos descritores morfométricos utilizados ou o emprego de abordagens de aprendizado mais sensíveis à ambiguidade entre categorias limítrofes podem colaborar para uma melhor classificação, especialmente em arquiteturas convolucionais mais simples. Com isso, ressalta-se ainda que o desempenho de RNC com baixa complexidade está fortemente associado à capacidade dos dados de entrada em representar características discriminantes, sobretudo quando as classes apresentam sobreposição morfológica ou transições graduais (Géron, 2021; Smith et al., 2020).

No entanto, deve-se exaltar a classificação realizada pelo modelo desenvolvido pode contribuir para análises de agregados de solos, visto que o resultado se mostrou


eficiente no reconhecimento de uma parcela das imagens. Além disso, com essa acurácia é possível afirmar também que o modelo tem potencial para contribuir com análises da variabilidade de agregados de amostras de solos agrícolas, em especial de solos tropicais (Peché-Filho, 2018; Ribeiro et al., 2020).

5.4. Segmentação de perturbações visíveis em agregados de solos agrícolas tropicais

O modelo U-Net, desenvolvido para segmentar regiões escurecidas que representem perturbações estruturais em fragmentos visíveis de agregados de solo, apresentou tempo médio de 460 segundos por época durante o treinamento, com duração aproximada de 6 segundos por lote, considerando setenta e cinco lotes por época. Inicialmente, planejou-se conduzir o treinamento ao longo de cinquenta épocas, no entanto, a execução foi interrompida na vigésima oitava época em decorrência da ativação do mecanismo de parada antecipada (*EarlyStopping*), que identificou estagnação no desempenho da validação. Tal interrupção permitiu preservar a estabilidade do modelo e evitar sobreajustes, assegurando a confiabilidade dos resultados obtidos (Géron, 2021; Smith et al., 2020).

A perda, apresentada pela **Figura 26A**, destaca a evolução da função de perda (loss) para os conjuntos de treinamento e validação, ao longo das vinte e oito épocas. Dessa maneira, observa-se uma trajetória decrescente ao longo do treinamento, com redução contínua do erro em ambos os conjuntos, mas com estabilização após a décima época. A proximidade entre as curvas de treino e validação indica que o modelo pode não ter sofrido com sobreajuste (overfitting), mantendo bom desempenho generalizável.

Figura 26 – (A) Evolução da função de perda (loss) e validação do modelo de segmentação; (B) Evolução da acurácia (accuracy) e validação do modelo de segmentação.




Fonte: Autoria Própria, 2025.

A **Figura 26B** ilustra a evolução da acurácia durante o treinamento, a qual ultrapassou 98% em ambos os conjuntos, indicando a efetiva aprendizagem da rede. Apesar desse valor elevado, ressalta-se que a acurácia, isoladamente, pode superestimar o desempenho em tarefas de segmentação, sobretudo em cenários mais complexos, como aqueles que envolvem a identificação de classes com estruturas sutis ou detalhes morfológicos finos, especialmente em regiões de fronteira entre classes.

Nesse sentido, avaliação do desempenho do modelo U-Net, desenvolvido para segmentação dos elementos associados às perturbações físicas, encontra-se ilustrada nas **Figuras 27**, sendo (A) referente às métricas de recall e precisão (B) F1-Score. Observa-se, nas curvas de treinamento, que o modelo atinge valores superiores a 0,85 tanto para precisão quanto para recall, com destaque para a precisão de validação, que se mantém acima de 0,90 a partir décima época (**Figura 27A**). Quanto ao recall, apresentou oscilações nas épocas iniciais, possivelmente relacionadas à complexidade das regiões segmentadas, mas estabiliza-se com o progresso do treinamento.

Figura 27 – (A) Evolução da curva da precisão e recall do modelo de segmentação; (B) Evolução da métrica F1-Score do modelo de segmentação



Fonte: Autoria Própria, 2025.

Já o F1-Score (**Figura 27B**), que representa o equilíbrio entre precisão e recall, mostra crescimento consistente e estabilidade a partir da época 15, com valores próximos entre treino e validação, variando entre 0,85 e 0,90. Esses resultados permitem evidenciar que o modelo apresenta capacidade de generalização e que é capaz de realizar a segmentação das regiões-alvo com elevada fidelidade, mesmo diante de variações estruturais e texturais nos agregados de solo.

Nesse sentido, para apresentar forma mais exata, valores finais das métricas de avaliação da acurácia do modelo de segmentação foram descritos na **Tabela 7**, estando todas as métricas já abordadas, mas com adição dos falsos positivos (FP), Falsos Negativos e o índice final, o teste Dice.

Tabela 7 – Métricas de desempenho para avaliação da acurácia do modelo de segmentação

Métrica de Desempenho	Valores
Recall (Val)	0,8922
Precisão (Val)	0,9103
F1-Score (Val)	0,8821
Especificidade	0,9652
Dice médio (teste)	0,6599
Falsos Positivos (FP)	217.437,85
Falsos Negativos (FN)	26.097,85

Fonte: Autoria Própria, 2025


O desempenho do modelo, conforme a avaliação, obteve um recall médio de 0,8922 e especificidade de 0,9652, o que demonstra a capacidade do modelo em detectar de forma sensível as regiões segmentadas, mantendo baixo índice de falsos positivos. Ainda assim, o Dice Score médio final obtido no banco de teste foi de 0,6599. Embora esse valor esteja dentro de padrões aceitáveis para tarefas com complexidade morfológica elevada, como é o caso da segmentação de estruturas

escuras em agregados de solo, esse desempenho pode ter sido influenciado por ruídos intrínsecos à imagem ou pela aplicação de tiling no processo de inferência, o que pode introduzir descontinuidades nas bordas das regiões segmentadas (Ronneberger et al., 2015; Isensee et al., 2021).

Ao observar a **Figura 28**, visualiza-se a imagem de entrada, a máscara real de entrada, a máscara predita pelo modelo e os falsos positivos. Com a riqueza em detalhes, identifica-se o padrão dos erros associados a uma borda extra na máscara predita e ao preenchimento interno da forma segmentada, o que, por si só, não está incorreto. Sendo assim, essa limitação está compatível com o Dice médio de 0,6599 e reforça a influência do *tiling* e da complexidade morfológica sobre o desempenho final do modelo.

Nesse sentido, a aplicação de ferramentas de pré-processamento, como a suavização por curvas gaussianas, a implementação de filtros específicos ou o uso de técnicas de ampliação do banco de dados, pode contribuir para o aprimoramento do desempenho do modelo, favorecendo a identificação de padrões e, conseqüentemente, uma segmentação mais precisa (Smith et al., 2020; Zou et al., 2024).

Figura 28 – A) Segmentação Fatia 1; B) Segmentação Fatia 2.



Fonte: Autoria Própria, 2025.

De modo geral, os resultados alcançados até o momento indicam que a U-Net foi capaz de aprender representações robustas para a segmentação das perturbações em fragmentos visíveis de solos agrícolas, mesmo diante de suas variações estruturais e de textura características.

Ainda que seja desafiador a aquisição de imagens de qualidade e alta resolução dos agregados de solo, bem como o processamento em decorrência da sua não trivialidade em imagens, os resultados demonstram-se promissores para análises de agregados.

Nesse sentido, compreende-se que o modelo pode contribuir, mesmo que ainda necessite de melhorias, para a identificação e segmentação dos elementos escuros da estrutura de agregados. Portanto, afirma-se que sistema permite a quantificação e avaliação das perturbações físicas e biológicas da estrutura dos agregados a partir de imagens de fragmentos visíveis dos agregados de solo.

Essa abordagem mostra-se capaz de colaborar como uma ferramenta de suporte em análises de tipificação de agregados de solo, visto que o modelo pode incrementar técnicas de predição que auxiliam na detecção de formas tubulares (raízes), formas de fissuras ou então orifícios, produzidos por microfauna (Smith et al., 2020; Peche-Filho, 2018)

Dessa maneira, ressalta-se a importância da ferramenta para contribuição de análises de campos e amostras laboratoriais que visam o monitoramento e manutenção da agregação de solos agrícolas.

6. CONSIDERAÇÕES FINAIS

Tendo em vista que neste estudo foram conduzidas diferentes abordagens de avaliação das amostras de solos agrícolas, bem como a análise de imagens digitais dos agregados, observa-se uma contribuição relevante para o aprimoramento de metodologias voltadas à caracterização estrutural do solo.

Os resultados obtidos evidenciaram o potencial do uso de deep learning, aplicado ao processamento de imagens digitais, em estudos voltados à identificação de padrões morfológicos e à detecção de perturbações físicas em agregados de solo.

Apesar da amostragem restrita por propriedade, o protocolo adotado permitiu a obtenção de agregados com distintas características morfológicas, resultando na formação de um banco de dados diversificado.

A seleção de partículas retidas na peneira de 4 mm (faixa entre 4 e 6,3 mm) possibilitou a construção de um banco de imagens com fragmentos visíveis de agregados que apresentaram diferentes formas, texturas superficiais, rugosidades e evidências de ações biológicas.

O protocolo de aquisição de imagens atendeu às expectativas quanto à resolução e nitidez, ainda que tenham sido observadas dificuldades em amostras com coloração muito escura ou presença de quartzo na superfície.

Essas limitações reforçam a necessidade de aprimoramentos ópticos, especialmente pela incorporação de conjuntos de iluminação com ângulos variáveis, a fim de mitigar problemas de reflectância elevada ou insuficiente.

Quanto ao modelo de classificação morfológica, baseado em uma Rede Neural Convolucional de baixa complexidade, observou-se desempenho satisfatório nas classes extremas, com menor acurácia na classe intermediária.

Esse comportamento pode estar associado à sobreposição morfológica entre as categorias, evidenciando a necessidade de reestabelecimento dos parâmetros de rotulagem, bem como da adoção de técnicas de *data augmentation* para fortalecimento do treinamento e aumento da capacidade de generalização do modelo.

Já o modelo de segmentação U-Net, por sua vez, demonstrou desempenho elevado na identificação de elementos escurecidos associados a perturbações estruturais nos agregados.

Apesar da complexidade das imagens utilizadas no treinamento, a rede neural foi capaz de generalizar com precisão. Ruídos e efeitos introduzidos pelo uso de *tiling*

podem ter comprometido parcialmente a acurácia nas bordas segmentadas, sendo recomendável o uso de técnicas adicionais de pré-processamento para mitigar tais distorções.

De modo geral, os modelos desenvolvidos apresentam potencial de aplicação em análises automatizadas da estrutura de agregados de solo, podendo contribuir com atividades laboratoriais, tipificação estrutural e diagnósticos ambientais em áreas agrícolas. Essa abordagem se mostra especialmente promissora para o estudo de solos tropicais.

Vale destacar que os modelos desenvolvidos apresentam potencial de aplicação em análises automatizadas da morfometria de agregados de solo, podendo contribuir para atividades laboratoriais, processos de tipificação da condição do agegação e diagnósticos ambientais em áreas agrícolas.

Dessa maneira, os resultados obtidos apresentam-se como uma contribuição para o avanço das ciências do solo no âmbito da agricultura regenerativa e sustentável.

REFERÊNCIAS

- Aitkenhead, M.; Cameron, C.; Gaskin, G.; Choisy, B.; Coull, M.; Black, H. Digital RGB photography and visible-range spectroscopy for soil composition analysis. *Geoderma*, v. 313, p. 265–275, 2018. <https://doi.org/10.1016/j.geoderma.2017.11.020>.
- Akkem, Y.; Biswas, S. K.; Varanasi, A. Smart farming using artificial intelligence: A review. *Engineering Applications of Artificial Intelligence*, [S.l.], v. 120, p. 105899, 2023. <https://doi.org/10.1016/j.engappai.2023.105899>.
- Albahar, M. “A Survey on Deep Learning and Its Impact on Agriculture: Challenges and Opportunities.” *Agriculture*, vol. 13, no. 3, 23 Feb. 2023, p. 540, <https://doi.org/10.3390/agriculture13030540>.
- Alibabaei, K., Gaspar, P. D., Lima, T. M. “Modeling Soil Water Content and Reference Evapotranspiration from Climate Data Using Deep Learning Method.” *Applied Sciences*, vol. 11, no. 11, 29 May 2021, p. 5029, <https://doi.org/10.3390/app11115029>.
- Alirezazadeh, P., Rahimi-Ajdadi, F., Abbaspour-Gilandeh, Y., Landwehr, N., Tavakoli, H. “Improved Digital Image-Based Assessment of Soil Aggregate Size by Applying Convolutional Neural Networks.” *Computers and Electronics in Agriculture*, vol. 191, Dec. 2021, p. 106499, <https://doi.org/10.1016/j.compag.2021.106499>.
- Amri, E., Gulzar, Y., Yeafi, A., Jendoubi, S., Dhawi, F., Mir, M. S. “Advancing Automatic Plant Classification System in Saudi Arabia: Introducing a Novel Dataset and Ensemble Deep Learning Approach.” *Modeling Earth Systems and Environment*, vol. 10, no. 2, 9 Jan. 2024, pp. 2693–2709, <https://doi.org/10.1007/s40808-023-01918-9>.
- Attri, I., Awasthi, L. K., Sharma, T. P., R. P. “A Review of Deep Learning Techniques Used in Agriculture.” *Ecological Informatics*, vol. 77, 1 Nov. 2023, pp. 102217–102217, <https://doi.org/10.1016/j.ecoinf.2023.102217>.
- Azadnia, R., Jahanbakhshi, A., Rashidi, S., Khajehzadeh, M., Bazyar, P. “Developing an Automated Monitoring System for Fast and Accurate Prediction of Soil Texture Using an Image-Based Deep Learning Network and Machine Vision System.” *Measurement*, vol. 190, Feb. 2022, p. 110669, <https://doi.org/10.1016/j.measurement.2021.110669>.
- Azizi, A., Gilandeh, Y. A., Mesri-Gundoshmian, T., Saleh-Bigdeli, A. A., Moghaddam, H. A. “Semantic Segmentation: A Modern Approach for Identifying Soil Clods in Precision Farming.” *Biosystems Engineering*, vol. 196, 1 Aug. 2020a, pp. 172–182, <https://doi.org/10.1016/j.biosystemseng.2020.05.022>.
- Azizi, A., Abbaspour-Gilandeh, Y., Vannier, E., Dusséaux, R., Mseri-Gundoshmian, T., & Moghaddam, H. A. “Classification of Soil Aggregates: A Novel Approach Based on Deep Learning.” *Soil and Tillage Research*, vol. 199, May 2020b, p. 104586, <https://doi.org/10.1016/j.still.2020.104586>. Accessed 16 June 2022.

Baretta, D.; Santos, J. C. P.; Segat, J. C.; Geremia, E. V.; Oliveira Filho, L. C. I.; Alves, M. V.. Fauna edáfica e qualidade do solo. *Tópicos em Ciência do Solo*, Viçosa: Sociedade Brasileira de Ciência do Solo, v. 7, p. 119–170, 2011.

Bardgett, R. D.; Van Der Putten, W. H. *Belowground biodiversity and ecosystem functioning*. *Nature*, v. 515, p. 505–511, 2014. DOI: 10.1038/nature13855.

Bartholomeu, D. B.; Oliveira, M. S.; Vieira, C. A. O.; Dantas, J. A. R.; Cruz, T. C. S.; Fonseca, E. F. B. Da; Oliveira, F. C.; Martins, P. R. S. Desempenho de índices de vegetação obtidos por sensores orbitais no monitoramento de colheitas mecanizadas de cana-de-açúcar. *Revista Brasileira de Engenharia Agrícola e Ambiental*, v. 27, n. 3, p. 192–198, 2023. <https://doi.org/10.1590/1807-1929/agriambi.v27n3p192-198>.

Bartz, M. L. C.; Pasini, A.; Brown, G. G. Earthworms as soil quality indicators in Brazilian no-tillage systems. **Applied Soil Ecology**, [S.L.], v. 69, n. 1, p. 39-48, jul. 2013. Elsevier BV. <http://dx.doi.org/10.1016/j.apsoil.2013.01.011>.

Benameur, R., Dahane, A., Kechar, B., Benyamina, A. H. “An Innovative Smart and Sustainable Low-Cost Irrigation System for Anomaly Detection Using Deep Learning.” *Sensors*, vol. 24, no. 4, 1 Jan. 2024, p. 1162, <https://doi.org/10.3390/s24041162>

Ben-Dor, E.; Inbar, Y.; Chen, Y. Near-infrared analysis as a rapid method to simultaneously evaluate several soil properties. *Soil Science Society of America Journal*, v. 59, n. 2, p. 364–372, 1995. DOI: <https://doi.org/10.2136/sssaj1995.03615995005900020011x>.

Berry, J.K.; Delgado, J.A.; Khosla, R.; Pierce, F.J. Precision conservation for environmental sustainability. *Journal of Soil and Water Conservation*, v. 58, n. 6, 2003, p. 332.

Bodner, G.; Nakhforoosh, A.; Arnold, T.; Leitner, D. *Hyperspectral imaging: a novel approach for plant root phenotyping*. *Plant Methods*, v. 14, n. 84, p. 1–17, 2018. Disponível em: <https://doi.org/10.1186/s13007-018-0352-1>.

Bolfe, E. L., Jorge, L. A. C. J., Sanches, I. D. A., Júnior, A. L. J., Costa, C. C., Victoria, D. C., Inamasu, R. Y., Grego, C. R., Ferreira, V. R., Ramirez, A. R. “Precision and Digital Agriculture: Adoption of Technologies and Perception of Brazilian Farmers.” *Agriculture*, vol. 10, no. 12, 21 Dec. 2020, p. 653, <https://doi.org/10.3390/agriculture10120653>.

Bolfe, E., Massruhá, S. A transformação digital e a sustentabilidade agrícola. *Agroanalysis*, v. 40, p. 32-34, mar. 2020

Bossuyt, H.; Six, J.; Hendrix, P. F. Interactive effects of functionally different earthworm species on aggregation and incorporation and decomposition of newly added residue carbon. *Geoderma*, v. 130, p. 14–25, 2006. DOI: 10.1016/j.geoderma.2005.01.005

Brady, N.C; Weil, R.R. Elementos da Natureza e Propriedades dos Solos. 3ª ed. Tradução técnica: Igo Fernando Lepsch. Editora Bookman, Porto Alegre, RS, 2013. 685 p.

Bronick, C.J.; Lal, R.. Soil structure and management: a review. *Geoderma*, [S.L.], v. 124, n. 1-2, p. 3-22, jan. 2005. Elsevier BV.
<http://dx.doi.org/10.1016/j.geoderma.2004.03.005>.

Caputo, H. P. *Mecânica dos solos e suas aplicações*. Rio de Janeiro, 1923.

Carvalho, M. M. Avaliação do solo de áreas mineradas em recuperação dentro do bioma amazônico por meio da relação entre morfometria de agregados do solo e teor de glomalina. 2021. 108f. Tese (Doutorado em Ciências Ambientais) – Instituto de Ciência e Tecnologia de Sorocaba, UNESP - Universidade Estadual Paulista, Sorocaba, 2021.

Castro Filho, C.; Muzilli, O.; Podanoschi, A. L. Estabilidade dos agregados e sua relação com o teor de carbono orgânico num Latossolo roxo distrófico, em função de sistemas de plantio, rotações de culturas e métodos de preparo das amostras. *Revista Brasileira de Ciência do Solo*, Viçosa, MG, v. 22, n. 3, p. 527–538, 1998.

Cisek, Paul. *Evolution of behavioural control from chordates to primates*. Philosophical Transactions of the Royal Society B: Biological Sciences, v. 377, n. 1844, p. 20200522, 2021. <https://doi.org/10.1098/rstb.2020.0522>.

Chandraprabha, M., Dhanraj, R. K. “Ensemble Deep Learning Algorithm for Forecasting of Rice Crop Yield Based on Soil Nutrition Levels.” *ICST Transactions on Scalable Information Systems*, 4 May 2023, pp. e7–e7,
<https://doi.org/10.4108/eetsis.v10i3.2610>.

Chaves, J. V. B.; Rosas, C. L. G.; Ferraz, C. P. A.; Aiello, L. H. F.; Peche-Filho, A.; Mota, L. T. M.; Longo, R. M.; Ribeiro, A. Í. Soil conservation and information technologies: A literature review. *Smart Agricultural Technology*, v. 11, p. 100935, 2025. <https://doi.org/10.1016/j.atech.2025.100935>.

Chen, J., Yang, A. Intelligent Agriculture, and Its Key Technologies Based on Internet of Things Architecture. Ieee Access: Practical Innovations, Open Solutions, 7, 77134–77141. 2019.

Cohen, J. A coefficient of agreement for nominal scales. *Educational and Psychological Measurement*, 20, 37–46.
1960. <https://doi.org/10.1177/001316446002000104>

Custódio, G., Prati, R. C. “Comparing Modern and Traditional Modeling Methods for Predicting Soil Moisture in IoT-Based Irrigation Systems.” *Smart Agricultural Technology*, vol. 7, 1 Mar. 2024, p. 100397,
<https://doi.org/10.1016/j.atech.2024.100397>.

Dahane, A., Benameur, R., Kechar, B. “An IoT Low-Cost Smart Farming for Enhancing Irrigation Efficiency of Smallholders Farmers.” *Wireless Personal Communications*, 11 Aug. 2022, <https://doi.org/10.1007/s11277-022-09915-4>.

Dhanya, V.G., Subeesh, A., Kushwaha, N.L., Vishwakarma, D. K., Kumar, T. N., Ritika, G., Singh, A.N. "Deep Learning Based Computer Vision Approaches for Smart Agricultural Applications." *Artificial Intelligence in Agriculture*, vol. 6, Sept. 2022, <https://doi.org/10.1016/j.aiia.2022.09.007>.

Delgado, J. A.; Berry, J. K. Advances in Precision Conservation. *Advances in Agronomy*, v. 98, n. 8, p. 1-44, 2008.

Devine, D.; Markewitz, P.; Hendrix, D.; Coleman, D.; 2014. Soil aggregates and associated organic matter under conventional tillage, no-tillage, and forest succession after three decades. *PLoS One*, 9, p.84988.

Dong, W., Wu, T., Sun, Y., Luo, J. "Digital Mapping of Soil Available Phosphorus Supported by AI Technology for Precision Agriculture." *IEEE Xplore*, 1 Aug. 2018, [dx.doi.org/10.1109/Agro-Geoinformatics.2018.8476007](https://doi.org/10.1109/Agro-Geoinformatics.2018.8476007).

Van Dusschoten, D.; Metzner, Ralf; Kochs, Johannes; Postma, Johannes A.; Pflugfelder, Daniel; Bühler, Jonas; Schurr, Ulrich; Jahnke, Siegfried. Quantitative 3D analysis of plant roots growing in soil using magnetic resonance imaging. *Plant Physiology*, Rockville, v. 170, n. 3, p. 1176–1188, 2016. DOI: 10.1104/pp.15.01388.

Dugan, I; Pereira, P.; Barcelo, D.; Bogunovic, I. Conservation practices reverse soil degradation in Mediterranean fig orchards. *Geoderma Regional*, v. 36, e00750, 2024. <https://doi.org/10.1016/j.geodrs.2023.e00750>.

Dyson, J.; Mancini, A.; Frontoni, E.; Zingaretti, P. Deep learning for soil and crop segmentation from remotely sensed data. *Remote Sensing*, v. 11, n. 16, p. 1859, 2019. <https://doi.org/10.3390/rs11161859>.

El Behairy, R. A.; El Arwash, H. M.; El Baroudy, A. A.; Ibrahim, M. M.; Mohamed, E. S.; Kucher, D. E.; Shokr, M. S. How can soil quality be accurately and quickly studied? A review. *Agronomy*, Basel, v. 14, art. 1682, p. 1–22, 2024. <https://doi.org/10.3390/agronomy14081682>.

Erktan, A.; Or, D.; Scheu, S. The physical structure of soil: determinant and consequence of trophic interactions. *Soil Biology and Biochemistry*, [S. l.], v. 148, p. 107876, 2020. <https://doi.org/10.1016/j.soilbio.2020.107876>.

Filippova, O. I.; Kholodov, V. A.; Safronova, N. A.; Yudina, A. V.; Kulikova, N. A. Particle-Size, Microaggregate-Size, and Aggregate-Size Distributions in Humus Horizons of the Zonal Sequence of Soils in European Russia. **Eurasian Soil Science**, [S.L.], v. 52, n. 3, p. 300-312, mar. 2019. Pleiades Publishing Ltd. <http://dx.doi.org/10.1134/s1064229319030037>.

Food and Agriculture Organization of the United Nations (FAO). "*Climate-smart agriculture: policies, practices and financing for food security, adaptation and mitigation*". Rome: FAO, 2010. Food Security and Climate Change, 31 de out. 2010.

Food and Agriculture Organization of the United Nations (FAO). *Status of the World's Soil Resources: Main Report*. Rome: FAO, 2015.

Food and Agriculture Organization of the United Nations (FAO). *Making Agrifood Systems More Resilient to Shocks and Stresses*. Rome: FAO, The State of Food and Agriculture (SOFA), 2021. DOI: <https://doi.org/10.4060/cb4476en>.

Freire, O. *Solos das regiões tropicais*. Botucatu: FEPAF, 2006. 271 p.

Gabor, D. Theory of communication. *Journal of the Institution of Electrical Engineers*, v. 93, n. 26, p. 429–457, 1946.

Géron, A. *Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow: concepts, tools, and techniques to build intelligent systems*. 2. ed. Sebastopol: O'Reilly Media, 2021

Gonzalez, R. C.; Woods, R. E. *Digital Image Processing*. 3rd ed. Upper Saddle River: Pearson Prentice Hall, 2008.

Goodfellow, I.; Bengio, Y.; Courville, A. *Deep learning*. Cambridge: MIT Press, 2016.

Habeeb, H. N., Mustafa, Y. T. “Deep Learning Approaches for Estimating Forest Vegetation Cover and Exploring Influential Ecosystem Factors.” *Earth Science Informatics*, vol. 17, no. 4, 7 June 2024, pp. 3379–3396, <https://doi.org/10.1007/s12145-024-01346-y>.

Habiboullah, A., Mohamed A. L. “Soil Moisture Prediction Using NDVI and NSMI Satellite Data: ViT-Based Models and ConvLSTM-Based Model.” *SN Computer Science*, vol. 4, no. 2, 4 Jan. 2023, <https://doi.org/10.1007/s42979-022-01554-7>.

Han, C.; Zhou, W.; Gu, Y.; Wang, J.; Zhou, Y.; Xue, Y.; Shi, Z.; Siddique, K. H. M. Effects of tillage regime on soil aggregate-associated carbon, enzyme activity, and microbial community structure in a semiarid agroecosystem. *Plant and Soil*, v. 498, p. 543–559, 2024. <https://doi.org/10.1007/s11104-023-06453-1>.

Han, Q., Zhao, Y., Zhao, Y., Liu, K., Pang, M. Soil pore segmentation of computed tomography images based on fully convolutional network. *Nongye Gongcheng Xuebao/Transactions of the Chinese Society of Agricultural Engineering*, 35, 128-133, 2019. <https://doi.org/10.11975/j.issn.1002-6819.2019.02.017>.

Hamrani, A., Akbarzadeh, A., Madramootoo, C. A. “Machine Learning for Predicting Greenhouse Gas Emissions from Agricultural Soils.” *Science of the Total Environment*, vol. 741, Nov. 2020, p. 140338, <https://doi.org/10.1016/j.scitotenv.2020.140338>.

Hernani, L. C. *Agregação do solo*. Portal Embrapa Solos, 2021. Disponível em: <https://www.embrapa.br/agencia-de-informacao-tecnologica/tematicas/sistema-plantio-direto/fundamentos/beneficios/ao-solo/fisica-do-solo/agregacao-do-solo>. Acesso em: 15 nov. 2024.

Hénin, S.; Gras, R.; Monnier, G. Os solos agrícolas. São Paulo, Ed. Univ. de São Paulo, 1976.

Helliwell, J. R.; Miller, A. J.; Whalley, W. R.; Mooney, S. J.; Sturrock, C. J. Quantifying the impact of microbes on soil structural development and behaviour in

wet soils. *Soil Biology & Biochemistry*, v. 74, p. 138–147, 2014.
<https://doi.org/10.1016/j.soilbio.2014.03.009>.

Horn, R.; Dexter, A. R. Dynamics of soil aggregation in an irrigated desert loess. *Soil & Tillage Research*, v. 13, p. 253–266, 1989. [https://doi.org/10.1016/0167-1987\(89\)90002-0](https://doi.org/10.1016/0167-1987(89)90002-0).

Intergovernmental Panel on Climate Change (IPCC). “Climate Change 2022: Impacts, Adaptation and Vulnerability Working Group II Contribution to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change.” *IPCC*, vol. 1, no. 1, 2022, <https://doi.org/10.1017/9781009325844>.

Isensee, F.; Jaeger, Paul F.; Kohl, S. A. A.; Petersen, J.; Maier-Hein, K. H. nnU-Net: a self-configuring method for deep learning-based biomedical image segmentation. *Nature Methods*, v. 18, p. 203–211, fev. 2021. DOI: 10.1038/s41592-020-01008-z.

Jain, A. K.; Farrokhnia, F. Unsupervised texture segmentation using Gabor filters. *Pattern Recognition*, Oxford, v. 24, n. 12, p. 1167–1186, 1991.
[https://doi.org/10.1016/0031-3203\(91\)90143-S](https://doi.org/10.1016/0031-3203(91)90143-S).

Jain, S.; Sethia, D.; Tiwari, K. C. *A critical systematic review on spectral-based soil nutrient prediction using machine learning*. Environmental Monitoring and Assessment, v. 196, n. 699, 2024. Disponível em: <https://doi.org/10.1007/s10661-024-12817-6>.

Jastrow, J. D.; Miller, R. M.; Lal, R. Aggregate stabilization and carbon sequestration in the soil. *Soil Science Society of America Journal*, v. 60, n. 2, p. 425–430, 1996.
 DOI: 10.2136/sssaj1996.03615995006000020015x.

Jensen, J. L.; Schjøning, P.; Watts, C. W.; Christensen, B. T.; Obour, P. B.; Munkholm, L. J. Soil degradation and recovery – Changes in organic matter fractions and structural stability. **Geoderma**, [S.L.], v. 364, n. 1, p. 114181, abr. 2020. Elsevier BV. <http://dx.doi.org/10.1016/j.geoderma.2020.114181>.

Jordan, M. I.; Mitchell, T. M. Machine learning: trends, perspectives, and prospects. *Science*, [S. I.], v. 349, n. 6245, p. 255–260, 2015. DOI: 10.1126/science.aaa8415.

Kamarudin, M. H., Ismail, Z. H.; Saidi, N. B. “Deep Learning Sensor Fusion in Plant Water Stress Assessment: A Comprehensive Review.” *Applied Sciences*, vol. 11, no. 4, 4 Feb. 2021, p. 1403, <https://doi.org/10.3390/app11041403>.

Kamagate, B. H.; Kopoin, N. C.; Koffi, D. D. A.; Asseu, O. P. A Robust Convolutional Neural Network Model for Fruit Image Classification. *Ingenierie des Systemes d'Information*, v.29, n. 5, p. 1701 – 1710, 2024.

Kamilaris, A.; Prenafeta-Boldú, F. X. Deep learning in agriculture: A survey. *Computers and Electronics in Agriculture*, v. 147, p. 70–90, 2018.
<https://doi.org/10.1016/j.compag.2018.02.016>.

Kaur, A., Bhatt, D. P., Raja, L. “Developing a Hybrid Irrigation System for Smart Agriculture Using IoT Sensors and Machine Learning in Sri Ganganagar, Rajasthan.”

Journal of Sensors (Print), vol. 2024, 29 Jan. 2024, pp. 1–15,
<https://doi.org/10.1155/2024/6676907>.

Kazemi Garajeh, M., Salmani, B., Zare Naghadehi, S., Valipoori Goodarzi, H., & Khasraei, A. “An Integrated Approach of Remote Sensing and Geospatial Analysis for Modeling and Predicting the Impacts of Climate Change on Food Security.” *Scientific Reports*, vol. 13, no. 1, 19 Jan. 2023, p. 1057,
<https://doi.org/10.1038/s41598-023-28244-5>.

Kemper, W. D.; Rosenau, R. C. Aggregate stability and size distribution. In: KLUTE, A. (ed.). *Methods of soil analysis. Part 1: Physical and mineralogical methods*. 2. ed. Madison: American Society of Agronomy; Soil Science Society of America, 1986. p. 425–442.

Kerp, H.; Bomfleur, B. Photography of plant fossils—New techniques, old tricks. *Review of Palaeobotany and Palynology*, v. 166, p. 117–151, 2011.
<https://doi.org/10.1016/j.revpalbo.2011.05.001>.

Kiran-Pandiri, D.N. K., Murugan, R., Goel, T. “Smart Soil Image Classification System Using Lightweight Convolutional Neural Network.” *Expert Systems with Applications*, vol. 238, 15 Mar. 2024, p. 122185, <https://doi.org/10.1016/j.eswa.2023.122185>.

Kosamkar, P. K.; Kulkarni, V. Y. “Effect of Soil and Climatic Attribute on Greenhouse Gas Emission from Agriculture Sector.” *Evolution in Computational Intelligence*, 9 Sept. 2020, pp. 91–101, https://doi.org/10.1007/978-981-15-5788-0_9.

Lal, R. Restoring Soil Quality to Mitigate Soil Degradation. *Sustainability*, [S.L.], v. 7, n. 5, p. 5875–5895, 13 maio 2015. MDPI AG. <http://dx.doi.org/10.3390/su7055875>.

Landis, J. R.; Koch, G. G. The measurement of observer agreement for categorical data. *Biometrics*, v. 33, n. 1, p. 159–174, 1977. <http://dx.doi.org/10.2307/2529310>.

Lecun, Y.; Bengio, Y.; Hinton, G. Deep learning. *Nature*, v. 521, n. 7553, p. 436–444, 2015. <http://dx.doi.org/10.1038/nature14539>.

Lee, Dong-Ho; Park, Jong-Hwa. Development of a UAS-based multi-sensor deep learning model for predicting Napa cabbage fresh weight and determining optimal harvest time. *Remote Sensing*, v. 16, n. 18, p. 3455, 2024.
<http://dx.doi.org/https://doi.org/10.3390/rs16183455>.

Li, G.; Yu, C.; Shen, P.; Hou, Y.; Ren, Z.; Li, N.; Liao, Y.; Li, T.; Wen, X. Crop diversification promotes soil aggregation and carbon accumulation in global agroecosystems: A meta-analysis. *Journal of Environmental Management*, [S.I.], v. 350, p. 119661, 2024. <https://doi.org/10.1016/j.jenvman.2023.119661>.

Li, J. Y. Q.; Duce, S.; Joyce, K. E.; Xiang, W. SeeCucumbers: using deep learning and drone imagery to detect sea cucumbers on coral reef flats. *Drones*, v. 5, n. 2, p. 28, 2021. <https://doi.org/10.3390/drones5020028>.

Li, X.; Mao, N.; Jiang, H.; Jiang, X.; Li, C.; Gong, X.; Liu, T.; Cheng, J. Synergistic effects of straw and earthworm addition on microbial diversity and microbial nutrient limitation in a subtropical conservation farming system. *Soil And Tillage Research*,

[S.L.], v. 224, p. 105500-1, out. 2022. Elsevier BV.
<http://dx.doi.org/10.1016/j.still.2022.105500>

Li, Y.; Hua, X.; Zheng, F.; Dong, D.; Liang, D.; Guo, Z. Effects of tubificid bioturbation on pore structures in sediment and the migration of sediment particles. *Environmental Science and Pollution Research*, v. 23, n. 8, p. 8064–8075, 2016. DOI: <https://doi.org/10.1007/s11356-015-5949-6>.

Ma, L.; Zhao, L.; Cao, L.; Li, D.; Chen, G.; Han, Y. Inversion of soil organic matter content based on improved convolutional neural network. *Sensors*, Basel, v. 22, n. 20, p. 7777, 2022. <https://doi.org/10.3390/s22207777>.

Manikandan, R., Ranganathan, G., Bindhu, V. “Deep Learning Based IoT Module for Smart Farming in Different Environmental Conditions.” *Wireless Personal Communications*, 22 Nov. 2022, <https://doi.org/10.1007/s11277-022-10016-5>.

Márquez, C. O.; García, V. J.; Cambardella, C. A.; Schultz, R. C.; Isenhardt, T. M. Aggregate-size stability distribution and soil stability. *Soil Science Society of America Journal*, v. 68, n. 3, p. 725–735, 2004. <https://doi.org/10.2136/sssaj2004.7250>.

Martínez, F. S. J., Ortega, F. J. M., Monreal, F. J. C., Kravchenko, A. N., Wang, W. “Soil Aggregate Geometry: Measurements and Morphology.” *Geoderma*, vol. 237-238, 1 Jan. 2015, Pp. 36–48, <https://doi.org/10.1016/j.geoderma.2014.08.003>.

Massruhá, S. M. F. S., Leite, M. A. A, Junior, A. L., Evangelista, S. R. M. Transformação Digital No Campo Rumo À Agricultura Sustentável E Inteligente, in: MASSRUHÁ, S. M. F. S. Agricultura Digital: Pesquisa, Desenvolvimento E Inovação Nas Cadeias Produtivas. Brasília: Embrapa, 2020. P. 20-45.

McCulloch, W. S.; Pitts, W. A logical calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics*, v. 5, p. 115–133, 1943. DOI: <https://doi.org/10.1007/BF02478259>

Mesquita, M. G. B. E.; Dias Junior, M. S.; 2013. Física do solo. In: O ecossistema solo – componentes relações ecológicas e efeitos na produção vegetal. Lavras: Ed. UFLA, 2013, p.352.

Mikha, M. M.; Green, T. R.; Untiedt, T. J.; Hergret, G. W. Land management affects soil structural stability: Multi-index principal component analyses of treatment interactions. *Soil & Tillage Research*, v. 235, p. 105890, 2024. <https://doi.org/10.1016/j.still.2023.105890>.

Mohamed, E. S., Belal, A., Abd-Elmabod, S. K., El-Shirbeny, M., Gad, A., Zahran, M. B. “Smart Farming for Improving Agricultural Management.” *The Egyptian Journal of Remote Sensing and Space Science*, vol. 24, no. 3, 6 Sept. 2021, pp. 971–981, <https://doi.org/10.1016/j.ejrs.2021.08.007>.

Munaganuri, R. K., Rao, Y. N. “PAMICRM: Improving Precision Agriculture through Multimodal Image Analysis for Crop Water Requirement Estimation Using Multidomain Remote Sensing Data Samples.” *IEEE Access*, 1 Jan. 2024, pp. 1–1, <https://doi.org/10.1109/access.2024.3386552>.

Nações Unidas. *Agenda 2030 para o Desenvolvimento Sustentável. Brasília: Nações Unidas no Brasil*, 2020. Disponível em: <https://brasil.un.org/sites/default/files/2020-09/agenda2030-pt-br.pdf>. Acesso em: 3 jan, 2024.

Nalwanga, R., Nsenga, J., Rushingabigwi, G., Gatare, I. *Design of an Embedded Machine Learning Based System for an Environmental-Friendly Crop Prediction Using a Sustainable Soil Fertility Management*. 23 Nov. 2021, <https://doi.org/10.1109/scored53546.2021.9652766>.

Novara, A., Papa, G. L., Dazzi, C., Gristina, L., Cerdà, A., 2014. Soil aggregates, organic matter turnover and carbon balance in a Mediterranean eroded vineyard. In: EGU General Assembly Conference Abstracts.1059p.

Novara, A.; Pisciotto, A.; Minacapilli, M.; Maltese, A.; Capodici, F.; Cerdà, A.; Gristina, L. The impact of soil erosion on soil fertility and vine vigor: a multidisciplinary approach based on field, laboratory and remote sensing approaches. *Science of the Total Environment*, v. 622–623, p. 474–480, 2018. 10.1016/j.scitotenv.2017.11.272.

Padhee, S. K., Nikam, B.R.; Dutta, S., Aggarwal, S. P. “Using Satellite-Based Soil Moisture to Detect and Monitor Spatiotemporal Traces of Agricultural Drought over Bundelkhand Region of India.” *GIScience & Remote Sensing*, vol. 54, no. 2, 9 Feb. 2017, pp. 144–166, <https://doi.org/10.1080/15481603.2017.1286725>.

Padmavathi, B.; Bhagyalakshmi, A.; Vishnupriya, G.; Datchanamoorthy, K. IoT-based prediction and classification framework for smart farming using adaptive multi-scale deep networks. *Expert Systems with Applications*, v. 254, p. 124318, 2024. <https://doi.org/10.1016/j.eswa.2024.124318>.

Page, A. L.; Miller, R. H.; Keeney, D. R. *Methods of soil analysis: part 1: physical and mineralogical methods*. 2th ed. Madison: ASA, 1986. 1188 p.

Patrizi, G., Bartolini, A., Ciani, L., Gallo, V., Sommella, P., Carratu, M. *A Virtual Soil Moisture Sensor for Smart Farming Using Deep Learning*. Vol. 71, 1 Jan. 2022, pp. 1–11, <https://doi.org/10.1109/tim.2022.3196446>.

Peche-Filho, A. Variability of aggregation as quality indicator in agricultural soils: a methodological proposal. 2018. 87 f. Thesis (PhD in Environmental Sciences) - Experimental Campus of Sorocaba, UNESP - Univ Estadual Paulista, Sorocaba, 2018.

Pedrin, H.; Schwartz, W. R. *Análise de imagens digitais: Princípios, Algoritmos e aplicações*. 2nd ed. Cengage, 2008.

Pereira, M. G.; Anjos, L. H. C.; Pinheiro Junior, C. R.; Pinto, L. A. S. R.; Silva Neto, E. C.; Fontana, A. Formação e caracterização de solos. In: PEREIRA, M. G. et al. *Formação, classificação e cartografia dos solos*. Seropédica, RJ: Universidade Federal Rural do Rio de Janeiro, 2019. Cap. 1, p. 1–20.

Phalempin, M.; Lippold, E.; Vetterlein, D.; Schlüter, S. An improved method for the segmentation of roots from X-ray computed tomography 3D images: Routine v.2. *Plant Methods*, [S.l.], v. 17, n. 39, p. 1–19, 2021. <https://doi.org/10.1186/s13007-021-00735-4>.

- Piron, D.; Pérès, G.; Hallaire, V.; Cluzeau, D. Morphological description of soil structure patterns produced by earthworm bioturbation at the profile scale. *European Journal of Soil Biology*, v. 50, p. 83–90, 2012. DOI: 10.1016/j.ejsobi.2011.12.006.
- Powers, D. M. W. Evaluation: From Precision, Recall and F-measure to ROC, Informedness, Markedness and Correlation. *Journal of Machine Learning Technologies*, v. 2, n. 1, p. 37–63, 2011.
- Prakash, S., Srivastava, S. “Impact of Climate Change on Biodiversity: An Overview.” *International Journal of Biological Innovations*, vol. 01, no. 02, 2019, pp. 60–65, <https://doi.org/10.46505/ijbi.2019.1205>.
- Preskill, J. Quantum computing in the NISQ era and beyond. *Quantum*, v.2, n. 79, 2018. <https://doi.org/10.22331/q-2018-08-06-79>.
- Pruvost, E., Tulet, H., Delort, E., Shokouh, G. S., Montesinos, P., Magnier, B., Christophe, Jourdan, Emma, Belaud, Mickael, Hedde. *Invertebrates Detection with YOLOv5: Towards Study of Soil Organisms Using Deep Learning*. 1 Sept. 2022, [dx.doi.org/10.1109/euip53989.2022.9922675](https://doi.org/10.1109/euip53989.2022.9922675).
- Raju, C.; Ashoka, D. V.; Vijaya, A. P. B. HybridTransferNet: soil image classification through comprehensive evaluation for crop suggestion. *International Journal of Artificial Intelligence (IJ-AI)*, Yogyakarta, v. 13, n. 2, p. 1702–1710, 2024. <https://doi.org/10.11591/ijai.v13.i2.pp1702-1710>.
- Rashid, B., Rehmani, M. H. “Applications of Wireless Sensor Networks for Urban Areas: A Survey.” *Journal of Network and Computer Applications*, vol. 60, Jan. 2016, pp. 192–219, <https://doi.org/10.1016/j.jnca.2015.09.008>.
- Ren, J., Liang, J., Zhao, Y. “Soil PH Measurement Based on Compressive Sensing and Deep Image Prior.” *IEEE Transactions on Emerging Topics in Computational Intelligence*, vol. 4, no. 1, 24 Jan. 2020, pp. 74–82, <https://doi.org/10.1109/tetci.2019.2902426>.
- Ribeiro, A. I.; Peche-Filho, A.; Rosas, C. L. G.; Albiero, D.; Fengler, F. H.; Medeiros, G. A.; Diniz, I. S.; Carvalho, M. M.; Longo, R. M. Precision conservation: from visual analysis of soil aggregates to the use of neural networks. *Revista Ciência Agronômica*, [S.L.], v. 51, n. 5, jan. 2020. DOI: <http://dx.doi.org/10.5935/1806-6690.20200101>
- Ronneberger, O.; Fischer, P.; Brox, T. U-Net: Convolutional networks for biomedical image segmentation. In: NAVAB, Nassir et al. (ed.). *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015*. Cham: Springer, 2015. v. 9351, p. 234–241. DOI: 10.1007/978-3-319-24574-4_28.
- Rose, D. C., Sutherland, W. J., Parker, C., Lobley, M., Winter, M., Morris, C., Twining, S., Ffoulkes, C., Amano, T., Dicks, L. V. “Decision Support Tools for Agriculture: Towards Effective Design and Delivery.” *Agricultural Systems*, vol. 149, 1 Nov. 2016, pp. 165–174, <https://doi.org/10.1016/j.agsy.2016.09.009>.
- Russ, J. C.; Neal, F. B. *The Image Processing Handbook*. 7. ed. Boca Raton: CRC Press, 2016.

Quintão, J. M. B., Cantinho, R. Z., Albuquerque, E. R. G. M., Maracahipes, L., Bustamante, M. M. C. “Mudanças Do Uso E Cobertura Da Terra No Brasil, Emissões de GEE E Políticas Em Curso.” *Ciência E Cultura*, vol. 73, no. 1, 1 Jan. 2021, pp. 18–24, <https://doi.org/10.21800/2317-66602021000100004>.

Rabot, E.; Wiesmeier, M.; Schlüter, S.; Vogel, H. J. Soil structure as an indicator of soil functions: A review. *Geoderma*, v. 314, p. 122–137, 2018. <https://doi.org/10.1016/j.geoderma.2017.11.009>.

Ruigrok, T.; Van Henten, E. J.; Kootstra, G. Improved generalization of a plant-detection model for precision weed control. *Computers And Electronics In Agriculture*, [S.L.], v. 204, p. 107554, jan. 2023. Elsevier BV. <http://dx.doi.org/10.1016/j.compag.2022.107554>.

Ruiz-Muñoz, J. F.; Nimmagadda, J. K.; Dowd, T. G.; Baciak, J. E.; Zare, A. Super resolution for root imaging. *Applications In Plant Sciences*, [S.L.], v. 8, n. 7, p. 1-1, jul. 2020. Wiley. <http://dx.doi.org/10.1002/aps3.11374>.

Rukhovich, D. I., Koroleva, P. V., Rukhovich, D. D., Kalinina, N. V. “The Use of Deep Machine Learning for the Automated Selection of Remote Sensing Data for the Determination of Areas of Arable Land Degradation Processes Distribution.” *Remote Sensing*, vol. 13, no. 1, 5 Jan. 2021, p. 155, <https://doi.org/10.3390/rs13010155>.

Samarin, M., Zweifel, L., Roth, V., Alewell, C. “Identifying Soil Erosion Processes in Alpine Grasslands on Aerial Imagery with a U-Net Convolutional Neural Network.” *Remote Sensing*, vol. 12, no. 24, 18 Dec. 2020, p. 4149, <https://doi.org/10.3390/rs12244149>.

Sami, M.; Khan, S. Q.; Khurram, M.; Farooq, M. U.; Anjum, R.; Aziz, S.; Qureshi, R.; Sadak, F. A Deep Learning-Based Sensor Modeling for Smart Irrigation System. *Agronomy*, [S.L.], v. 12, n. 1, p. 212, 16 Jan. 2022. MDPI AG. <http://dx.doi.org/10.3390/agronomy12010212>.

Sampat, A. G. Física de Suelos: Principios y Aplicaciones. Editorial Liminusa, México, 2ª ed. 1976.

Samuel, A. L. Some studies in machine learning using the game of checkers. *IBM Journal of Research and Development*, v. 3, n. 3, p. 210–229, 1959. DOI: 10.1147/rd.33.0210.

Selvanarayanan, R., Rajendran, S., Algburi, S., Khalaf, O. I., Hamam, H. “Empowering Coffee Farming Using Counterfactual Recommendation Based RNN Driven IoT Integrated Soil Quality Command System.” *Scientific Reports*, vol. 14, no. 1, 15 Mar. 2024, p. 6269, <https://doi.org/10.1038/s41598-024-56954-x>.

Sharma, P., Dadheech, P. “Modern-Age Agriculture with Artificial Intelligence: A Review Emphasizing Crop Yield Prediction.” *Evergreen*, vol. 10, no. 4, 1 Dec. 2023, pp. 2570–2582, <https://doi.org/10.5109/7160906>.

- Singh, S., Jain, P. "Applications of Artificial Intelligence for the Development of Sustainable Agriculture." *Agro-Biodiversity and Agri-Ecosystem Management*, 2022, pp. 303–322, https://doi.org/10.1007/978-981-19-0928-3_16.
- Sirsat, M.S., Cernadas, E., Fernández-Delgado, M., Barro, S. "Automatic Prediction of Village-Wise Soil Fertility for Several Nutrients in India Using a Wide Range of Regression Methods." *Computers and Electronics in Agriculture*, vol. 154, Nov. 2018, pp. 120–133, <https://doi.org/10.1016/j.compag.2018.08.003>.
- Six, J.; Elliott, E. T.; Paustian, K. *Soil structure and soil organic matter: II. A normalized stability index and the effect of mineralogy*. Soil Science Society of America Journal, v. 64, n. 3, p. 1042–1049, 2000
- Six, J; Elliott, E.T; Paustian, K. Soil macroaggregate turnover and microaggregate formation: a mechanism for c sequestration under no-tillage agriculture. *Soil Biology and Biochemistry*, [S.L.], v. 32, n. 14, p. 2099-2103, dez. 2000b. Elsevier BV. [http://dx.doi.org/10.1016/s0038-0717\(00\)00179-6](http://dx.doi.org/10.1016/s0038-0717(00)00179-6).
- Six, J.; Bossuyt, H.; Degryze, S.; Denef, K. A history of research on the link between (micro)aggregates, soil biota, and soil organic matter dynamics. *Soil & Tillage Research*, v. 79, p. 7–31, 2004. DOI: 10.1016/j.still.2004.03.008.
- Six, J.; Frey, S. D.; Thiet, R. K.; Batten, K. M. Bacterial and fungal contributions to carbon sequestration in agroecosystems. *Soil Science Society of America Journal*, v. 70, n. 2, p. 555–569, 2006. <https://doi.org/10.2136/sssaj2004.0347>
- Smith, A. G., Petersen, J., Selvan, R., Rasmussen, C. R. *Segmentation of Roots in Soil with U-Net*. Vol. 16, no. 1, 8 Feb. 2020, <https://doi.org/10.1186/s13007-020-0563-0>.
- Sokolova, M.; Lapalme, G. A systematic analysis of performance measures for classification tasks. *Information Processing & Management*, v. 45, n. 4, p. 427–437, 2009.
- Song, X., Zhang, G., Liu, F., Li, D., Zhao, Y., Yang, J. "Modeling Spatio-Temporal Distribution of Soil Moisture by Deep Learning-Based Cellular Automata Model." *Journal of Arid Land*, vol. 8, no. 5, 4 May 2016, pp. 734–748, <https://doi.org/10.1007/s40333-016-0049-0>.
- Sujatha, M., Jaidhar, C.D. "Machine Learning-Based Approaches to Enhance the Soil Fertility—a Review." *Expert Systems with Applications*, 1 Nov. 2023, pp. 122557–122557, <https://doi.org/10.1016/j.eswa.2023.122557>.
- Sumathi, P., Karthikeyan, V. V., Kavitha, M. S., & Karthik, S. "Improved Soil Quality Prediction Model Using Deep Learning for Smart Agriculture Systems." *Computer Systems Science and Engineering*, vol. 45, no. 2, 2023, pp. 1545–1559, <https://doi.org/10.32604/csse.2023.027580>.
- Sutton, R. S.; Barto, A. G. *Reinforcement learning: an introduction*. 2. ed. Cambridge: MIT Press, 2018.

Teixeira, P. C.; Donagemma, G. K.; Fontana, A.; Teixeira, W. G. Manual de métodos de análise de solo. 3. ed. rev. e ampl. Brasília, DF: Embrapa, 2017. 574 p. ISBN 978-85-7035-771-7.

Teramoto, S.; Uga, Y. Convolutional neural networks combined with conventional filtering to semantically segment plant roots in rapidly scanned X-ray computed tomography volumes with high noise levels. *Plant Methods*, [S.L.], v. 20, n. 1, p. 1-1, 21 maio 2024. Springer Science and Business Media LLC.
<http://dx.doi.org/10.1186/s13007-024-01208-0>.

Tisdall, J. M.; Oades, J. M. Organic matter and water-stable aggregates in soils. *Journal of Soil Science*, 33(2), 141-163. 1982.

Totsche, K. U.; Amelung, W.; Gerzabek, M. H.; Guggenberger, G.; Klumpp, E.; Knief, C.; Lehndorff, E.; Mikutta, R.; Peth, S.; Prechtel, A. Microaggregates in soils. *Journal of Plant Nutrition and Soil Science*, [S.L.], v. 181, n. 1, p. 104-136, 11 ago. 2017. Wiley. <http://dx.doi.org/10.1002/jpln.201600451>.

Trentin, C.; Ampatzidis, Y.; Lacerda, C.; Shiratsuchi, L. *Tree crop yield estimation and prediction using remote sensing and machine learning: A systematic review. Smart Agricultural Technology*, v. 9, p. 100556, 2024.
<https://doi.org/10.1016/j.atech.2024.100556>.

Truber, P. V. Agregação do solo e ocorrência de fungos micorrízicos arbusculares em sistemas de rotação de culturas. 2013. 75 f. Dissertação (Mestrado em Agronomia – Ciência do Solo) – Faculdade de Ciências Agrárias e Veterinárias, Universidade Estadual Paulista “Júlio de Mesquita Filho”, Jaboticabal, 2013.

Turolla, A., Mauro, M., Mezzera, L., Antonelli, M., Carminati, M., “Development of a Miniaturized and Selective Impedance Sensor for Real-Time Slime Monitoring in Pipes and Tanks.” *Sensors and Actuators B Chemical*, vol. 281, 28 Oct. 2018, pp. 288–295, <https://doi.org/10.1016/j.snb.2018.10.107>.

United Nation Convention to Combat Desertification (UNCCD). *Global Land Outlook 2nd Edition: Land Restoration for Recovery and Resilience*. Bonn: UNCCD, 2022.

Vasconcelos, G. J. Q.; Costa, G. S. R.; Spina, T. V.; Pedrini, H. Low-cost robot for agricultural image data acquisition. *Agriculture*, Basel, v. 13, n. 2, p. 413, 2023. DOI: <https://doi.org/10.3390/agriculture13020413>.

Venkataresh, M.; Kullayamma, I. Deep learning based concurrent excited gated recurrent unit for crop recommendation based on soil and climatic conditions. *Multimedia Tools and Applications*, v. 83, p. 64109–64138, 2024.
<https://doi.org/10.1007/s11042-023-18004-y>.

Vos, R., Jackson, J., James, S., Sánchez, M. V. Refugees and Conflict-Affected People: Integrating Displaced Communities into Food Systems, in: VOS, R. 2020, Global Food Policy Report, 46–53.

Wang, X., Corzo, G., Lü, H., Zhou, S., Mao, K., Zhu, Y., Duarte, S., Liu, M., Su, J. “Sub-Seasonal Soil Moisture Anomaly Forecasting Using Combinations of Deep

Learning, Based on the Reanalysis Soil Moisture Records.” *Agricultural Water Management*, vol. 295, 13 Mar. 2024, pp. 108772–108772, <https://doi.org/10.1016/j.agwat.2024.108772>.

Wang, Y., Xie, M., Hu, B., Jiang, Q., Shi, Z., He, Y.; Peng, J. “Desert Soil Salinity Inversion Models Based on Field in Situ Spectroscopy in Southern Xinjiang, China.” *Remote Sensing*, vol. 14, no. 19, 5 Oct. 2022, pp. 4962–4962, <https://doi.org/10.3390/rs14194962>.

Wang, Y., Ma, H., Wang, J., Liu, L., Pietikäinen, M., Zhang, Z., Chen, X. “Hyperspectral Monitor of Soil Chromium Contaminant Based on Deep Learning Network Model in the Eastern Junggar Coalfield.” *Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy*, vol. 257, 1 Aug. 2021, pp. 119739–119739, <https://doi.org/10.1016/j.saa.2021.119739>.

Wang, Z., Oh, S. K., Wang, Z, Fu, Z, Pedrycz, W, Yoon, J H. “Design of Progressive Fuzzy Polynomial Neural Networks through Gated Recurrent Unit Structure and Correlation/Probabilistic Selection Strategies.” *Fuzzy Sets and Systems*, vol. 470, 22 July 2023, pp. 108656–108656, <https://doi.org/10.1016/j.fss.2023.108656>.

Wu, Y., Yang, Z., Liu, Y. “Internet-of-Things-Based Multiple-Sensor Monitoring System for Soil Information Diagnosis Using a Smartphone.” *Micromachines*, vol. 14, no. 7, 8 July 2023, pp. 1395–1395, <https://doi.org/10.3390/mi14071395>.

Yang, Q., Yan, Y., Maize, K., Jin, X., Jiang, H., Alam, M. A., Ziaie, B., Chiu, G. S. A., Allebach, J. P. “Image Based Quality Assurance of Fabricated Nitrate Sensor.” *NIP & Digital Fabrication Conference*, vol. 35, no. 1, 29 Sept. 2019, pp. 138–143, <https://doi.org/10.2352/issn.2169-4451.2019.35.138>.

Young, I. M.; Crawford, J. W. Interactions and Self-Organization in the Soil-Microbe Complex. *Science*, [S.L.], v. 304, n. 5677, p. 1634-1637, 11 jun. 2004. American Association for the Advancement of Science (AAAS). <http://dx.doi.org/10.1126/science.1097394>.

Yudina, A. V.; Fomin, D. S.; Kotelnikova, A. D.; Milanovskii, E. Yu. *From the Notion of Elementary Soil Particle to the Particle-Size and Microaggregate-Size Distribution Analyses: A Review*. Eurasian Soil Science, v. 51, n. 11, p. 1326–1347, nov. 2018. <http://dx.doi.org/10.1134/S1064229318110091>

Zarebanadkouki, M.; Carminati, A.; Kaestner, An.; Mannes, D.; Morgano, M.; Peetermans, S.; Lehmann, E.; Trtik, P. On-the-fly neutron tomography of water transport into lupine roots. *Physics Procedia*, v. 69, p. 292–298, 2015. <http://dx.doi.org/10.1016/j.phpro.2015.07.041>.

Zhang, C.; Walsh, K. B.; Mckenna, P. Advances in sensing and data analytics in precision agriculture: A review. *Computers and Electronics in Agriculture*, v. 185, p. 106–148, 2021. DOI: 10.1016/j.compag.2021.106148

Zhang, L., Cai, Y., Huang, H., Li, A., Yang, L., Zhou, C. “A CNN-LSTM Model for Soil Organic Carbon Content Prediction with Long Time Series of MODIS-Based

Phenological Variables.” *Remote Sensing*, vol. 14, no. 18, 6 Sept. 2022, pp. 4441–4441, <https://doi.org/10.3390/rs14184441>.

Zhao, H., O'connor, J., Zou, S., Solaiman, Z. M., Mickan, B. S., Bolan, N. “Soil Health and Carbon Storage in Community Gardens in the Perth Metropolitan Area, Australia.” *Soil Use and Management*, vol. 40, no. 1, 1 Jan. 2024, <https://doi.org/10.1111/sum.13033>.

Zheng, S., Lu, J., Zhao, H., Zhu, X., Luo, Z., Wang, Y., Fu, Y., Feng, J., Xiang, T., Torr, P. H. S. *Rethinking Semantic Segmentation from a Sequence-To-Sequence Perspective with Transformers*. 20 June 2021, <https://doi.org/10.1109/cvpr46437.2021.00681>.

Zheng, W., Zheng, K., Gao, L., Zhangzhong, L., Lan, R., Xu, L., Yu, J. “GRU–Transformer: A Novel Hybrid Model for Predicting Soil Moisture Content in Root Zones.” *Agronomy*, vol. 14, no. 3, 23 Feb. 2024, pp. 432–432, <https://doi.org/10.3390/agronomy14030432>.

Zou, K.; Shan, Y.; Ran, de C.; Zhao, X.; Che, X. A Deep Learning Image Augmentation Method for Field Agriculture. *IEEE Access*, [S.L.], v. 12, p. 37432–37442, 2024. Institute of Electrical and Electronics Engineers (IEEE). <http://dx.doi.org/10.1109/access.2024.3373548>.

APÊNDICE A – INFORMAÇÕES GERAIS DO PENEIRAMENTO DAS AMOSTRAS DE SOLO UTILIZADAS

Tabela 8 - Informações gerais do peneiramento das amostras de solos agrícolas

	TIPO DE AMOSTRA	Cidade	Estado	Cultura atual	Cultura anterior	Dosagem aplicação do microgeo (L/ha)	PESO TOTAL APÓS ESTUFA	Peso total (ensaio seco)	6,3mm	4mm	2mm	1mm	0,5mm	fundo	soma paneiras
1	TESTEMUNHA	Santa rita do trivelato	Mato Grosso	Soja	Milho	0	662,97	355,64	230,44	22,49	22,25	13,53	12,08	54,85	355,64
2	MICROGEO	Santa rita do trivelato	Mato Grosso	Soja	Milho	150	731,3	422,62	288,73	18,57	18,28	12,88	12,6	71,56	422,62
3	TESTEMUNHA	Novo Horizonte	Mato Grosso	Soja	Milho	0	547,72	307,78	219,96	19,84	20,57	12,9	11,48	23,03	307,78
4	MICROGEO	Novo Horizonte	Mato Grosso	Soja	Milho	150	580,33	305,9	214,11	15,2	20,71	14,95	13,21	27,72	305,9
5	TESTEMUNHA	Novo Horizonte	Mato Grosso	Soja	Milho	0	596,1	324,26	244,99	15,19	21,15	14,06	12,12	16,75	324,26
6	MICROGEO	Novo Horizonte	Mato Grosso	Soja	Milho	150	611,03	370,44	314,32	12,18	11,53	10,12	9,16	13,13	370,44
7	TESTEMUNHA	Santa rita do trivelato	Mato Grosso	Soja	Milho	0	689,05	372,71	335,75	7,53	7,26	5,08	4,59	12,29	372,5
8	MICROGEO	Santa rita do trivelato	Mato Grosso	Soja	Milho	150	647,91	302,51	207,53	17,61	22,02	13,42	12,61	29,32	302,51
9	TESTEMUNHA	Jataí	Goiás	Soja	Milho	0	789,22	442,58	219,76	25,64	29,54	17,68	20,94	129,02	442,58
10	MICROGEO	Jataí	Goiás	Soja	Milho	150	779,27	404,78	180,65	15,14	14,18	12,87	29,4	152,54	404,78
11	TESTEMUNHA	Fraiburgo	Santa Catarina	Macieira	Milho	0	385,53	213,56	126,32	17,98	25,17	21,11	14,94	8,04	213,56
12	MICROGEO	Fraiburgo	Santa Catarina	Macieira	Milho	300	417,33	213,14	27,58	16,44	41,49	51,17	45,71	30,75	213,14
13	TESTEMUNHA	Araguari	Minas Gerais	Café	Café	0	599,53	449,13	299,72	15,98	25,66	22,7	27,45	57,62	449,13
14	MICROGEO	Araguari	Minas Gerais	Café	Café	300	610,51	421,68	321,11	21,53	22,4	15,47	13,33	27,84	421,68
15	TESTEMUNHA	Jataí	Goiás	Soja	Milho	0	488,48	252,76	182,63	14,2	17,39	12,45	10,84	15,25	252,76
16	MICREOGEO	Jataí	Goiás	Soja	Milho	150	517,95	290,9	124,12	22,86	25,15	35,85	29,34	53,58	290,9
17	TESTEMUNHA	Amambai	Mato Grosso do Sul	Milho	Soja	0	725,12	560,82	500,74	15,52	17,5	11,09	7,07	8,9	560,82

18	MICROGEO	Amambai	Mato Grosso do Sul	Milho	Soja	150	709,14	390,45	288,24	24,42	31,78	19,43	13,68	12,9	390,45
19	TESTEMUNHA	São João D'Aliança	Goiás	Milho	Soja	0	563,56	336,43	152,92	24,66	36,03	26,87	32,02	63,93	336,43
20	MICROGEO	São João D'Aliança	Goiás	Milho	Soja	150	403,22	179,8	36,21	14,16	20,9	17,84	26,12	64,57	179,8
21	TESTEMUNHA	Sarandi	Rio Grande do Sul	Trigo	Nabo	0	573,85	324,59	296,94	7,01	8,68	5,87	3,24	2,85	324,59
22	MICROGEO	Sarandi	Rio Grande do Sul	Trigo	Nabo	150	511,26	236,78	165,59	12,36	17,81	14,81	11,58	14,63	236,78
23	TESTEMUNHA	Araguari	Minas Gerais	Soja	Sorgo	0	387,77	171,54	136,6	7,07	8,93	6,72	4,92	7,3	171,54
24	MICROGEO	Araguari	Minas Gerais	Soja	Sorgo	150	225,2	102	49,8	8,78	10,03	9,82	8,98	14,59	102
25	TESTEMUNHA	Goiatuba	Goiás	Soja	Milho	150	337,35	187,75	43,04	19,38	19,15	13,49	16,56	76,13	187,75
26	MICROGEO	Goiatuba	Goiás	Soja	Milho	150	335,51	175,05	36,74	20,75	24,83	14,68	15,45	62,6	175,05
27	TESTEMUNHA	Júlio de Castilhos	Rio Grande do Sul	Azevem (PASTAGEM)	Azevem (PASTAGEM)	150	615,33	311,26	281,56	4,83	8,1	6,79	4,67	5,31	311,26
28	MICROGEO	Júlio de Castilhos	Rio Grande do Sul	Azevem (PASTAGEM)	Azevem (PASTAGEM)	150	644,36	434,76	376,99	13,46	13,62	12,16	8,6	9,93	434,76
29	TESTEMUNHA	Naviraí	Mato Grosso do Sul	Cana de Açúcar	Cana de Açúcar	0	649,29	330,08	189,16	15,96	14,78	9,43	10,6	90,15	330,08
30	MICROGEO	Naviraí	Mato Grosso do Sul	Cana de Açúcar	Cana de Açúcar	300	761,39	400,69	180,37	19,36	25,72	15,14	16,8	143,3	400,69
31	TESTEMUNHA	Serranópolis	Goiás	Cana de Açúcar	Cana de Açúcar	0	898,91	441,81	217,43	21,46	26,4	15,1	22,21	139,21	441,81
32	MICROGEO	Serranópolis	Goiás	Cana de Açúcar	Cana de Açúcar	300		-275,15	431,47	22,95	31,41	21,56	17,33	20,37	545,09
33	TESTEMUNHA	Santa Margarida do Sul	Rio Grande do Sul	Canola	Canola	0	669,7	321,92	277,1	10,19	6,16	10,78	7,53	10,16	321,92
34	MICROGEO	Santa Margarida do Sul	Rio Grande do Sul	Canola	Canola	150	621,95	334,41	286,1	8,66	10,47	9,89	8,14	11,15	334,41
35	TESTEMUNHA	Palmeira das Missões	Rio Grande do Sul	Trigo	Soja	0	463,8	280,6	203,92	15,38	16,62	14,85	13,44	16,39	280,6

36	MICROGEO	Palmeira das Missões	Rio Grande do Sul	Trigo	Soja	150	497,82	254,33	166,45	17,07	24,12	17,84	15,09	13,76	254,33
37	TESTEMUNHA	Papanduva	Santa Catarina	Trigo	Trigo	150	471,19	271,19	248,79	5,43	7,32	1,5	5,61	2,54	271,19
38	MICROGEO	Papanduva	Santa Catarina	Aveia Branca	Milho	150		-215,58	296,66	9,86	10,45	5,22	1,32	0,43	323,94
39	TESTEMUNHA	Fraiburgo	Santa Catarina	Trigo	Trigo	0	547,48	303,23	247,95	13,06	17,42	12,84	7,66	4,3	303,23
40	MICROGEO	Fraiburgo	Santa Catarina	Trigo	Trigo	150	459,48	210,62	166,89	11,38	16,38	10,5	3,78	1,69	210,62
41	TESTEMUNHA	Naviraí	Mato Grosso do Sul	Milho safrinha	Soja			0							0
42	Microgeo	Naviraí	Mato Grosso do Sul	Milho safrinha	Soja	150	609,52	315,63	200,72	21,76	30,46	22,74	18,71	21,24	315,63
43	TESTEMUNHA	Sertaneja	Paraná	Milho Safrinha	Soja	0	518,46	265,08	174,48	21,3	29,51	19,3	12,98	7,51	265,08
44	Microgeo	Sertaneja	Paraná	Milho Safrinha	Soja	150	516,33	269,85	183,25	16,06	24,79	19,19	15,71	10,85	269,85
45	TESTEMUNHA	Pedro Afonso	Tocantins	Cana de Açúcar	Cana de Açúcar	0	885,62	509,12	153,3	55,8	174,24	26,23	32,67	66,88	509,12
46	MICROGEO	Pedro Afonso	Tocantins	Cana de Açúcar	Cana de Açúcar	300	1277,15	793,81	276,9	155,28	121,99	71,38	78,29	161,35	793,81
47	TESTEMUNHA	São Miguel do Iguaçu	Paraná	Soja	Milho Safrinha	0	563,89	311,77	255,4	14,31	17,76	13,26	7,12	3,92	311,77
48	MICROGEO	São Miguel do Iguaçu	Paraná	Soja	Milho Safrinha	150	488,5	294,14	222,59	15,02	22,94	15,62	11,05	6,92	294,14
49	TESTEMUNHA	Ipiranga	Paraná	Soja	Trigo	0	701,18	413	347,38	19,73	23,54	11,6	5,58	5,17	413
50	MICROGEO	Ipiranga	Paraná	Soja	Trigo	150	503,87	248,45	171,65	17,62	25,92	14,88	9,72	8,66	248,45
51	TESTEMUNHA	Formosa do Rio Preto	Bahia	Soja	Soja	0	915,83	549,1	308,47	20,13	27,13	19,5	26,45	147,42	549,1
52	MICROGEO	Formosa do Rio Preto	Bahia	Soja	Soja	150	922,98	544,08	136,58	44,37	77,51	36,91	46,49	202,22	544,08
53	TESTEMUNHA	Luis Eduardo Magalhães	Bahia	Soja	Soja	0	955,73	514,84	418,28	9,7	8,83	8,55	13,64	55,84	514,84
54	MICROGEO	Luis Eduardo Magalhães	Bahia	Soja	Soja	150	1118,9	696,48	436,13	24,89	33,15	24,81	38,75	138,75	696,48
55	TESTEMUNHA	Boa Esperança	Paraná	Soja	Milho Safrinha	0	586,4	353,72	254,97	21,73	25,98	16,2	12,73	22,11	353,72

56	MICROGEO	Boa Esperança	Paraná	Soja	Milho Safrinha	150	573,07	305,92	205,16	23,86	25,98	17,73	13,53	19,66	305,92
----	----------	------------------	--------	------	----------------	-----	--------	--------	--------	-------	-------	-------	-------	-------	--------

APÊNDICE B – VALIDAÇÃO DA CLASSIFICAÇÃO DE AGREGADOS DE SOLO

Tabela 9 – Validação da classificação de agregados da amostra de Solo 1.

Solo1 - Biofertilizante				Solo1 - Testemunha			
Imagem	Classificação	classificação do especialista	ID	Imagem	Classificação	classificação do especialista	ID
10.png	Regular	regular	1	110.png	Ruim	ruim	1
11.png	Regular	regular		111.png	Ruim	ruim	
110.png	Regular	regular		112.png	Ruim	ruim	
111.png	Ruim	regular		113.png	Ruim	ruim	
112.png	Regular	regular		114.png	Regular	regular	
113.png	Ruim	ruim		115.png	Regular	regular	
114.png	Ruim	ruim		116.png	Regular	ruim	
115.png	Regular	regular		117.png	Regular	regular	
116.png	Regular	regular		118.png	Regular	regular	
117.png	Ruim	ruim		119.png	Ruim	ruim	
118.png	Ruim	ruim	2	120.png	Ruim	ruim	2
119.png	Ruim	ruim		121.png	Regular	regular	
12.png	Regular	regular		122.png	Regular	regular	
120.png	Regular	regular		123.png	Regular	regular	
121.png	Regular	regular		124.png	Regular	regular	
122.png	Ruim	regular		125.png	Regular	regular	
123.png	Ruim	ruim		126.png	Bom	bom	
124.png	Regular	regular		127.png	Regular	regular	
125.png	Ruim	ruim		128.png	Ruim	ruim	
126.png	Ruim	ruim		129.png	Regular	regular	
127.png	Ruim	ruim	3	130.png	Ruim	ruim	3
128.png	Regular	regular		131.png	Ruim	ruim	
129.png	Bom	bom		132.png	Regular	regular	
13.png	Ruim	ruim		133.png	Regular	regular	
130.png	Bom	bom		134.png	Regular	regular	
131.png	Regular	regular		135.png	Regular	regular	
132.png	Regular	regular		136.png	Regular	regular	
133.png	Bom	regular		137.png	Regular	regular	
134.png	Bom	regular		138.png	Ruim	regular	
135.png	Bom	regular		139.png	Regular	regular	
136.png	Regular	regular	4	140.png	Regular	regular	4
137.png	Regular	regular		141.png	Regular	regular	
138.png	Bom	regular		142.png	Ruim	ruim	
139.png	Bom	regular		143.png	Regular	regular	
14.png	Ruim	ruim		144.png	Ruim	ruim	
140.png	Ruim	ruim		145.png	Regular	regular	
141.png	Ruim	ruim		146.png	Regular	regular	
142.png	Ruim	ruim		147.png	Regular	regular	
143.png	Regular	regular		148.png	Regular	regular	
144.png	Regular	regular		149.png	Regular	regular	
145.png	Regular	regular	5	150.png	Ruim	ruim	5
146.png	Bom	bom		151.png	Ruim	regular	
147.png	Regular	regular		152.png	Bom	bom	
148.png	Bom	bom		153.png	Bom	bom	
149.png	Regular	regular		154.png	Regular	regular	
15.png	Regular	regular		155.png	Regular	regular	
150.png	Regular	regular		156.png	Regular	regular	
151.png	Bom	regular		157.png	Ruim	regular	
152.png	Bom	bom		158.png	Regular	regular	
153.png	Regular	regular		159.png	Bom	regular	

154.png	Regular	regular	160.png	Bom	regular	6
155.png	Regular	regular	161.png	Regular	regular	
156.png	Regular	regular	162.png	Bom	bom	
157.png	Regular	regular	163.png	Regular	regular	
158.png	Bom	bom	164.png	Regular	regular	
159.png	Regular	regular	165.png	Regular	regular	
16.png	Bom	bom	166.png	Regular	regular	
160.png	Regular	regular	167.png	Regular	regular	
161.png	Bom	regular	9 168.png	Regular	regular	
162.png	Regular	regular	169.png	Regular	regular	
163.png	Bom	regular	10 170.png	Regular	regular	
164.png	Regular	regular	171.png	Regular	regular	
165.png	Regular	regular	172.png	Bom	regular	7
166.png	Bom	bom	173.png	Regular	regular	
167.png	Bom	bom	174.png	Regular	regular	
168.png	Regular	regular	175.png	Regular	regular	
169.png	Bom	regular	11 176.png	Regular	regular	
17.png	Bom	bom	177.png	Bom	bom	
170.png	Regular	regular	178.png	Regular	regular	
171.png	Regular	regular	179.png	Bom	bom	
172.png	Regular	regular	180.png	Bom	regular	8
173.png	Regular	regular	181.png	Regular	regular	
174.png	Regular	regular	182.png	Bom	bom	
175.png	Ruim	ruim	183.png	Bom	bom	
176.png	Bom	bom	184.png	Regular	regular	
177.png	Bom	bom	185.png	Regular	regular	
178.png	Bom	bom	186.png	Bom	regular	9
179.png	Bom	regular	12 187.png	Bom	regular	10
18.png	Bom	regular	13 188.png	Bom	regular	11
19.png	Regular	regular	189.png	Bom	bom	
20.png	Regular	regular	190.png	Regular	regular	
21.png	Bom	regular	14 191.png	Bom	bom	
22.png	Bom	bom	192.png	Regular	regular	
23.png	Bom	bom	193.png	Regular	regular	
24.png	Regular	regular	194.png	Regular	regular	
25.png	Regular	regular	195.png	Regular	regular	
26.png	Regular	regular	196.png	Regular	regular	
27.png	Ruim	ruim	197.png	Regular	regular	
28.png	Ruim	ruim	198.png	Regular	regular	
29.png	Bom	bom	199.png	Regular	regular	
30.png	Regular	regular	21.png	Regular	regular	
31.png	Regular	regular	210.png	Regular	regular	
32.png	Regular	regular	22.png	Regular	regular	
33.png	Bom	bom	23.png	Regular	regular	
34.png	Regular	regular	24.png	Bom	regular	12
35.png	Ruim	ruim	25.png	Regular	regular	
36.png	Regular	ruim	26.png	Bom	bom	
37.png	Bom	bom	27.png	Bom	bom	
38.png	Bom	bom	28.png	Bom	bom	
39.png	Bom	bom	29.png	Bom	bom	
divergencias		14	divergencias			12

Tabela 10 – Validação da classificação de agregados da amostra de Solo 2.

Tabela 10 – validação da classificação de agregados da amostra de Solo 2:						
Solo 2 - Testemunha			Solos 2 - Biofertilizante			
Imagem	Classificação	classificação do especialista	Imagem	Classificação	classificação do especialista	
110.png	Ruim	ruim	110.png	Regular	regular	
111.png	Regular	regular	111.png	Regular	regular	
112.png	Regular	regular	112.png	Regular	regular	
113.png	Regular	regular	113.png	Regular	regular	
114.png	Regular	regular	114.png	Regular	ruim	1
115.png	Ruim	regular	115.png	Ruim	ruim	
116.png	Ruim	ruim	116.png	Ruim	rum	
117.png	Regular	regular	117.png	Regular	regular	
118.png	Ruim	ruim	118.png	Bom	regular	2
119.png	Regular	regular	119.png	Bom	regular	3
120.png	Regular	regular	120.png	Bom	regular	4
121.png	Regular	regular	121.png	Regular	regular	
122.png	Regular	regular	122.png	Regular	regular	
123.png	Regular	regular	123.png	Regular	regular	
124.png	Bom	regular	2 124.png	Regular	regular	
125.png	Bom	bom	125.png	Bom	bom	
126.png	Bom	bom	126.png	Bom	bom	
127.png	Bom	regular	3 127.png	Bom	bom	
128.png	Bom	regular	4 128.png	Bom	regular	5
129.png	Regular	regular	129.png	Regular	regular	
130.png	Bom	bom	130.png	Bom	bom	
131.png	Ruim	regular	5 131.png	Bom	bom	
132.png	Bom	regular	6 132.png	Bom	bom	
133.png	Regular	regular	133.png	Regular	regular	
134.png	Regular	regular	134.png	Regular	regular	
135.png	Regular	ruim	7 135.png	Regular	regular	
136.png	Regular	ruim	8 136.png	Bom	bom	
137.png	Bom	bom	137.png	Bom	bom	
138.png	Bom	bom	138.png	Bom	bom	
139.png	Bom	bom	139.png	Bom	bom	
14.png	Bom	bom	14.png	Regular	regular	
140.png	Bom	bom	140.png	Bom	regular	6
141.png	Bom	bom	141.png	Bom	regular	7
142.png	Bom	bom	142.png	Regular	regular	
143.png	Bom	regular	9 143.png	Bom	bom	
144.png	Regular	regular	144.png	Bom	bom	
145.png	Bom	bom	145.png	Bom	bom	
146.png	Bom	bom	146.png	Bom	bom	
147.png	Bom	bom	147.png	Bom	bom	
148.png	Regular	regular	148.png	Bom	bom	
149.png	Bom	regular	10 149.png	Bom	bom	
15.png	Regular	regular	15.png	Ruim	ruim	
150.png	Regular	regular	150.png	Bom	bom	
151.png	Regular	regular	151.png	Bom	bom	
152.png	Regular	regular	152.png	Bom	bom	
153.png	Regular	regular	153.png	Bom	regular	8
154.png	Bom	regular	11 154.png	Bom	regular	9
155.png	Bom	regular	12 155.png	Ruim	ruim	
156.png	Bom	regular	13 156.png	Regular	ruim	10
157.png	Regular	regular	157.png	Bom	regular	11

158.png	Bom	bom	158.png	Bom	regular	12
159.png	Bom	bom	159.png	Regular	regular	
16.png	Regular	regular	16.png	Ruim	ruim	
160.png	Bom	regular	14 160.png	Regular	regular	
161.png	Bom	regular	15 161.png	Regular	regular	
162.png	Bom	regular	16 162.png	Bom	regular	13
163.png	Bom	regular	17 163.png	Bom	regular	14
164.png	Regular	regular	164.png	Bom	regular	15
17.png	Regular	regular	165.png	Bom	bom	
18.png	Ruim	ruim	166.png	Regular	regular	
19.png	Regular	ruim	18 167.png	Regular	regular	
20.png	Regular	regular	168.png	Bom	bom	
21.png	Ruim	ruim	169.png	Bom	bom	
22.png	Regular	regular	17.png	Regular	regular	
23.png	Regular	regular	170.png	Regular	regular	
24.png	Bom	bom	171.png	Regular	regular	
25.png	Bom	bom	172.png	Ruim	ruim	
26.png	Ruim	ruim	173.png	Ruim	ruim	
27.png	Ruim	ruim	174.png	Bom	bom	
28.png	Ruim	ruim	175.png	Bom	bom	
30.png	Regular	bom	19 176.png	Bom	bom	
31.png	Bom	bom	177.png	Bom	bom	
32.png	Bom	bom	178.png	Bom	bom	
33.png	Regular	regular	179.png	Regular	regular	
34.png	Regular	regular	18.png	Bom	regular	16
35.png	Bom	bom	180.png	Bom	bom	
36.png	Bom	bom	181.png	Bom	bom	
37.png	Bom	bom	182.png	Regular	regular	
38.png	Bom	bom	183.png	Ruim	ruim	
39.png	Bom	bom	19.png	Regular	regular	
40.png	Bom	bom	20.png	Bom	bom	
41.png	Bom	bom	21.png	Bom	bom	
42.png	Bom	regular	20 22.png	Bom	bom	
43.png	Bom	regular	21 23.png	Ruim	regular	17
44.png	Bom	bom	24.png	Regular	regular	
45.png	Bom	bom	25.png	Bom	regular	18
46.png	Bom	bom	26.png	Regular	regular	
47.png	Bom	bom	27.png	Bom	bom	
48.png	Bom	bom	28.png	Bom	bom	
49.png	Bom	bom	29.png	Bom	bom	
50.png	Bom	bom	30.png	Bom	bom	
51.png	Bom	bom	31.png	Bom	bom	
52.png	Bom	bom	32.png	Regular	regular	
53.png	Bom	bom	33.png	Bom	bom	
54.png	Bom	bom	34.png	Bom	bom	
55.png	Bom	bom	35.png	Bom	bom	
56.png	Bom	regular	22 36.png	Bom	bom	
57.png	Bom	bom	37.png	Bom	bom	
58.png	Bom	bom	38.png	Bom	bom	
59.png	Regular	regular	39.png	Bom	bom	
divergências		22	divergências			18

Tabela 11 – Validação da classificação de agregados da amostra de Solo 3.

Solos 3- Testemunha			Solo 3 - Biofertilizante		
Imagem	Classificação	classificação do especialista	Imagem	Classificação	classificação do especialista
11.png	Regular	regular	110.png	Regular	regular
110.png	Regular	regular	111.png	Ruim	regular
111.png	Regular	regular	112.png	Regular	regular
112.png	Regular	bom	113.png	Regular	regular
113.png	Regular	regular	114.png	Regular	bom
114.png	Regular	regular	115.png	Regular	regular
115.png	Regular	regular	116.png	Regular	regular
116.png	Regular	regular	117.png	Regular	regular
117.png	Regular	regular	118.png	Regular	regular
118.png	Ruim	regular	119.png	Regular	regular
119.png	Ruim	regular	120.png	Regular	ruim
12.png	Regular	regular	121.png	Regular	ruim
120.png	Regular	regular	122.png	Regular	ruim
121.png	Regular	regular	123.png	Ruim	ruim
122.png	Regular	regular	124.png	Ruim	ruim
123.png	Regular	regular	125.png	Ruim	ruim
124.png	Ruim	ruim	126.png	Regular	regular
125.png	Ruim	ruim	127.png	Regular	regular
126.png	Ruim	ruim	128.png	Regular	regular
127.png	Ruim	ruim	129.png	Regular	regular
128.png	Ruim	ruim	130.png	Regular	bom
129.png	Regular	bom	131.png	Bom	bom
13.png	Ruim	ruim	132.png	Bom	bom
130.png	Regular	bom	133.png	Regular	regular
131.png	Bom	bom	134.png	Regular	regular
132.png	Regular	bom	135.png	Regular	regular
133.png	Ruim	ruim	136.png	Regular	regular
134.png	Ruim	ruim	137.png	Regular	ruim
135.png	Bom	bom	138.png	Regular	ruim
136.png	Bom	bom	139.png	Regular	ruim
137.png	Regular	regular	140.png	Regular	regular
138.png	Regular	regular	141.png	Regular	regular
139.png	Regular	regular	142.png	Regular	regular
14.png	Regular	regular	143.png	Ruim	ruim
140.png	Regular	regular	144.png	Ruim	ruim
141.png	Regular	regular	145.png	Ruim	ruim
142.png	Regular	regular	146.png	Regular	ruim
143.png	Regular	regular	147.png	Regular	regular
144.png	Regular	regular	148.png	Regular	regular
145.png	Regular	regular	149.png	Regular	regular
146.png	Regular	regular	150.png	Ruim	ruim
147.png	Regular	regular	151.png	Ruim	ruim
148.png	Regular	regular	152.png	Ruim	ruim
149.png	Regular	regular	210.png	Bom	bom
15.png	Ruim	ruim	211.png	Regular	regular
150.png	Bom	bom	212.png	Regular	regular
16.png	Ruim	ruim	213.png	Bom	bom
17.png	Ruim	ruim	214.png	Regular	bom
18.png	Regular	regular	215.png	Regular	regular
19.png	Regular	regular	216.png	Regular	regular

20.png	Ruim	regular	7	217.png	Ruim	regular	11
21.png	Regular	regular		218.png	Regular	regular	
22.png	Regular	regular		219.png	Regular	ruim	12
23.png	Regular	regular		220.png	Ruim	ruim	
24.png	Regular	regular		221.png	Ruim	regular	13
25.png	Regular	ruim	8	222.png	Regular	regular	
26.png	Regular	regular		223.png	Regular	regular	
27.png	Regular	regular		224.png	Bom	bom	
28.png	Regular	regular		225.png	Bom	bom	
29.png	Regular	regular		226.png	Regular	regular	
30.png	Bom	regular	9	227.png	Regular	regular	
31.png	Ruim	ruim		228.png	Regular	regular	
32.png	Regular	regular		229.png	Regular	regular	
33.png	Regular	ruim	10	230.png	Regular	regular	
34.png	Regular	ruim	11	231.png	Regular	regular	
35.png	Ruim	ruim		25.png	Regular	regular	
36.png	Ruim	ruim		26.png	Bom	bom	
37.png	Regular	regular		27.png	Bom	bom	
38.png	Regular	regular		28.png	Regular	regular	
39.png	Regular	regular		29.png	Regular	regular	
40.png	Regular	regular		30.png	Regular	regular	
41.png	Regular	regular		31.png	Regular	regular	
42.png	Regular	regular		32.png	Regular	regular	
43.png	Bom	bom		33.png	Regular	regular	
44.png	Bom	bom		34.png	Regular	regular	
45.png	Regular	regular		35.png	Regular	regular	
46.png	Ruim	ruim		36.png	Regular	regular	
47.png	Ruim	ruim		37.png	Regular	regular	
48.png	Bom	bom		38.png	Bom	bom	
49.png	Regular	regular		39.png	Regular	bom	14
50.png	Bom	bom		40.png	Regular	regular	
51.png	Bom	bom		41.png	Bom	regular	15
52.png	Bom	regular	12	42.png	Bom	bom	
53.png	Regular	regular		43.png	Bom	regular	16
54.png	Bom	regular	13	44.png	Ruim	regular	17
55.png	Bom	bom		45.png	Regular	regular	
56.png	Bom	bom		46.png	Bom	bom	
57.png	Bom	bom		47.png	Bom	bom	
58.png	Ruim	ruim		48.png	Regular	regular	
59.png	Ruim	ruim		49.png	Regular	regular	
60.png	Regular	regular		50.png	Regular	regular	
61.png	Regular	regular		51.png	Regular	regular	
62.png	Regular	regular		52.png	Bom	regular	18
63.png	Regular	regular		53.png	Regular	regular	
64.png	Regular	regular		54.png	Regular	regular	
65.png	Regular	regular		55.png	Regular	regular	
66.png	Regular	regular		56.png	Ruim	ruim	
67.png	Regular	regular		57.png	Regular	regular	
68.png	Regular	regular		58.png	Regular	ruim	19
69.png	Regular	regular		59.png	Bom	bom	
divergencias		13	divergencias			19	