

ANÁLISE GRANULOMÉTRICA DE AREIA COM REDES NEURAIAS CONVOLUCIONAIS APLICADAS A IMAGENS DIGITAIS

Roberta Dal Pont Colombo¹, Sergio Coral²

Resumo: A análise granulométrica é uma etapa essencial para compreender as propriedades físicas de materiais como solos e areias, influenciando diretamente parâmetros como porosidade, permeabilidade e resistência mecânica. Tradicionalmente, essa análise é realizada por métodos laboratoriais de peneiramento e sedimentação, que, embora precisos, são demorados e dispendiosos. Neste trabalho, propõe-se o uso de redes neurais convolucionais (CNNs) aplicadas a imagens digitais para automatizar a caracterização granulométrica de amostras de areia. As imagens foram capturadas com microscópio digital e processadas por meio de técnicas de pré-processamento utilizando as bibliotecas OpenCV, NumPy e TensorFlow/Keras. O modelo de CNN foi treinado e validado com base em medidas de referência obtidas no software ImageJ-Fiji. Os resultados indicaram que, embora o modelo tenha conseguido identificar padrões e segmentar grãos de areia, ainda apresentou discrepâncias significativas em relação aos métodos tradicionais, especialmente na contagem das partículas. Conclui-se que a abordagem possui potencial promissor, mas requer aprimoramentos, como aumento do conjunto de treinamento e uso de arquiteturas mais robustas, para alcançar maior precisão e confiabilidade. Além disso, observa-se que a aplicação de técnicas de aprendizado profundo nesse tipo de análise abre caminho para o desenvolvimento de ferramentas automatizadas capazes de processar grandes volumes de dados com rapidez e consistência. Essa automação tem o potencial de reduzir o tempo necessário para caracterização granulométrica e minimizar erros humanos, tornando o processo mais acessível e eficiente.

Palavras-chave: granulometria; redes neurais convolucionais; processamento de imagens; areia; aprendizado profundo.

¹Curso de Ciência da Computação, Universidade do Extremo Sul Catarinense (Unesc), Robertadpcolombo@gmail.com

²Orientador. Curso de Ciência da Computação, Universidade do Extremo Sul Catarinense (Unesc), sergiocoral@unesc.net

ABSTRACT: Grain size analysis is an essential step in understanding the physical properties of materials such as soils and sands, directly influencing parameters like porosity, permeability, and mechanical strength. Traditionally, this analysis is performed using laboratory methods such as sieving and sedimentation, which, although accurate, are time-consuming and costly. In this work, the use of convolutional neural networks (CNNs) applied to digital images is proposed to automate the granulometric characterization of sand samples. The images were captured with a digital microscope and processed through preprocessing techniques using the OpenCV, NumPy, and TensorFlow/Keras libraries. The CNN model was trained and validated based on reference measurements obtained with the ImageJ-Fiji software. The results indicated that, although the model was able to identify patterns and segment sand grains, it still showed significant discrepancies compared to traditional methods, especially in particle counting. It is concluded that the approach has promising potential but requires improvements, such as increasing the training dataset and employing more robust architectures, to achieve greater accuracy and reliability. Furthermore, the application of deep learning techniques in this type of analysis paves the way for the development of automated tools capable of processing large volumes of data quickly and consistently. This automation has the potential to reduce the time required for granulometric characterization and minimize human errors, making the process more accessible and efficient.

Keywords: granulometry; convolutional neural networks; image processing; sand; deep learning.

1 INTRODUÇÃO

A análise granulométrica, comumente denominada granulometria, é uma etapa fundamental em várias disciplinas das áreas de engenharia, pois fornece informações cruciais sobre a distribuição de tamanho das partículas que compõem materiais como solos, sedimentos, areias e outros agregados (Suguio, 2003).

Essas informações influenciam diretamente propriedades essenciais, como porosidade, permeabilidade e comportamento mecânico, tornando a granulometria especialmente relevante em contextos geotécnicos e ambientais (Suguio, 2003).

Tradicionalmente, a análise granulométrica é realizada por métodos como peneiramento, sedimentação e difração a laser, que, embora

confiáveis, demandam tempo, infraestrutura laboratorial específica e, muitas vezes, alto custo operacional (Massad, 2016; Morais et al., 2021).

Com os avanços das tecnologias digitais, métodos baseados em imagens têm se mostrado alternativas promissoras, permitindo análises não destrutivas, rápidas e mais acessíveis, especialmente quando integradas a técnicas de inteligência artificial (Rodrigues; Lasthaus, 2021).

Dentre essas técnicas, as redes neurais convolucionais (CNNs) se destacam por sua capacidade de reconhecer padrões visuais complexos, sendo amplamente utilizadas em tarefas de classificação, segmentação e contagem de objetos (Janiesch; Zschech; Heinrich, 2021).

Quando aplicadas à análise granulométrica, as CNNs possibilitam a automatização do processo, reduzindo interferências humanas e aumentando a precisão na caracterização dos grãos (Janiesch; Zschech; Heinrich, 2021).

O objetivo geral do estudo consiste em caracterizar a granulometria da areia por meio do processamento de imagens digitais, utilizando redes neurais convolucionais como ferramenta principal para a análise.

Para alcançar esse objetivo, foram definidos objetivos específicos que incluem compreender os conceitos fundamentais da granulometria da areia e os princípios das redes neurais convolucionais; padronizar a captura e o preparo das imagens digitais, garantindo condições adequadas de iluminação, foco e contraste; empregar técnicas de processamento de imagens com OpenCV, aplicando filtragem, realce e segmentação para evidenciar as características dos grãos; desenvolver e treinar um modelo de rede neural convolucional, ajustando seus parâmetros para identificar e contar partículas nas imagens; comparar os resultados obtidos pelo modelo com as medições fornecidas pelo software ImageJ-Fiji; e, por fim, avaliar o desempenho da abordagem baseada em inteligência artificial, destacando suas limitações e propondo melhorias para aprimoramentos futuros.

Além disso, o desenvolvimento deste estudo contou com o uso de ferramentas computacionais que forneceram suporte essencial às etapas de processamento e análise das imagens digitais. A biblioteca OpenCV foi empregada para realizar o pré-processamento das imagens, permitindo operações como filtragem, redução de ruídos, realce de bordas e segmentação dos grãos de areia (McKinney, 2018).

A NumPy, por sua vez, foi utilizada para o tratamento e manipulação de matrizes numéricas, possibilitando a execução eficiente das operações matemáticas envolvidas no processamento dos dados (McKinney,

2018).

Para o desenvolvimento e treinamento do modelo de aprendizado profundo, foram utilizadas as bibliotecas TensorFlow e Keras, amplamente reconhecidas na área de inteligência artificial.

O TensorFlow fornece a estrutura de computação necessária para a execução dos algoritmos de aprendizado, enquanto o Keras oferece uma interface de alto nível que facilita a construção, compilação e ajuste das redes neurais convolucionais. Em conjunto, essas ferramentas possibilitaram a integração entre o processamento digital de imagens e as técnicas de aprendizado profundo aplicadas à análise granulométrica da areia (Homem; Ufes, 2020).

Entre os estudos revisados, destaca-se o artigo desenvolvido por Borges et al. (2015), publicado na *Brazilian Journal of Aquatic Science and Technology* (BJAST), o artigo apresenta um protocolo prático e de baixo custo para a análise granulométrica de sedimentos arenosos de praias utilizando imagens digitais e o software gratuito ImageJ.

O método proposto envolve a captação de imagens digitais dos grãos de areia, seguida do processamento e análise das partículas com base em parâmetros como tamanho, forma e distribuição, e os resultados obtidos com essa técnica foram comparados aos métodos tradicionais de peneiramento mecânico e difração a laser, revelando uma boa correspondência e confiabilidade dos dados.

Outro artigo que se destaca foi o desenvolvido por Santos et al. (2022), o estudo avaliou a aplicação do software livre ImageJ na caracterização de grãos de areia, utilizando técnicas de análise digital de imagens. As amostras foram fotografadas e posteriormente processadas digitalmente para a extração de parâmetros geométricos e morfológicos das partículas, e a pesquisa concluiu que o uso do ImageJ representa uma alternativa viável, precisa e economicamente acessível para a caracterização de partículas.

A estrutura deste trabalho está organizada da seguinte forma: inicialmente, apresenta-se a introdução, que inclui a contextualização do tema, os objetivos e a justificativa. Em seguida, descrevem-se os procedimentos metodológicos adotados, abrangendo desde a coleta e organização dos dados até a implementação do sistema. Na sequência, são apresentados os resultados obtidos com o desenvolvimento do protótipo, acompanhados de sua análise. Por fim, a conclusão ressalta as contribuições alcançadas e aponta possibilidades para pesquisas futuras.

2 MATERIAIS E MÉTODOS

Para o desenvolvimento desta pesquisa, foram empregados recursos de hardware e software compatíveis com as necessidades do estudo.

O hardware utilizado consistiu em um Notebook equipado com processador Intel® Core™ i5-1135G7 de 11ª geração com processador de 2.40 GHz, 8 GB de memória RAM e 100 GB de armazenamento interno, configurado para sistemas operacionais de 64 bits, processador x64.

Este equipamento foi suficiente para o processamento das imagens e o treinamento da rede neural.

Adicionalmente, utilizou-se um microscópio digital de alta resolução, juntamente com um iPhone 12, responsável pela captura das imagens dos grãos de areia, garantindo maior qualidade e precisão na obtenção das amostras visuais.

No que se refere ao software, o sistema operacional adotado foi o Windows, com o ambiente de desenvolvimento Visual Studio Code. O processamento e a análise das imagens foram realizados com o uso das bibliotecas OpenCV, NumPy, TensorFlow e Keras, todas em linguagem Python, permitindo o tratamento das imagens e o treinamento do modelo de rede neural convolucional (CNN).

Além disso, o software ImageJ foi empregado como ferramenta de referência e calibração das medições, assegurando a acurácia dos parâmetros de tamanho e forma dos grãos.

2.1 COLETA DAS AMOSTRAS

As amostras de areia utilizadas na pesquisa foram adquiridas em uma loja especializada, já apresentando medidas padronizadas e prontas para análise. Cada amostra foi devidamente identificada e armazenada em recipientes limpos, secos e selados, garantindo a preservação das características físicas originais até o momento das medições.


2.2 CAPTURA DAS IMAGENS

A captura das imagens foi realizada por meio de um microscópio digital e de um iPhone 12, em ambiente controlado para assegurar condições padronizadas de iluminação e contraste. As amostras foram posicionadas sobre um fundo branco fosco, de modo a evitar interferências visuais e facilitar a segmentação dos grãos nas etapas posteriores.

A Figura 1 ilustra a configuração utilizada para a captura das ima-

gens, mostrando como a fotografia foi realizada e detalhando a disposição dos equipamentos e da amostra durante o procedimento.

Figura 1 - Estrutura de Coleta



Fonte: Elaborado pelo autor.

2.3 PRÉ-PROCESSAMENTO DAS IMAGENS

Após a captura, as imagens foram submetidas a uma etapa de pré-processamento digital utilizando a biblioteca OpenCV.

Esse procedimento tem por finalidade aprimorar a qualidade visual das imagens e extrair informações relevantes sobre as partículas de areia.


As principais etapas desse processo incluem a conversão das imagens para escala de cinza, a redução de ruídos por meio do filtro Gaussian Blur, o aumento do contraste e a segmentação das partículas por limitização adaptativa.

Essas etapas são fundamentais para garantir que as características visuais dos grãos sejam preservadas e destacadas de forma adequada, permitindo uma análise mais precisa das suas formas, tamanhos e contornos.

Além disso, o pré-processamento adequado das imagens contribui para reduzir interferências externas, como sombras e variações de iluminação, assegurando que o modelo de rede neural receba dados limpos e consistentes para o treinamento e a posterior contagem das partículas.

A Figura 2 apresenta a imagem já submetida ao pré-processamento digital, correspondendo à versão tratada utilizada nas etapas de análise. Após a aplicação da conversão para escala de cinza, filtragem Gaussiana, realce de contraste e limiarização adaptativa, observa-se a melhoria na definição dos contornos e a redução de ruídos. Esse tratamento, implementado com a biblioteca OpenCV, garante a uniformização e a consistência visual necessárias para o adequado desempenho do modelo de rede neural convolucional.

Figura 2 - Tratamento



Fonte: Elaborado pelo autor.

Em seguida, foi realizada a extração de bordas, a binarização da imagem e a rotulagem dos objetos identificados, com o objetivo de isolar cada partícula e eliminar sobreposições. Essas etapas permitem que o modelo de rede neural identifique de forma mais precisa os contornos e dimensões dos grãos de areia.

2.4 DESENVOLVIMENTO DA REDE NEURAL CONVOLUCIONAL

Para a análise automatizada, foi desenvolvido um modelo de rede neural convolucional (CNN) implementado no framework TensorFlow/Keras.

O modelo é composto por camadas convolucionais, camadas de pooling e camadas totalmente conectadas, configuradas para reconhecer padrões de textura e forma presentes nas imagens.

O conjunto de dados foi dividido em 70% para treinamento, 20% para validação e 10% para teste, de modo a avaliar o desempenho do modelo em dados não vistos.

Durante o treinamento, é utilizada a função de perda categorical cross-entropy, com o otimizador Adam, ajustando-se a learning rate conforme o progresso do aprendizado.

O desempenho do modelo foi medido por métricas quantitativas

como acurácia, erro médio absoluto (MAE) e matriz de confusão, permitindo avaliar sua precisão e capacidade de generalização.

Para o treinamento da rede neural, foram utilizadas 60 imagens ao total, distribuídas de forma equilibrada entre as classes: 20 imagens de areia média, 20 de areia fina e 20 de areia grossa. Essa divisão homogênea buscou garantir que o modelo tivesse uma representação adequada das diferentes granulometrias, contribuindo para um aprendizado mais consistente e para a redução de viés entre as classes.

Para a etapa de validação, foram utilizadas 12 imagens inéditas, distintas daquelas empregadas no treinamento, com o objetivo de avaliar a capacidade do modelo de generalizar para novos dados.

Essas imagens foram distribuídas de forma equilibrada entre as classes, sendo aproximadamente 33,33% de areia média, 33,33% de areia fina e 33,33% de areia grossa, garantindo assim uma representação proporcional das três granulometrias e totalizando 100% das amostras de validação.

Essa divisão homogênea assegurou que o desempenho verificado não estivesse enviesado por uma classe específica, permitindo uma comparação mais justa e consistente com os resultados obtidos pelo ImageJ.

2.5 VALIDAÇÃO DOS RESULTADOS

A validação dos resultados foi realizada por meio da comparação entre as estimativas obtidas pelo modelo de CNN e as medições de referência obtidas com o software ImageJ. Esse procedimento foi fundamental para verificar o desempenho do modelo em relação a uma ferramenta amplamente reconhecida e consolidada na área de análise de imagens. A utilização do ImageJ como padrão de comparação garante uma base sólida para a avaliação, uma vez que o software é amplamente empregado em pesquisas científicas e conhecido pela sua precisão e consistência na quantificação de partículas e estruturas microscópicas.

Segundo Borges et al. (2015), o uso do software ImageJ–Fiji mostrou resultados consistentes e alinhados com os obtidos por métodos tradicionais de análise granulométrica, como peneiramento e sedimentação, validando sua eficiência na identificação e quantificação de partículas.

Dessa forma, ao comparar os resultados deste trabalho com os apresentados no referido estudo, observa-se que o ImageJ mantém alta precisão na segmentação e contagem de grãos, apresentando valores com-

patíveis com os métodos convencionais. Essa correspondência reforça a confiabilidade do ImageJ como ferramenta de referência na análise granulométrica digital, servindo como base sólida para a comparação e validação de novos métodos automatizados, como o modelo de rede neural proposto neste trabalho.

Essa comparação permitirá analisar o grau de concordância entre os métodos e verificar a eficácia da abordagem baseada em aprendizado de máquina, destacando tanto as potencialidades quanto as limitações do modelo desenvolvido.

Além disso, possibilita avaliar o nível de precisão alcançado pela rede neural convolucional em relação ao método de referência, fornecendo uma visão mais detalhada sobre sua capacidade de generalização e consistência diante de diferentes amostras de areia.

A partir dessa análise, torna-se possível identificar eventuais discrepâncias nos resultados, compreender as causas dessas divergências e propor ajustes nos parâmetros da rede neural ou nas etapas de pré-processamento das imagens, visando aprimorar o desempenho geral do sistema.

Tais ajustes podem envolver a modificação da arquitetura do modelo, o refinamento das técnicas de segmentação ou a ampliação do conjunto de dados de treinamento, de modo a tornar o modelo mais robusto e representativo. Em última instância, essa etapa contribui para o aprimoramento contínuo da metodologia proposta, fortalecendo sua aplicabilidade prática em análises granulométricas automatizadas e consolidando seu potencial como uma alternativa viável aos métodos tradicionais.


2.6 FLUXOGRAMA DO PROCESSO METODOLÓGICO

A Figura 3 apresenta o cronograma de desenvolvimento do projeto, evidenciando as etapas planejadas e a forma como as atividades foram distribuídas ao longo do período estabelecido.

Esse cronograma oferece uma visão mais detalhada do fluxo de trabalho, permitindo compreender o progresso esperado em cada fase e o alinhamento entre as diferentes tarefas.

Além disso, funciona como um guia para orientar a execução do projeto, contribuindo para uma melhor organização, acompanhamento contínuo e cumprimento dos prazos definidos.

Figura 3 - Fluxograma



Fonte: Elaborado pelo autor.

3 RESULTADOS E DISCUSSÃO

De modo geral, os resultados obtidos nesta pesquisa demonstram que, embora a rede neural convolucional tenha conseguido identificar e segmentar parcialmente os grãos de areia presentes nas imagens analisadas, o desempenho do modelo ainda não pode ser considerado satisfatório em termos de precisão na contagem.

Observou-se que, apesar de a rede apresentar certo potencial para distinguir os contornos e as características visuais dos grãos, o processo de reconhecimento automático ainda apresenta falhas perceptíveis, especialmente em situações em que há sobreposição entre partículas, variação de iluminação durante a captura ou irregularidade no formato natural dos grãos. Esses elementos dificultam de maneira significativa a identificação correta dos limites entre as partículas, levando o modelo, em diversas ocasiões, a subcontar os grãos ou a confundir regiões ambíguas, o que compromete diretamente a qualidade das estimativas finais produzidas pela CNN.

A diferença significativa entre os valores obtidos pelo modelo e aqueles registrados pelo software ImageJ – Fiji indica que a abordagem proposta, na configuração atual, ainda não é suficientemente eficiente para substituir métodos tradicionais de análise granulométrica. Essa discrepância pode estar relacionada à combinação de diversos fatores já mencionados, como a quantidade e qualidade das imagens utilizadas no treinamento, a necessidade de ajustes mais adequados nos hiperparâmetros da rede, e a possível limitação do conjunto de dados em representar, de forma satisfatória, a diversidade dos grãos analisados. Esses aspectos podem ter

influenciado o desempenho geral do modelo, contribuindo para resultados menos precisos do que o esperado, mesmo quando a rede foi capaz de identificar parcialmente as estruturas presentes nas imagens.

Tabela 1 - Acurácia

	Rede Neural	ImageJ - Fiji	Erro (%)	Acurácia (%)
Imagem 01	54	434	87,6	12,4
Imagem 02	13	146	91,1	8,9
Imagem 03	41	179	77,1	22,9
Imagem 04	45	110	59,1	40,9
Imagem 05	77	140	45	55
Imagem 06	35	238	85,3	14,7
Imagem 07	105	247	57,5	42,5
Imagem 08	42	318	86,8	13,2
Imagem 09	26	391	93,3	6,7
Imagem 10	35	315	88,9	11,1
Imagem 11	65	215	69,8	30,2
Imagem 12	39	152	74,3	25,7

Fonte: Elaborado pelo autor.

Ao analisar os resultados apresentados na Tabela 1, verifica-se que a acurácia média do modelo de rede neural convolucional em relação ao método de referência (ImageJ–Fiji) foi de aproximadamente 23,7%, indicando uma discrepância considerável entre as estimativas da CNN e os valores obtidos pelo software tradicional. Esse desempenho evidencia que, embora o modelo tenha sido capaz de reconhecer parcialmente os padrões presentes nas imagens, sua capacidade de generalização ainda é limitada, especialmente em amostras com sobreposição de partículas ou variações de iluminação. Esses fatores afetam diretamente a qualidade da segmentação, resultando em subcontagens mais acentuadas e em uma menor correspondência com os valores reais, o que reforça a necessidade de abordagens mais avançadas para lidar com cenários complexos de textura e distribuição dos grãos.

Além disso, é importante considerar que o desenvolvimento de modelos baseados em aprendizado profundo requer um processo contínuo de refinamento, envolvendo não apenas o aumento do volume de dados de treino, mas também a aplicação de técnicas de pré-processamento e segmentação mais robustas. Nesse contexto, ajustes na arquitetura da rede, melhorias nos filtros de detecção e uma maior padronização das condições de captura podem contribuir para resultados mais consistentes. Dessa forma, embora os resultados obtidos até o momento não tenham alcançado

o nível de acurácia esperado, eles servem como um ponto de partida relevante para futuras melhorias e ajustes, reforçando o potencial da inteligência artificial como ferramenta de apoio à análise granulométrica.

Tabela 2 - Comparação dos Métodos

	Rede Neural	ImageJ - Fiji
Imagem 01	54	434
Imagem 02	13	146
Imagem 03	41	179
Imagem 04	45	110
Imagem 05	77	140
Imagem 06	35	238
Imagem 07	105	247
Imagem 08	42	318
Imagem 09	26	391
Imagem 10	35	315
Imagem 11	65	215
Imagem 12	39	152

Fonte: Elaborado pelo autor.


Os valores apresentados na coluna correspondente à Rede Neural referem-se aos resultados obtidos pelo modelo desenvolvido neste estudo, treinado especificamente para realizar a contagem automática das partículas presentes nas imagens. Já os valores exibidos na coluna do ImageJ-Fiji representam as medições realizadas pelo software de referência, amplamente utilizado em análises científicas de imagens.

Essa comparação permite avaliar de forma objetiva o desempenho do modelo proposto em relação a um método consolidado, oferecendo uma visão clara sobre a capacidade da rede neural em reproduzir resultados próximos aos obtidos por ferramentas tradicionais. Além disso, possibilita identificar não apenas os acertos do modelo em imagens nas quais a segmentação foi mais eficiente, mas também as limitações evidenciadas nos casos de maior discrepância, especialmente em situações envolvendo sobreposição de partículas, variações de iluminação ou contornos pouco definidos. Dessa forma, a análise conjunta das duas abordagens contribui para uma compreensão mais completa da eficácia do método automatizado e orienta ajustes futuros para aprimoramento da técnica.

Na Tabela 2 e na Figura 4, observa-se a comparação entre o método tradicional (ImageJ-Fiji) e a rede neural. Nota-se que a rede neural identificou menos partículas nas imagens, apresentando um desempenho inferior em relação ao método de referência. Essa diferença fica clara ao

analisar a quantidade de detecções realizadas por cada abordagem, evidenciando que o modelo de rede não conseguiu reconhecer todas as partículas presentes nas amostras da mesma forma que o software tradicional. Dessa maneira, a comparação mostra de forma consistente que o ImageJ-Fiji mantém uma maior precisão na contagem, enquanto a rede neural ainda demonstra limitações ao lidar com as características visuais das imagens analisadas.

Figura 4 - Comparação do Pior Desempenho




Fonte: Elaborado pelo autor.

Essa diferença torna-se ainda mais evidente na análise visual do pior caso, em que o ImageJ foi capaz de detectar um número significativamente maior de elementos, enquanto a rede neural exibiu uma segmentação mais limitada e, em alguns trechos, incompleta. Essa limitação pode estar associada a fatores como sobreposição dos grãos, variações de iluminação ou contornos pouco definidos, que dificultam o reconhecimento automático. A análise conjunta entre os valores numéricos e a comparação visual permite compreender com mais clareza o comportamento do modelo diante de diferentes condições, evidenciando os cenários em que seu desempenho é mais crítico e reforçando a importância de aprimoramentos no pré-processamento e no treinamento da rede.

Na análise do melhor desempenho, na Tabela 2 e na Figura 5 observa-se o comportamento oposto ao do caso anterior. Nessa situação, a

rede neural apresentou resultados mais próximos aos obtidos pelo método tradicional, conseguindo identificar a maior parte das partículas presentes na imagem. Visualmente, nota-se uma boa correspondência entre as detecções, indicando que, em condições mais favoráveis, o modelo é capaz de realizar uma segmentação satisfatória e próxima à do ImageJ-Fiji. Esse desempenho mais elevado sugere que, quando a imagem apresenta menor sobreposição, boa definição dos contornos e iluminação adequada, a CNN consegue reconhecer os padrões com maior precisão, demonstrando que seu potencial pode ser melhor explorado mediante ajustes no treinamento e padronização das condições de entrada.

Figura 5 - Comparação do Melhor Desempenho



Fonte: Elaborado pelo autor.

Ao analisar os dados apresentados na Tabela 2, observa-se que o modelo de rede neural apresentou valores consistentemente inferiores aos obtidos pelo método tradicional. Essa discrepância pode estar associada a limitações no conjunto de treinamento, que pode não ter sido suficientemente amplo ou representativo, e também à baixa diferenciação entre grãos muito pequenos ou sobrepostos, o que dificulta o reconhecimento adequado durante a inferência.

Além disso, o processo de pré-processamento das imagens e a qualidade das amostras capturadas podem ter influenciado diretamente os resultados. Mesmo com o uso de um microscópio digital e do iPhone 12,

pequenas variações de iluminação, foco e contraste impactam o desempenho da CNN, que é sensível a ruídos e imperfeições visuais.

Ao comparar os resultados deste trabalho com o estudo Borges et al. (2015), observa-se que o método baseado no software ImageJ–Fiji demonstrou desempenho superior na segmentação e contagem de partículas, com maior consistência e precisão estatística. No referido estudo, a utilização de técnicas de binarização e ajuste de limiar proporcionou uma identificação mais eficiente dos grãos, reduzindo a ocorrência de falsos positivos e negativos. Em contraste, o modelo de rede neural aqui desenvolvido ainda apresentou dificuldades em generalizar corretamente padrões granulométricos mais complexos, evidenciando que, embora a inteligência artificial possua grande potencial, o ImageJ ainda se mostra mais consolidado para análises precisas em contextos laboratoriais.

Embora o desempenho do modelo não tenha atingido o nível esperado, os testes realizados demonstram o potencial da abordagem e indicam caminhos de aprimoramento, como o aumento do número de imagens rotuladas, o ajuste de hiperparâmetros da rede e a utilização de arquiteturas mais profundas ou especializadas em segmentação, como a U-Net.

Em comparação direta com o trabalho Santos et al. (2022), desenvolvido na Universidade Federal do Amazonas, nota-se uma diferença marcante quanto à eficácia do método de análise de imagem. Enquanto Santos obteve resultados consistentes utilizando o software ImageJ para caracterização morfométrica de partículas de areia, este estudo, ao empregar uma rede neural convolucional para contagem automática de grãos, apresentou valores inferiores e maior variabilidade. Tal contraste evidencia que, embora a análise digital de imagens convencionais já esteja consolidada como uma técnica confiável e reproduzível, a aplicação de aprendizado profundo ainda demanda avanços significativos especialmente no que se refere ao aumento do conjunto de treinamento e à otimização da arquitetura da rede para atingir precisão equivalente aos métodos tradicionais.

Dessa forma, os resultados reforçam a importância da etapa de calibração e treinamento no desenvolvimento de modelos de aprendizado profundo aplicados à análise de materiais, evidenciando que o método, na forma atual, ainda requer otimizações para alcançar resultados confiáveis e reproduzíveis.

4 CONCLUSÃO

Os resultados obtidos neste estudo demonstraram que, embora o uso de redes neurais convolucionais aplicadas à análise granulométrica de areia apresente potencial teórico para automatizar o processo, o modelo desenvolvido ainda não alcançou desempenho satisfatório em termos de precisão e contagem das partículas.

As diferenças significativas entre os valores obtidos pelo modelo e os do método tradicional (ImageJ) evidenciam limitações no conjunto de dados, na arquitetura da rede e no processo de pré-processamento das imagens. Apesar disso, o trabalho reforça que a aplicação de técnicas de aprendizado profundo na análise granulométrica é um campo promissor, que pode se beneficiar de aprimoramentos metodológicos e computacionais.

Ao longo do trabalho, foram explorados desde os fundamentos da granulometria e das técnicas de visão computacional até o desenvolvimento e treinamento do modelo baseado em CNN, incluindo etapas de captura, tratamento e análise das imagens. Esse percurso permitiu compreender os desafios envolvidos no uso de inteligência artificial para esse tipo de tarefa, especialmente em contextos onde fatores como sobreposição, iluminação e definição dos contornos afetam diretamente o desempenho do modelo.

A principal contribuição deste estudo consiste na demonstração prática de uma abordagem computacional baseada em redes neurais convolucionais para a análise de grãos de areia, integrando ferramentas como OpenCV, TensorFlow/Keras e ImageJ. Dessa forma, o trabalho serve como base para estudos futuros voltados ao uso da visão computacional em análises de materiais granulares.

Para aprimorar os resultados obtidos, recomenda-se ampliar o conjunto de imagens utilizadas no treinamento, padronizar as condições de captura como iluminação, contraste e foco e empregar arquiteturas de rede mais robustas, como a U-Net ou a ResNet. Tais aprimoramentos podem tornar o método mais preciso, estável e aplicável em diferentes contextos de análise granulométrica.

REFERÊNCIAS

BORGES, G. et al. **Análise granulométrica de sedimentos arenosos de praias através de imagens digitais. descrição de um protocolo de mensuração de partículas no software imagej-fiji.** Brazilian Journal of

Aquatic Science and Technology, 2015, v. 19, n. 2, p. 23–32.

HOMEM, W. L.; UFES, P. **Apostila de machine learning**. PET Engenharia Mecânica, UFES, 2020.

JANIESCH, C.; ZSCHECH, P.; HEINRICH, K. **Machine learning and deep learning**. Electronic markets, 2021, Springer, v. 31, n. 3, p. 685–695.

MASSAD, F. **Mecânica dos solos experimental**. [S.l.]: Oficina de Textos, 2016.

MCKINNEY, W. **Python para análise de dados: Tratamento de dados com Pandas, NumPy e IPython**. [S.l.]: Novatec Editora, 2018.

MORAIS, A. L. S. D. et al. **Análise granulométrica: Uma revisão bibliográfica**. Journal of Exact Sciences, 2021, v. 27, n. 1.

RODRIGUES, P. H. B.; LASTHAUS, A. **Técnicas de visão computacional para classificação de peças**. Revista Mackenzie de Engenharia e Computação, 2021, v. 21, n. 1, p. 144–167.

SANTOS, W. Z. d. et al. **O uso da análise de imagem digital na disciplina de operações unitárias para caracterização de partículas de areia**. 2022, Brasil.

SUGUIO, K. **Geologia sedimentar**. [S.l.]: Editora Blucher, 2003.