

FGSet: Conectando Conjuntos de Dados Simulados, Controlados e do Mundo Real para Análise de Grãos de Fertilizantes

1st Nelson de Faria Traversi
Grupo de Automação Inteligente e Robótica
Universidade Federal do Rio Grande
Rio Grande, Brasil
20kfurg@gmail.com

2nd Paulo Jefferson Dias de Oliveira Evald
Grupo de Sistemas Inteligentes e Controle
Universidade Federal de Pelotas
Pelotas, Brasil
paulo.evald@ufpel.edu.br

3rd Silvia Silva da Costa Botelho
Grupo de Automação Inteligente e Robótica
Universidade Federal do Rio Grande
Rio Grande, Brasil
silviacb@furg.br

Abstract—A falta de conjuntos de dados bem anotados tem dificultado significativamente o progresso na análise automatizada de fertilizantes. Este artigo apresenta três conjuntos de dados de grãos de fertilizantes, projetados para desenvolver e validar sistemas de detecção e classificação desse material, com foco no uso de ambientes simulados e controlados para melhorar o desempenho dos modelos com dados reais limitados. O primeiro conjunto de dados é sintético, gerado por meio de um simulador que cria uma representação vista de cima de amostras de fertilizante, combinando imagens de grãos individuais de fertilizante. O segundo conjunto de dados é coletado em um ambiente controlado sob condições ideais, porém realistas, oferecendo um equilíbrio entre precisão experimental e relevância prática. Finalmente, o terceiro conjunto de dados captura condições agrícolas reais, coletadas em ambientes de campo desafiadores para refletir as complexidades inerentes à aquisição de dados agrícolas. Os resultados mostram que o conjunto de dados misto apresenta vantagens em relação ao conjunto de dados usando imagens exclusivamente de ambientes industriais.

Index Terms—*Datasets, Segmentação de imagens, Indústria de fertilizantes, Segmentação de grãos.*

I. INTRODUÇÃO

A crescente demanda por aumento da produção de alimentos tem colocado uma imensa pressão sobre a indústria agrícola para melhorar a produtividade e otimizar as operações [1], [2]. Os fertilizantes são um componente fundamental para o aumento da produtividade das culturas, e sua eficiência é influenciada não apenas pela composição química, mas também por suas propriedades físicas, como tamanho e forma das partículas [3]. Os grãos de fertilizante são geralmente pequenos, com diâmetros que variam de 4,75 mm a 1 mm, tornando a análise precisa dessas propriedades crucial para otimizar tanto a produção do fertilizante quanto sua aplicação no campo [4]. Este artigo aborda os desafios da análise

de partículas de fertilizantes utilizando visão computacional, introduzindo uma abordagem de treinamento em múltiplas etapas, apoiada por três conjuntos de dados distintos criados para esse propósito.

Os métodos tradicionais de avaliação de fertilizantes, como a peneiração e a medição manual, são demorados e trabalhosos, dificultando a obtenção de *feedback* em tempo real, essencial para otimizar a eficiência operacional. Em contraste, a visão computacional oferece uma alternativa transformadora, permitindo a aquisição automatizada e em tempo real de dados diretamente das linhas de produção [5]. No entanto, a falta de conjuntos de dados públicos e bem anotados voltados para a análise de partículas de fertilizantes representa uma barreira significativa para a adoção dessas tecnologias. Modelos de aprendizado profundo requerem dados extensivos e diversificados para se generalizarem de forma eficaz [6], e a escassez de conjuntos de dados adequados cria desafios para o desenvolvimento, validação e *benchmarking* de algoritmos de segmentação [7]. Para a análise de fertilizantes, onde a caracterização precisa do tamanho, forma e distribuição das partículas é fundamental [8], essa lacuna de dados limita a confiabilidade e a aplicabilidade dos sistemas de visão computacional.

A obtenção de imagens de alta qualidade em ambientes industriais dificulta ainda mais a adoção da visão computacional. A linha de produção apresenta desafios únicos, como o movimento constante das correias transportadoras, que causa desfoque de movimento [9], [10], e a presença de partículas de poeira liberadas durante o processamento dos grãos, prejudicando a visibilidade e as condições de iluminação. Além disso, o ambiente industrial frequentemente limita o acesso, tornando difícil a captura de imagens ideais para uma segmentação precisa. Essas limitações exigem abordagens inovadoras para o treinamento de modelos e aquisição de imagens. Neste estudo,

propomos o uso de conjuntos de dados mistos para mitigar esses desafios. Este estudo apresenta três conjuntos de dados distintos projetados para enfrentar esses desafios (conjunto de dados virtuais, conjunto de dados em ambiente controlado e conjunto de dados em ambiente industrial) e demonstra as vantagens em utilizar conjuntos de dados mistos em relação a um conjunto de dados exclusivamente reais.

Além disso, sabe-se que a segmentação, especialmente os métodos baseados em bordas, desempenha um papel fundamental na análise de fertilizantes. A segmentação precisa permite a identificação e medição exata das partículas de fertilizante, essenciais para avaliar suas propriedades físicas. As técnicas de detecção de bordas são eficazes para separar partículas de fundos complexos, aumentando a precisão das análises subsequentes [11]. Portanto, esta pesquisa discute uma abordagem que aproveita as forças complementares dos ambientes simulados e controlados para enfrentar a escassez de conjuntos de dados reais e as complexidades da captura de imagens industriais. Nosso objetivo é melhorar o desempenho em imagens do mundo real treinando modelos em conjuntos de dados sintéticos e ajustando-os posteriormente com dados controlados, mesmo com dados reais limitados. Essa abordagem preenche a lacuna entre condições simuladas e reais, proporcionando um desempenho robusto de segmentação em cenários diversos. Propomos uma abordagem de segmentação baseada em classificação densa com redes profundas usando esses conjuntos de dados, equilibrando o uso de cada conjunto durante diferentes etapas de treinamento. Esta metodologia explora balanços quantitativos de amostras de treinamento, estabelecendo diretrizes para a criação de conjuntos de dados em aplicações semelhantes. Ao pré-treinar em conjuntos de dados sintéticos e controlados e ajustar com dados reais, demonstramos melhorias significativas no desempenho para aplicações reais onde a coleta de dados é limitada. Assim, este trabalho aborda uma lacuna crítica na disponibilidade de recursos de dados, abrindo caminho para métodos avançados de controle de qualidade em tempo real que podem melhorar os processos de produção de fertilizantes e contribuir para a eficiência agrícola global e a segurança alimentar.

II. METODOLOGIA PARA CONSTRUÇÃO DE CONJUNTOS DE DADOS DE IMAGENS DE FERTILIZANTES

Esta seção descreve a metodologia abrangente para a construção dos três conjuntos de dados distintos.

Para o conjunto de dados virtual, grãos individuais de fertilizante de diversos tamanhos foram medidos com um paquímetro e pesados para garantir uma representação precisa. Cada grão foi fotografado em uma superfície branca usando uma câmera estabilizada posicionada a 10 cm acima da amostra. Um simulador foi então empregado para criar imagens compostas, organizando aleatoriamente as imagens dos grãos em uma grade de 224x224 pixels. Além da imagem RGB composta, o simulador gerou uma imagem correspondente contendo apenas as bordas dos grãos. Embora essa abordagem tenha permitido a criação rápida de inúmeras imagens, a falta

de realismo do conjunto de dados virtual exigiu o desenvolvimento de conjuntos de dados mais avançados e com maior fidelidade.

Para o conjunto de dados do ambiente controlado, os grãos de fertilizante foram dispostos uniformemente em um recipiente com raio de 15 cm. Para garantir uma iluminação consistente, uma luz de anel foi posicionada dentro do recipiente para fornecer iluminação difusa, enquanto uma tampa com abertura central foi utilizada para bloquear a luz externa. A câmera foi estabilizada a 10 cm acima da superfície dos grãos para capturar as imagens. Todas as imagens foram convertidas para escala de cinza para manter a consistência entre os conjuntos de dados. Essa etapa minimizou o impacto do excesso de iluminação no ambiente controlado, que alterava ligeiramente as cores originais, facilitando uma comparação mais precisa entre os conjuntos de dados fabril e virtual. Embora pequenas diferenças de intensidade tenham permanecido, as características críticas para a segmentação—bordas definidas e contraste—foram preservadas. Cada imagem no conjunto de dados controlado passou por uma anotação manual para a criação das máscaras de segmentação *ground truth*. Esse processo exigiu esforço meticuloso e várias horas por imagem.

O conjunto de dados do ambiente fabril foi gerado a partir da captura de imagens durante o processo de produção, especificamente após a secagem dos grãos de fertilizante, mas antes de serem peneirados. Nesta etapa, os tamanhos dos grãos não seguem um padrão padronizado. Como não havia infraestrutura disponível para fotografia aérea, as imagens foram capturadas de um ângulo lateral à medida que os grãos saíam da esteira transportadora em queda livre. Esse ambiente apresentou desafios únicos, incluindo altos níveis de poeira que afetaram as condições de iluminação. Como resultado, a luz de anel não foi utilizada, e o flash embutido da câmera forneceu a iluminação necessária. A câmera foi posicionada a 30 cm dos grãos em queda para garantir clareza e reduzir o risco de danos ao equipamento. Assim como no conjunto de dados controlado, as imagens da fábrica foram segmentadas manualmente para criar as anotações *ground truth*.

Para anotar os conjuntos de dados, focamos na melhoria das bordas dos grãos de fertilizante, criando imagens que exibem apenas os contornos dos grãos. Foram utilizadas duas abordagens para alcançar esse objetivo: a geração automatizada de bordas por meio de um simulador próprio e o processo de anotação manual.

Além disso, técnicas de aumento de dados foram aplicadas para aumentar o número de imagens nos conjuntos de dados sem distorcer as bordas dos grãos, com o objetivo de melhorar a robustez e a capacidade de generalização dos modelos de aprendizado de máquina [12]. Essas técnicas permitiram que os modelos fossem treinados em um conjunto mais diversificado de imagens, ajudando a evitar o sobre-ajuste. Todas as técnicas de aumento foram aplicadas uniformemente tanto às imagens originais quanto às suas máscaras de bordas correspondentes. As seguintes técnicas foram empregadas: recorte aleatório, redimensionamento, rotação, espelhamento, ajuste de cor e injeção de ruídos.

III. ESTUDO DE CASO

Os três conjuntos de dados – virtual, ambiente controlado e fábrica – possuem pontos fortes e desafios únicos que impactam sua utilidade no treinamento de modelos de aprendizado de máquina para segmentação de grãos. Suas características complementares destacam seu potencial para uso individual ou abordagens combinadas, dependendo da aplicação desejada. Esses conjuntos de dados são apresentados a seguir.

Conjunto de dados virtuais: esse conjunto, gerado por um simulador de superfícies, oferece flexibilidade e escalabilidade inigualáveis. Sua capacidade de gerar um número infinito de imagens ajustando a composição dos grãos, posições e padrões de sobreposição faz dele um recurso útil para pré-treinamento de modelos. No entanto, também apresenta características específicas que merecem destaque:

- Pontos fortes:
 - *Variabilidade infinita:* o simulador pode produzir inúmeras imagens, garantindo cobertura de diversos cenários, desde grãos espaçados até densamente empilhados;
 - *Controle sobre a composição:* controle preciso sobre as proporções dos grãos (ex.: categorias grossas, finas ou ideais) permite cenários de treinamento direcionados;
 - *Custo-efetividade:* elimina a necessidade de coleta ou anotação manual de dados, reduzindo custos operacionais.
- Desafios:
 - *Risco de sobre-ajuste:* apesar da variabilidade, o conjunto de dados virtual é limitado pelas imagens de grãos originais usadas na simulação, levando a um possível sobre-ajuste;
 - *Realismo limitado:* a natureza simulada pode não capturar completamente as complexidades de iluminação e ruído do mundo real.

Conjunto de dados do ambiente controlado: esse conjunto busca equilibrar realismo e qualidade, tornando-se ideal para refinamento de modelos pré-treinados. Como as imagens são capturadas sob condições controladas de iluminação, proporciona imagens de alta qualidade que destacam contornos e contrastes dos grãos.

Conjunto de dados do ambiente fabril: esse conjunto industrial representa as condições reais para as quais o modelo será implantado, mas sua complexidade destaca a importância do pré-treinamento com conjuntos mais limpos como o virtual e o controlado.

Cada conjunto desempenha um papel crítico no *pipeline* de aprendizado de máquina, e seu uso combinado pode mitigar limitações individuais. Assim, destaca-se:

- *Pré-treinamento com o conjunto de dados virtuais:* a abundância de dados garante uma compreensão ampla das formas e distribuições dos grãos;

- *Ajuste fino com o conjunto de dados em ambiente controlado:* aproveita anotações de alta qualidade e iluminação controlada para refinar a detecção de bordas;
- *Teste e validação com o conjunto de dados em ambiente fabril:* serve como referência para avaliar o desempenho do modelo em cenários reais.

Essa abordagem progressiva garante que os modelos estejam bem preparados e possam generalizar efetivamente para condições do mundo real. A seguir são detalhados os conjuntos de dados, discutindo mais detalhes e suas particularidades.

A. Conjunto de Dados Virtual

Este conjunto de dados consiste em mais de 4000 imagens únicas, geradas usando um simulador de superfícies. Essas imagens incorporam fotos de 70 grãos de várias categorias. Embora o conjunto de dados inclua 4000 imagens, a natureza simulada permite a geração de um número ilimitado de imagens, ajustando a composição, posição e padrões de sobreposição dos grãos, garantindo variação contínua. As imagens são compostas por até 3000 grãos por imagem para garantir a cobertura total do fundo. O conjunto de dados é dividido em três categorias de grãos: 30% das imagens são dominadas por grãos da categoria grossa, 30% apresentam a maioria dos grãos da categoria fina e os 40% restantes das imagens consistem principalmente de grãos da categoria de tamanho ideal. A Figura 1 apresenta um exemplo de uma imagem deste conjunto de dados virtual, juntamente com sua máscara correspondente e na Fig. 2.




Fig. 1. Imagem original do conjunto de dados virtuais.




Fig. 2. Máscara da imagem original do conjunto de dados virtuais.

B. Conjunto de dados do ambiente controlado

Este conjunto de dados foi gerado a partir de 20 imagens de alta resolução, cada uma com dimensões de 4000x3000 pixels, que foram posteriormente aumentadas para criar um total de 1200 imagens, redimensionadas para 224x224 pixels. As técnicas de aumento de dados foram aplicadas para introduzir variabilidade e aumentar a robustez do conjunto de dados. Das 20 imagens originais, metade foi composta principalmente por grãos da categoria de tamanho ideal, enquanto as 10 imagens restantes continham uma mistura de grãos de tamanhos variados. Essa diversidade garante que o conjunto de dados cubra uma ampla gama de configurações de grãos, oferecendo dados valiosos para treinamento e teste de modelos. A Fig. 3 ilustra um exemplo de imagem do conjunto de dados do ambiente controlado, juntamente com sua máscara de segmentação correspondente na Fig. 4.




Fig. 3. Imagem original do conjunto de dados do ambiente controlado.




Fig. 4. Máscara da imagem original do conjunto de dados do ambiente controlado.

C. Conjunto de dados do ambiente industrial

O conjunto de dados do ambiente industrial consiste em 1200 imagens geradas a partir das 20 melhores imagens segmentadas manualmente capturadas em uma fábrica. Essas imagens foram tiradas em condições desafiadoras, onde o posicionamento lateral da câmera criou dificuldades para segmentar com precisão os grãos localizados na parte superior esquerda das imagens. O conjunto de dados foi organizado em categorias com base na área onde os recortes aleatórios foram

aplicados para abordar esse problema, com uma categoria separada para imagens afetadas por esse desafio de segmentação. Essa categorização garante que o conjunto de dados forneça uma ampla variedade de cenários, desde imagens bem segmentadas até aquelas que representam desafios mais complexos em ambientes industriais reais. A Fig. 5 apresenta um exemplo de uma imagem do conjunto de dados do ambiente industrial juntamente com sua máscara correspondente na Fig. 6.



Fig. 5. Imagem original do conjunto de dados do ambiente fabril.




Fig. 6. Máscara da imagem original do conjunto de dados do ambiente fabril.

D. Comparação de brilho, contraste e equilíbrio de cores

Uma análise detalhada de brilho, contraste e equilíbrio de cores foi conduzida para avaliar a consistência visual e a qualidade dos três conjuntos de dados. Essas características são essenciais para garantir a uniformidade entre os conjuntos de dados, o que é crítico para o treinamento de modelos de aprendizado de máquina [13]. A Fig. 7 mostra os resultados dessas comparações. Esses resultados destacam as diferenças na composição e variabilidade entre os três conjuntos de dados, fornecendo *insights* sobre como cada conjunto pode influenciar o desempenho dos modelos de aprendizado de máquina.

O conjunto de dados virtual, gerado usando um simulador de superfícies, apresenta a maior variabilidade em termos de tamanhos de grãos e número de grãos por imagem. Essa variabilidade reflete a natureza flexível e personalizável da geração de dados simulados, permitindo que uma ampla gama de cenários seja representada ajustando o número e o tamanho dos grãos em cada imagem. Já, o conjunto de dados do ambiente controlado oferece consistência, o que é útil para experimentos que exigem previsibilidade, enquanto o conjunto fabril introduz a variabilidade inerente ao mundo real, o que é essencial para criar modelos que possam ser aplicados em aplicações práticas.

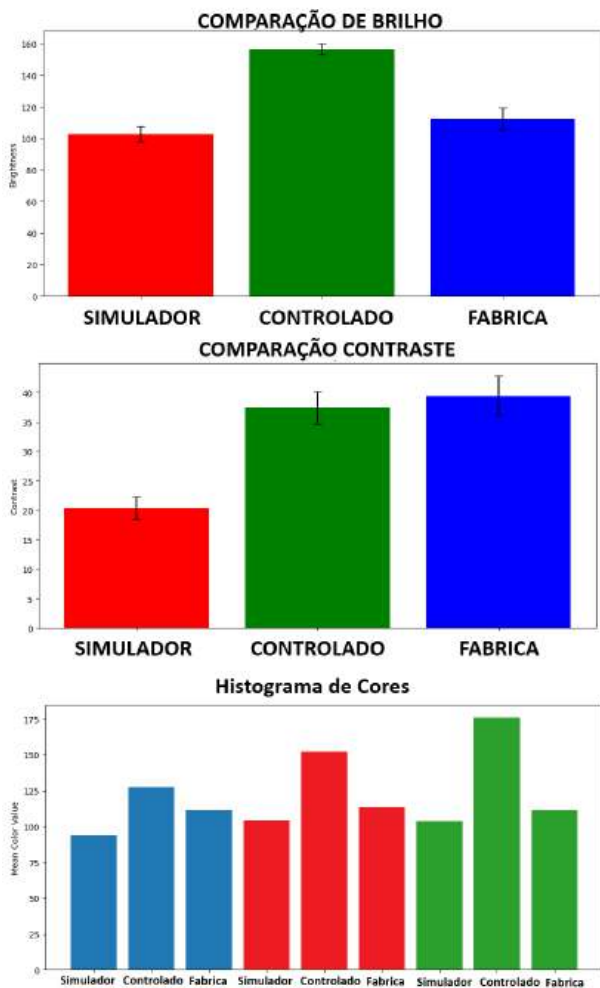


Fig. 7. Comparação de brilho, contraste e histograma de cores entre os conjuntos de dados simulado, ambiente controlado e fábrica.

O conjunto virtual, com seu alto grau de flexibilidade, serve como um recurso valioso para gerar grandes quantidades de dados e explorar uma gama mais ampla de cenários. Compreender a distribuição do tamanho dos grãos e o número de grãos por imagem é crucial para desenvolver modelos robustos de aprendizado de máquina, pois afeta a capacidade do modelo de lidar com diferentes tamanhos e densidades de grãos, bem como sua capacidade de generalizar em diversas condições do mundo real. Entretanto, a combinação dos conjuntos de dados potencializa beneficemente o resultado final do conjunto de dados mistos, utilizado para validação posteriormente.

IV. VALIDAÇÃO: SEGMENTAÇÃO DE GRÃOS REAIS DE NPK EM AMBIENTE FABRIL

A hipótese deste trabalho é que ao combinar diferentes conjuntos de dados (sintéticos e controlados), torna-se possível gerar aprendizado suficiente para preencher a lacuna deixada pela disponibilidade limitada de amostras de imagens anotadas da fábrica. Essa abordagem aborda os desafios da segmentação de grãos de fertilizante em condições industriais reais, onde

fatores como variação de iluminação, poeira e movimento dos grãos complicam a segmentação precisa. Nesta seção, exploramos o papel desses conjuntos de dados no processo de aprendizado para tarefas de segmentação usando um modelo U-Net. O objetivo não é validar o desempenho do modelo U-Net em si [14], mas avaliar como os diferentes conjuntos de dados contribuem para a capacidade do modelo de aprender e generalizar de forma eficaz. Diante dos desafios de capturar imagens do mundo real em ambientes industriais, este estudo enfatiza a importância de usar dados mais acessíveis, como imagens simuladas e de ambientes controlados, como alternativas às imagens de fábrica.

O modelo U-Net foi avaliado em vários cenários experimentais para determinar a importância de diferentes conjuntos de dados, tanto individualmente quanto em combinação de conjuntos de dados. Esses experimentos foram projetados para avaliar a capacidade do modelo de generalizar a partir de conjuntos de dados sintéticos e controlados para condições reais de fábrica. Os experimentos também exploraram se os conjuntos de dados sintéticos e controlados poderiam substituir os dados reais da fábrica para treinamento quando esses dados são limitados. Os conjuntos de dados utilizados nos experimentos incluíram: 3000 imagens sintéticas, 1200 imagens capturadas em condições ideais de um ambiente controlado e 400 imagens obtidas em ambiente fabril, sendo 200 imagens alocadas para ajuste fino e outras 200 usadas exclusivamente para teste.

Os experimentos foram categorizados nos seguintes ambientes:

- 1) **Ambiente A - Treinamento apenas com dados da fábrica:** o modelo foi treinado diretamente nas 200 imagens reais da fábrica usadas para ajuste fino. Isso serve como uma linha de base para avaliar o desempenho do modelo com dados reais limitados, sem qualquer pré-treinamento;
- 2) **Ambiente B - Transferência de aprendizado do ImageNet:** o modelo foi inicializado com pesos pré-treinados no ImageNet e testado diretamente nas 200 imagens reais da fábrica sem treinamento adicional. Isso testa se os recursos aprendidos de um conjunto de dados amplo podem ser transferidos para a tarefa de segmentação;
- 3) **Ambiente C - Generalização virtual-para-real:** treinamento com o conjunto de dados virtual (3000 imagens) e teste com 200 imagens reais da fábrica. Isso avalia a capacidade do modelo de generalizar a partir de dados sintéticos para condições reais.
- 4) **Ambiente D - Generalização controlada-para-real:** treinamento com o conjunto de dados do ambiente controlado (1200 imagens) e teste com 200 imagens reais da fábrica. Isso testa a eficácia dos dados controlados em replicar condições do mundo real;
- 5) **Ambiente E - Pré-treinamento virtual com ajuste fino:** treinamento com o conjunto de dados virtual (3000 imagens), seguido de ajuste fino nas 200 imagens reais da fábrica e teste nas 200 imagens reais da fábrica.

Isso explora a utilidade do pré-treinamento com dados sintéticos para compensar a escassez de dados reais;

- 6) **Ambiente F: Pré-treinamento controlado com ajuste fino:** treinamento com o conjunto de dados do ambiente controlado (1200 imagens), seguido de ajuste fino nas 200 imagens reais da fábrica e teste nas 200 imagens reais da fábrica. Isso avalia se os dados controlados superam os dados sintéticos para ajuste fino;
- 7) **Ambiente G - Generalização mista-para-real:** treinamento com uma combinação dos conjuntos de dados virtual (3000 imagens) e controlado (1200 imagens), e teste com as 200 imagens reais da fábrica. Isso testa se a combinação dos conjuntos melhora a generalização para condições reais;
- 8) **Ambiente H - Pré-treinamento misto com ajuste fino:** treinamento com uma mistura dos conjuntos de dados virtual (3000 imagens) e controlado (1200 imagens), seguido de ajuste fino nas 200 imagens reais da fábrica e teste nas 200 imagens reais da fábrica. Isso avalia se a combinação dos conjuntos melhora o desempenho no ajuste fino.

Os seguintes parâmetros foram mantidos constantes em todos os ambientes:

- **Otimizador:** Adam, com taxa de aprendizado de 1×10^{-3} ;
- **Função de perda:** *Dice Loss*, selecionada por sua eficácia em lidar com o desequilíbrio de classes em tarefas de segmentação;
- **Métrica de avaliação:** *Intersection over Union* (IoU);
- **Tamanho do lote:** 8, equilibrando eficiência computacional e estabilidade do modelo;
- **Número máximo de épocas:** 80, com parada antecipada se a perda de validação não melhorar por 10 épocas consecutivas;
- **Aumento de dados:** Incluiu rotações, espelhamentos e recorte aleatório para melhorar a generalização do modelo.

A. Resultados da Validação

O desempenho do modelo U-Net foi avaliado em um conjunto de teste de 200 imagens reais da fábrica. As perdas de validação *Dice* para cada ambiente estão resumidas abaixo.

A perda *Dice* de validação no ambiente A foi 0,72. O treinamento direto nas 200 imagens reais resultou em um desempenho subótimo, destacando as limitações do uso de dados limitados sem pré-treinamento. Já a perda *Dice* de validação no ambiente B foi de 0,50. O uso de pesos pré-treinados do ImageNet sem treinamento específico produziu o menor desempenho, mostrando que recursos genéricos são insuficientes para essa tarefa.

A perda *Dice* de validação no ambiente C foi 0,77. Este ambiente apresentou uma capacidade limitada de generalização, pois o modelo treinado apenas com dados sintéticos teve dificuldades com as condições reais. Por outro lado, a perda *Dice* de validação no ambiente D foi 0,81. O treinamento com o conjunto de dados controlado resultou em melhor

desempenho do que o virtual, provavelmente devido à sua semelhança com as condições reais.

A perda *Dice* de validação no ambiente E foi 0,96. O pré-treinamento com dados sintéticos seguido de ajuste fino melhorou significativamente o desempenho, mostrando a utilidade desta estratégia. Já a perda *Dice* de validação no ambiente F foi 0,95. O pré-treinamento com dados controlados resultou em um desempenho forte, embora ligeiramente inferior ao pré-treinamento virtual.

A perda *Dice* de validação no ambiente G foi 0,83. O treinamento com uma combinação dos conjuntos de dados melhorou a generalização em comparação com os conjuntos individuais. Por fim, a perda *Dice* de validação no ambiente H foi 0,97. O ajuste fino após treinamento com dados mistos resultou no melhor desempenho, destacando os benefícios da combinação de conjuntos de dados. Portanto, a abordagem com uso dos três conjuntos de dados superou o uso de conjuntos de dados exclusivos em termos de desempenho. As seguintes inferências podem ser observadas dos conjuntos individuais:

- O conjunto de dados sintético, gerado por um simulador de superfícies, atende ao requisito de garantir controle preciso sobre variáveis como tamanho, formato e distribuição dos grãos. Essa abordagem permite extensos experimentos e ajustes finos dos modelos em um ambiente controlado e livre de ruído. No entanto, embora seja ideal para o treinamento inicial, o conjunto de dados sintético carece da variabilidade do mundo real, tornando-o menos eficaz para lidar com a imprevisibilidade dos cenários industriais;
- O conjunto de dados de ambiente controlado, capturado sob condições ideais, atende ao requisito de fornecer dados realistas, mantendo o controle sobre fatores ambientais como iluminação e ângulos da câmera. Esse conjunto atua como uma ponte entre os dados sintéticos e reais, introduzindo texturas e padrões mais realistas, minimizando o ruído. Apesar de seus benefícios, ele não replica completamente a complexidade e os desafios encontrados em ambientes industriais reais, o que pode levar a limitações na generalização do modelo;
- conjunto de dados real da fábrica atende ao requisito de representar condições operacionais reais, incluindo ruído e variabilidade inerentes, como poeira, iluminação irregular e movimentação dinâmica dos grãos. Este conjunto de dados fornece a representação mais autêntica do ambiente de aplicação, garantindo que modelos treinados ou ajustados com ele sejam mais adequados para implantação em cenários industriais. No entanto, a coleta e anotação de dados reais da fábrica são trabalhosas e custosas, e a variabilidade e o ruído inerentes podem exigir pré-processamento ou ajustes adicionais para alcançar o desempenho ideal.

V. CONCLUSÃO

Neste trabalho, o potencial do uso de dados mais facilmente disponíveis, como conjuntos de dados sintéticos e de ambi-

entes controlados, foi explorado e demonstrado a viabilidade da utilização desses dados em tarefas de segmentação de grãos de fertilizante, reduzindo a dependência de imagens obtidas exclusivamente em ambiente fabril. A confirmação dessa possibilidade é um avanço significativo para a melhoria desse setor, visto que há escassez de dados nessas aplicações. Para suprir tal déficit, introduzimos e avaliamos uma metodologia que envolve o uso de três conjuntos de dados distintos: um conjunto de dados sintético, um conjunto de dados de ambiente controlado e um conjunto de dados real de fábrica. De forma geral, a metodologia demonstra uma abordagem progressiva — da precisão sintética ao realismo controlado até a complexidade do mundo real — proporcionando valiosos *insights* sobre a adaptabilidade e o desempenho dos modelos de segmentação em diferentes condições. Os experimentos demonstraram que, embora os conjuntos de dados sintéticos e controlados desempenhem um papel crucial no pré-treinamento, os dados reais continuam sendo essenciais para alcançar alta precisão de segmentação. Modelos treinados exclusivamente no conjunto de dados sintético alcançaram resultados moderados (perda de *Dice* = 0.77), enquanto o conjunto de ambiente controlado obteve um desempenho superior (perda de *Dice* = 0.81). No entanto, as melhorias mais significativas foram observadas quando os conjuntos sintéticos ou controlados foram suplementados com ajuste fino em um pequeno conjunto de imagens reais da fábrica. O ajuste fino com apenas 200 imagens reais da fábrica, após o pré-treinamento no conjunto virtual, resultou em uma forte perda de *Dice* de 0.96, e um resultado semelhante foi alcançado quando o ajuste fino foi realizado após o pré-treinamento com o conjunto de ambiente controlado (perda de *Dice* = 0.95). Esses resultados ilustram que a combinação de dados sintéticos ou controlados com até mesmo uma quantidade limitada de dados reais pode melhorar significativamente o desempenho do modelo. Além disso, o treinamento com uma mistura de conjuntos de dados sintéticos e controlados, seguido de ajuste fino com dados reais da fábrica, obteve o melhor resultado (perda de *Dice* = 0.97), demonstrando a eficácia da combinação desses conjuntos de dados para melhorar a generalização. O treinamento exclusivamente com 200 imagens reais da fábrica resultou em uma perda de *Dice* de 0.72, ressaltando as limitações do uso isolado de pequenos conjuntos de dados reais. Adicionalmente, a transferência direta de aprendizado a partir do ImageNet produziu resultados insatisfatórios (perda de *Dice* = 0.50), destacando a importância dos dados específicos do domínio, mesmo que em quantidades limitadas. Portanto, pode-se afirmar que embora os conjuntos de dados sintéticos e controlados sejam recursos valiosos para pré-treinamento, eles não podem substituir completamente os dados do mundo real. No entanto, quando combinados com um pequeno conjunto de imagens reais, os conjuntos de dados sintéticos e controlados podem reduzir significativamente a dependência de grandes volumes de dados reais. Essa abordagem é particularmente benéfica para aplicações industriais onde a coleta de dados reais é difícil ou dispendiosa. Ao utilizar de forma eficaz os conjuntos de dados sintéticos e controlados, os modelos

de segmentação podem alcançar um desempenho robusto em condições desafiadoras do mundo real.

REFERENCES

- [1] K. Fuglie, M. Gautam, A. Goyal, and W. F. Maloney, *Harvesting prosperity: Technology and productivity growth in agriculture*. Washington, DC: World Bank Publications, 2019.
- [2] J. M. Dias, P. J. D. O. Ewald, R. T. Guthes, M. dos Anjos Duarte, P. L. J. Drews, and S. S. da Costa Botelho, “A non-invasive learning-based method for pipeline overhaul on fertilizer production plants,” in *48th Annual Conference of the IEEE Industrial Electronics Society (IECON)*. IEEE, 2022, pp. 1–6.
- [3] S. Foster and E. Custodio, “Groundwater resources and intensive agriculture in europe—can regulatory agencies cope with the threat to sustainability?” *Water Resources Management*, vol. 33, no. 6, pp. 2139–2151, 2019.
- [4] E. Perfect, Q. Xu, and D. L. Terry, “Improved parameterization of fertilizer particle size distribution,” *Journal of AOAC International*, vol. 81, no. 5, pp. 935–942, 1998.
- [5] H. Zhang, J. Mu, S. Liu, Z. Wang, G. Chu, and J. Wang, “Fertilizer sphericity measuring device based on equatorial and meridian circles,” *Information Processing in Agriculture*, vol. 8, no. 1, pp. 52–63, 2021.
- [6] C. Zhang, S. Bengio, M. Hardt, B. Recht, and O. Vinyals, “Understanding deep learning (still) requires rethinking generalization,” *Communications of the ACM*, vol. 64, no. 3, pp. 107–115, 2021.
- [7] S. Zeng, H. Zhang, Y. Chen, Z. Sheng, Z. Kang, and H. Li, “Swgan: A new algorithm of adhesive rice image segmentation based on improved generative adversarial networks,” *Computers and Electronics in Agriculture*, vol. 213, p. 108226, 2023.
- [8] X. Sun, L. Niu, H. Zhang, Q. Wang, W. Zhou, H. Tang, and J. Wang, “Exploring sustainable agriculture: Investigating the impact of controlled release fertilizer damage through bonded particle modeling,” *Journal of Cleaner Production*, vol. 468, p. 143095, 2024.
- [9] H. Zhang and J. Yang, “Intra-frame deblurring by leveraging inter-frame camera motion,” in *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2015, pp. 4036–4044.
- [10] A. N. Almustofa, Y. Nugraha, A. Sulasikin, I. D. Bhaswara, and J. I. Kanggrawan, “Exploration of image blur detection methods on globally blur images,” in *2022 10th International Conference on Information and Communication Technology (ICoICT)*. IEEE, 2022, pp. 275–280.
- [11] R. C. Gonzalez, *Digital image processing*. Pearson education india, 2009.
- [12] S. Yang, W. Xiao, M. Zhang, S. Guo, J. Zhao, and F. Shen, “Image data augmentation for deep learning: A survey,” 2023. [Online]. Available: <https://arxiv.org/abs/2204.08610>
- [13] S. M. Pizer, E. P. Amburn, J. D. Austin, R. Cromartie, A. Geselowitz, T. Greer, B. ter Haar Romeny, J. B. Zimmerman, and K. Zuiderveld, “Adaptive histogram equalization and its variations,” *Computer Vision, Graphics, and Image Processing*, vol. 39, no. 3, pp. 355–368, 1987.
- [14] O. Ronneberger, P. Fischer, and T. Brox, “U-net: Convolutional networks for biomedical image segmentation,” in *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015*, N. Navab, J. Hornegger, W. M. Wells, and A. F. Frangi, Eds. Cham: Springer International Publishing, 2015, pp. 234–241.