

# Uma abordagem de entrada mista para segmentação de grãos na indústria de fertilizantes usando redes neurais codificadoras-decodificadoras

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

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

3<sup>nd</sup> Silvia Silva da Costa Botelho  
*Grupo de Automação Inteligente e Robótica*  
*Universidade Federal do Rio Grande*  
Rio Grande, Brasil  
silviacb@furg.br

**Abstract**—O equilíbrio de nutrientes no solo é crucial para a produção de alimentos em larga escala. Para manter esse equilíbrio, os agricultores aplicam frequentemente fertilizantes orgânicos e sintéticos. Um fator crítico na qualidade do fertilizante é o tamanho dos grãos, pois ele determina a capacidade de penetração do fertilizante no solo. Tradicionalmente, o tamanho das partículas é avaliado por meio de peneiras, um processo demorado e ineficiente. Para enfrentar essas limitações, sistemas automatizados de análise de qualidade surgiram como soluções promissoras para a indústria de fertilizantes. Entre esses sistemas, os métodos de tomada de decisão baseados em visão computacional têm mostrado um potencial significativo. No entanto, a maioria dos algoritmos de segmentação existentes depende de técnicas de imagem digital que exigem fundos visíveis para criar contraste com os grãos. Além disso, métodos determinísticos carecem de generalização, frequentemente exigindo uma recalibração para cada aplicação específica. Para superar esses desafios, este artigo apresenta uma abordagem baseada em redes neurais, utilizando uma U-Net de dupla codificação para segmentação de grãos de fertilizante em uma superfície completamente coberta, onde o fundo é obscurecido e estão presentes grãos de diferentes tamanhos.

**Index Terms**—Redes neurais *encoder-decoder*, Segmentação de imagens, Indústria de fertilizantes, Segmentação de grãos.

## I. INTRODUÇÃO

A agricultura é vital para as economias nacionais [1] e para a subsistência da humanidade [2]. Um dos principais desafios globais é o crescimento populacional, que deve atingir 9 bilhões até o final do século [3], aumentando a pressão sobre a produção de alimentos [4], [5].

A transição para a agricultura de precisão pode mitigar os impactos ambientais. A agricultura tradicional aumenta a produção, mas contribui para problemas como o excesso de nitrogênio, eutrofização dos ecossistemas, emissões de gases de efeito estufa, perda de biodiversidade e esgotamento de

recursos hídricos [6]–[9]. Além disso, o uso prolongado de fertilizantes deteriora a qualidade do solo e reduz a produtividade das culturas [10]. A agricultura de precisão otimiza a aplicação de recursos para melhorar a eficiência e a sustentabilidade [11], mas a qualidade dos insumos permanece um fator crítico para o seu sucesso.

A abordagem convencional para avaliar a uniformidade dos grãos de fertilizante envolve o uso de peneiras mecânicas para analisar o tamanho das partículas. Embora eficaz, esse processo é notoriamente demorado. Além disso, grãos que excedem um tamanho específico precisam ser reprocessados para atender ao volume necessário para alcançar a solubilidade adequada [12]. Esse reprocessamento inevitavelmente aumenta o tempo e os custos de produção. Para enfrentar esse gargalo, soluções tecnológicas inovadoras, tais como métodos baseados em aprendizado de máquina, foram propostas para agilizar o processo.

Nesse contexto, técnicas de visão computacional podem ser empregadas para processar imagens capturadas por câmeras estrategicamente posicionadas na linha de produção. Essas técnicas permitem a inferência em tempo real do tamanho dos grãos e facilitam a geração de alertas para partículas superdimensionadas ou subdimensionadas em um lote. Os principais benefícios do uso do processamento de imagens digitais baseado em inteligência artificial incluem a rápida resposta desses sistemas de suporte à decisão e sua natureza não destrutiva [13], [14]. No entanto, tarefas como segmentação e classificação de objetos sobrepostos, identificação de objetos similares agrupados ou análise de objetos sem um fundo visível continuam sendo altamente desafiadoras. Os métodos determinísticos para segmentação de objetos, como Otsu [15], k-means [16] e Canny [17] dependem do contraste entre o objeto e o fundo para obter uma segmentação precisa. No caso dos grãos de fertilizante, as amostras geralmente estão com-

pletamente cobertas, com o fundo escurecido por uma grande quantidade de partículas. Esses métodos exigem calibração precisa para um tamanho específico de grão para obter resultados satisfatórios, mas tendem a ter um desempenho ruim quando aplicados a lotes contendo grãos de diferentes tamanhos. Por outro lado, a aplicação de inteligência artificial para segmentação de imagens experimentou um crescimento significativo na última década [18]–[23], impulsionada pelos avanços no poder de computação e na evolução das tecnologias de *big data*.

A visão computacional tem sido amplamente aplicada na produção de alimentos, incluindo a detecção de linhas de cultivo para aplicação de insumos de precisão e monitoramento do crescimento [24]–[33]. Algoritmos baseados em inteligência artificial também são empregados para prever o crescimento das culturas em diferentes condições de nutrientes, água e estratégias de fertilização [34]–[46]. No entanto, os modelos de aprendizado de máquina requerem grandes conjuntos de dados bem anotados para atingir um desempenho ideal, os quais muitas vezes são escassos. Este trabalho visa preencher essa lacuna, aproveitando técnicas de aprendizado de máquina adaptáveis a novos casos, enquanto integra métodos determinísticos que, apesar de exigirem calibração específica, demandam significativamente menos dados para funcionar de forma eficaz. Até onde sabemos, nosso grupo foi pioneiro nesta área, com estudos preliminares em [47]–[51].

Este estudo apresenta uma nova arquitetura de U-Net com entrada mista, projetada para melhorar a precisão da segmentação, aproveitando informações visuais complementares. O modelo proposto incorpora uma estrutura de codificação dupla, onde um codificador processa a imagem RGB original, enquanto o outro lida com uma versão segmentada obtida utilizando o operador de Prewitt. *Gates* de atenção são utilizados para facilitar o fluxo de informações entre os codificadores e o decodificador, permitindo a fusão eficaz das características extraídas. O desempenho da abordagem proposta é avaliado em comparação com uma U-Net padrão [49] e o modelo *Segment Anything Model* (SAM) [52], com foco especial na avaliação do número de grãos individuais detectados e seus tamanhos relativos.

## II. METODOLOGIA

A solução proposta para a segmentação de grãos de fertilizante envolve o uso de um modelo U-Net com codificação dupla. Essa arquitetura utiliza duas entradas: uma imagem RGB padrão e uma imagem segmentada, projetada para reforçar as capacidades de detecção de bordas da rede. As saídas dos dois codificadores são combinadas por meio de um *attention gate*, que aprimora o processo de segmentação para produzir uma imagem de saída refinada. O treinamento da U-Net de codificação dupla requer um conjunto de dados substancial. Para atender a essa necessidade, desenvolvemos três conjuntos de dados: o primeiro contém 1200 imagens simuladas com suas respectivas máscaras de segmentação, o segundo compreende 1200 imagens capturadas em um ambiente controlado com máscaras segmentadas manualmente, e o terceiro consiste



Fig. 1. Exemplo de superfície simulada RGB e sua máscara.

em 200 imagens coletadas de um ambiente fabril, utilizadas exclusivamente para testes.

### A. Conjuntos de Dados

Até onde sabemos, não há conjuntos de dados públicos de grãos de fertilizante. Portanto, construímos um conjunto de dados para este trabalho, que será disponibilizado gratuitamente.

Este trabalho utiliza três conjuntos de dados distintos: um conjunto de dados simulado, um conjunto de ambiente controlado e um conjunto de ambiente fabril real.

1) *Conjunto de Dados Virtual*: O conjunto de dados virtual foi gerado usando um simulador de superfícies que combina imagens individuais de grãos para criar superfícies compostas realistas. Este simulador utiliza uma biblioteca de 120 imagens distintas de grãos e as organiza em colagens, produzindo imagens RGB com uma resolução de 224x224 pixels. Além das imagens RGB, o simulador também gera as máscaras correspondentes, como mostrado na Figura 1.

Este conjunto de dados oferece anotações precisas de segmentação das bordas de cada grão presente na superfície, garantindo uma delimitação precisa. Ele fornece uma ampla variedade de amostras que capturam variações na distribuição do tamanho dos grãos, refletindo fielmente cenários do mundo real. Além disso, o conjunto de dados mantém a flexibilidade para ser adaptado a requisitos experimentais específicos, tornando-se um recurso valioso para estudos e aplicações baseadas em segmentação. No entanto, devido ao número limitado de amostras de grãos, o conjunto de dados está sujeito ao *overfitting*, o que pode impactar a capacidade de generalização dos modelos treinados nele.

2) *Conjunto de Dados de Ambiente Controlado*: O conjunto de dados de ambiente controlado foi desenvolvido para preencher a lacuna entre o conjunto de dados simulado e as condições do mundo real. Cada imagem foi capturada em condições ideais, com iluminação controlada e ausência de fatores de ruído comuns, como desfoque, poeira e inconsistências de iluminação. Esse ambiente permitiu a aquisição de imagens RGB de alta resolução, facilitando o processo de segmentação manual.

<sup>1</sup>Os conjuntos de dados estarão disponíveis publicamente quando o artigo for publicado.




Fig. 2. Exemplo de imagem RGB e segmentada no ambiente controlado.

No entanto, apesar da qualidade aprimorada da imagem, as anotações de segmentação foram feitas manualmente, tornando-as inerentemente menos precisas do que as geradas pelo simulador. O objetivo principal deste conjunto de dados é mitigar os problemas de *overfitting* observados no conjunto de dados simulado, fornecendo dados mais representativos, mesmo com uma qualidade de anotação ligeiramente inferior. Um exemplo deste conjunto de dados pode ser visto na Figura 2.

3) *Conjunto de Dados do Ambiente Fabril Real*: O conjunto de dados do ambiente fabril real foi criado usando imagens de alta resolução capturadas diretamente da linha de produção, oferecendo uma representação realista das condições operacionais industriais. Um total de 10 imagens, cada uma com resolução de 4000x3000 pixels, foram capturadas, como mostrado na Figura 3. Essas imagens retratam superfícies completamente cobertas com grãos de fertilizante de vários tamanhos e orientações, simulando cenários reais com grãos sobrepostos e obstruções de fundo.

Para gerar o *ground truth* para a segmentação, os contornos dos grãos em cada imagem de alta resolução foram desenhados manualmente, resultando em máscaras correspondentes, conforme ilustrado na Figura 4. No entanto, devido aos desafios associados à segmentação manual, certas partes das imagens ficaram sem anotações.

Para expandir o conjunto de dados, cada imagem de alta resolução foi manualmente recortada em seções menores de 900x900 pixels. Durante o processo de recorte, foram incluídas regiões sobrepostas para aumentar a diversidade do conjunto de dados, enquanto áreas sem anotações adequadas foram excluídas. Esse processo resultou em aproximadamente 200 imagens recortadas.

Esse conjunto de dados captura os desafios inerentes aos ambientes fabris reais, como sobreposição de grãos, distribuição não uniforme e variabilidade de tamanho. Essas características fazem dele um recurso valioso para testar a capacidade dos modelos de segmentação em generalizar para cenários reais.

### III. REDES DE SEGMENTAÇÃO

As redes de segmentação são um componente essencial das tarefas de visão computacional que exigem previsões



Fig. 3. Ambiente fabril de grãos.




Fig. 4. Máscara do ambiente fabril.

precisas a nível de pixel. Neste trabalho, empregamos dois modelos de segmentação: a U-Net e sua variação, a Dual U-Net. Ambas as arquiteturas foram projetadas para aproveitar estruturas de codificação-decodificação com conexões de salto (*skip connections*) para preservar os detalhes espaciais durante a segmentação.

Além disso, exploramos o atual estado da arte em segmentação, o modelo *Segment Anything Model* (SAM). Desenvolvido pela Meta AI, o SAM introduz uma estrutura versátil baseada em *prompts* para segmentação de propósito geral, oferecendo alta adaptabilidade e eficiência em diversas tarefas.

#### A. U-net

A U-Net foi originalmente apresentada em [49]. Essa rede neural é capaz de reconhecer o contexto da imagem em seu caminho de contração, proporcionando uma localização precisa de um objeto na cena em seu caminho de expansão.

Além disso, as vantagens deste modelo em comparação com outras redes neurais incluem sua capacidade de ser treinado de ponta a ponta com um número reduzido de imagens, bem como seu baixo tempo de treinamento.

As etapas do aprendizado da U-Net podem ser enumeradas da seguinte forma:

- A rede recebe duas imagens (a imagem original e a imagem com sua máscara anotada como *ground truth*);
- O codificador da rede processa a imagem original por meio de uma série de redes neurais convolucionais;
- Uma conexão de salto (*skip connection*) envia as informações da rede convolucional anterior para o decodificador, preservando parte da informação necessária para a reconstrução da imagem;
- A operação de *max pooling* é aplicada à imagem, reduzindo seu tamanho de 512 para 64 pixels;
- O processo é revertido utilizando operações de *up-sampling*, concatenações com as conexões de salto anteriores e operações de convolução regulares no decodificador.

A Figura 5 mostra a arquitetura deste modelo.

### B. Dual U-Net

Enquanto o modelo U-Net processa convencionalmente uma única imagem de entrada para produzir uma imagem correspondente de saída, a arquitetura Dual U-Net estende

essa abordagem incorporando dois fluxos de entrada distintos. Essas entradas são processadas independentemente por dois codificadores separados, gerando mapas de características que são combinados por meio de conexões de salto em cada nível do decodificador. Para garantir a preservação eficaz dos detalhes durante o processo de fusão, são utilizados *attention gates*. Esses mecanismos aplicam uma fusão ponderada às características das conexões de salto, priorizando os recursos mais relevantes e, assim, melhorando a retenção de detalhes na saída final.

Neste trabalho, a entrada secundária consiste em uma versão da imagem de entrada original filtrada pelo operador de Prewitt. Essa entrada adicional tem o objetivo de focar o aprendizado da rede na segmentação de bordas, aproveitando a capacidade do filtro de Prewitt de acentuar informações de bordas. Ao integrar essa entrada secundária, a rede é guiada a enfatizar características relacionadas às bordas, potencialmente melhorando a precisão da segmentação das delimitações.

1) *Prewitt*: O filtro de Prewitt [53] é um método amplamente utilizado para detecção de bordas no processamento de imagens. Ele destaca regiões com altos gradientes de intensidade espacial, enfatizando eficazmente as bordas de uma imagem. Aplicando filtros de gradiente horizontal e vertical, o método de Prewitt detecta bordas com base nas mudanças de intensidade dos pixels, sendo adequado para a identificação de contornos de objetos.




Fig. 5. Arquitetura da U-Net.

### C. Segment Anything Model

O modelo SAM [52], desenvolvido pela Meta AI, é uma estrutura de segmentação de propósito geral que utiliza uma abordagem baseada em *prompts* para segmentação de objetos de forma interativa e versátil. Sua arquitetura é composta por três componentes principais: um codificador de imagem (*Vision Transformer*) para extração de características, um codificador de *prompt* para processar entradas como pontos ou caixas delimitadoras, e um decodificador leve para gerar máscaras de segmentação.

Treinado com bilhões de máscaras em diversos conjuntos de dados, o SAM generaliza eficazmente novas tarefas desconhecidas. Ele suporta diversas aplicações, incluindo imagem médica, condução autônoma e criação de conteúdo, oferecendo alta eficiência e adaptabilidade. Ao enfatizar a interatividade e flexibilidade, o SAM representa um avanço significativo na tecnologia de segmentação.

## IV. FASE DE PRÉ-TREINAMENTO DA REDE

Os modelos U-Net e Dual U-Net foram inicializados com pesos derivados de um autoencoder projetado com uma estrutura semelhante à U-Net original. Esse autoencoder foi treinado com pares de dados de entrada-saída idênticos, permitindo a inicialização dos pesos dos codificadores. Após a fase de treinamento do autoencoder, os pesos da primeira metade da rede (o codificador) foram transferidos para as arquiteturas U-Net e Dual U-Net. Esse processo acelerou significativamente o treinamento de ambos os modelos.

Os modelos foram treinados utilizando o otimizador Adam com uma taxa de aprendizado de  $1 \times 10^{-3}$ , empregando uma função de perda composta que combina a entropia cruzada binária com a métrica de interseção sobre união (IoU).

## V. METODOLOGIA DE ANÁLISE DO TAMANHO E CONTAGEM DOS GRÃOS

A metodologia proposta para a análise do tamanho e contagem dos grãos envolve o processamento de imagens em tons de cinza para identificar e medir o tamanho e a quantidade de grãos individuais. Esse processo é automatizado por meio de uma combinação de técnicas de pré-processamento de imagens, segmentação e análise estatística, conforme descrito a seguir:

### A. Pré-processamento de Imagem

Para garantir a consistência e preparar as imagens para segmentação, as imagens de entrada em escala de cinza são invertidas usando uma operação de *bitwise NOT*. Esse passo é necessário porque o algoritmo de segmentação assume uma distribuição específica de intensidade, onde os grãos aparecem como regiões de alta intensidade contra um fundo escuro. A limiarização (*thresholding*) é aplicada utilizando o método de Otsu, que determina o valor ótimo de limiar para criar uma imagem binária, separando eficazmente os grãos do fundo.

### B. Segmentação e Rotulagem

As máscaras binárias são geradas a partir das imagens limiarizadas, que são posteriormente processadas para identificar regiões individuais dos grãos. O processo de segmentação utiliza um algoritmo de rotulagem baseado em conectividade, usando um elemento estrutural predefinido para agrupar *pixels* conectados em *clusters*. O resultado é uma máscara rotulada, onde cada componente conectado representa um grão distinto.

### C. Extração de Características

Para cada grão rotulado, a área é calculada para representar seu tamanho em unidades de pixel. Os tamanhos dos grãos são extraídos usando as propriedades regionais dos componentes rotulados e o número total de grãos é registrado para cada imagem. Essas medições são armazenadas para análise estatística posterior.

### D. Visualização dos Resultados

Para validar visualmente o processo de segmentação, as máscaras rotuladas são sobrepostas às imagens originais usando uma representação codificada por cores, onde cada grão recebe uma cor única. Esse passo auxilia na verificação da eficácia do algoritmo de segmentação e garante a identificação precisa dos grãos.

## VI. EXPERIMENTOS E RESULTADOS

Para avaliar o desempenho da arquitetura proposta Dual U-Net de codificadores duplos, experimentos foram conduzidos utilizando três conjuntos de dados: um conjunto virtual, um conjunto de ambiente controlado e um conjunto industrial real. Um novo conjunto misto foi criado combinando os conjuntos de dados virtual e controlado, totalizando 2.400 imagens, com contribuições iguais de cada conjunto. Esse conjunto misto foi utilizado para treinar tanto a U-Net original quanto a Dual U-Net de codificadores duplos. Para os testes, um conjunto de 200 imagens do ambiente industrial real foi utilizado, garantindo que essas imagens não fossem vistas durante o treinamento.

Além disso, o modelo *Segment Anything* foi incluído na avaliação. Como esse modelo não requer treinamento, as 200 imagens de teste foram diretamente fornecidas ao modelo, e suas saídas de segmentação foram registradas.

### A. Resultados Quantitativos

A avaliação inicial focou na métrica de perda de Dice. Os resultados foram os seguintes:

- A U-Net original obteve uma perda de Dice de 0,84.
- A Dual-Encoder U-Net obteve uma perda de Dice de 0,89.
- O modelo SAM não produz perda de Dice, mas foi incluído em avaliações qualitativas adicionais.

Embora esses valores de perda de Dice forneçam uma comparação geral, eles foram insuficientes para avaliar de forma abrangente o desempenho prático das redes. Assim, uma métrica adicional de precisão na contagem de grãos foi introduzida para avaliar a capacidade das redes em segmentar e contar grãos individuais de forma eficaz.

## B. Precisão na Contagem de Grãos

A avaliação da contagem de grãos revelou diferenças significativas no desempenho da segmentação:

- **U-Net Original:** A U-Net original teve um desempenho insatisfatório, alcançando menos de 20% de precisão. A rede teve dificuldades para gerar contornos fechados, resultando em segmentação incompleta dos grãos;
- **SAM:** O modelo Segment Anything atingiu uma precisão de 73% na contagem de grãos. Ele foi particularmente eficaz na segmentação de grãos maiores e bem definidos, mas apresentou dificuldades com grãos menores;
- **Dual-Encoder U-Net:** A Dual-Encoder U-Net atingiu uma precisão de 91% na contagem de grãos. Embora tenha encontrado alguns desafios com grãos maiores, demonstrou excelente desempenho na segmentação de grãos menores, evidenciando sua robustez e precisão na identificação de detalhes finos.

## C. Discussão

A avaliação da contagem de grãos destaca os benefícios práticos da arquitetura *Dual-Encoder U-Net*, principalmente na segmentação de bordas. Embora a métrica de perda de Dice tenha mostrado uma melhoria marginal, a capacidade da *Dual-Encoder U-Net* de produzir contagens de grãos mais precisas evidencia seu desempenho superior em aplicações reais. A comparação com o modelo *Segment Anything* demonstra ainda mais a capacidade da *Dual-Encoder U-Net* de lidar com tarefas complexas de segmentação, especialmente para grãos menores e menos definidos.

Para ilustrar as saídas dos modelos, diversos exemplos do conjunto de testes são apresentados. A imagem original é mostrada na Figura 6, fornecendo uma referência para os dados de entrada. A máscara de segmentação correspondente ao *ground truth* é exibida na Figura 7, com uma versão colorida na Figura 8 para melhor distinção dos grãos individuais. A saída do modelo U-Net original é exibida na Figura 9, enquanto a saída da Dual-Encoder U-Net é mostrada na Figura 10. Por fim, a saída gerada pelo modelo *Segment Anything* é exibida na Figura 11.

As diferenças na qualidade da saída entre os modelos podem ser amplamente atribuídas aos métodos de pós-processamento utilizados para exibir as imagens segmentadas. Esses métodos afetam a clareza e a distinção visual dos grãos segmentados, o que pode influenciar a percepção do desempenho dos modelos nas comparações visuais.

## VII. CONCLUSÃO

Este estudo demonstra a eficácia da arquitetura *Dual-Encoder U-Net* na solução dos desafios da segmentação de grãos baseada em bordas. Ao incorporar uma entrada secundária filtrada pelo operador de Prewitt, a rede é orientada para um aprendizado específico de bordas, permitindo alcançar resultados de segmentação superiores em comparação com abordagens tradicionais. Os experimentos destacaram as limitações da U-Net original, que teve dificuldades em gerar contornos fechados dos grãos, resultando em baixa precisão



Fig. 6. Imagem RGB do ambiente real.




Fig. 7. Máscara do ambiente real.




Fig. 8. Máscara colorida do ambiente real.




Fig. 9. Saída da U-Net.




Fig. 10. Saída da *Dual-Encoder U-Net*.



Fig. 11. Saída do modelo *Segment Anything*.

na contagem dos grãos. Em contraste, a *Dual-Encoder U-Net* apresentou uma melhoria notável, alcançando uma precisão de 91% na contagem de grãos, lidando eficazmente com grãos menores e preservando os detalhes das bordas. Embora o modelo *Segment Anything* tenha apresentado um bom desempenho para grãos maiores, sua precisão geral foi inferior, demonstrando as vantagens de uma arquitetura personalizada como a *Dual-Encoder U-Net*. Os resultados enfatizam a importância de utilizar conjuntos de dados diversificados, incluindo ambientes simulados e controlados, para treinar modelos robustos para aplicações no mundo real. Além disso, o design *Dual-Encoder* e a integração de entradas focadas em bordas oferecem uma direção promissora para trabalhos futuros em tarefas de segmentação onde a precisão e a definição de contornos são críticas.

#### 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] R. Sharma, S. S. Kamble, A. Gunasekaran, V. Kumar, and A. Kumar, "A systematic literature review on machine learning applications for sustainable agriculture supply chain performance," *Computers & Operations Research*, vol. 119, p. 104926, 2020.
- [3] S. E. Vollset, E. Goren, C.-W. Yuan, J. Cao, A. E. Smith, T. Hsiao, C. Bisignano, G. S. Azhar, E. Castro, and J. Chalek, "Fertility, mortality, migration, and population scenarios for 195 countries and territories from 2017 to 2100: a forecasting analysis for the global burden of disease study," *The Lancet*, vol. 396, no. 10258, pp. 1285–1306, 2020.
- [4] M. M. Maja and S. F. Ayano, "The impact of population growth on natural resources and farmers' capacity to adapt to climate change in low-income countries," *Earth Systems and Environment*, vol. 5, no. 2, pp. 271–283, 2021.

- [5] 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.
- [6] D. E. Canfield, A. N. Glazer, and P. G. Falkowski, "The evolution and future of earth's nitrogen cycle," *Science*, vol. 330, no. 6001, pp. 192–196, 2010.
- [7] P. Smith, H. Haberl, A. er Popp, K. heinz Erb, C. Lauk, R. Harper, F. N. Tubiello, A. re de Siqueira Pinto, M. Jafari, S. Sohi, O. Masera, H. Bötcher, G. Berndes, M. Bustamante, H. Ahammad, H. Clark, H. Dong, E. A. Elsiddig, C. Mbow, N. H. Ravindranath, C. W. Rice, C. R. Abad, A. Romanovskaya, F. Sperling, M. Herrero, J. I. House, and S. Rose, "How much land-based greenhouse gas mitigation can be achieved without compromising food security and environmental goals?" *Global Change Biology*, vol. 19, no. 8, pp. 2285–2302, 2013.
- [8] W. Steffen, K. Richardson, J. Rockström, S. E. Cornell, I. Fetzer, E. M. Bennett, R. Biggs, S. R. Carpenter, W. De Vries, and C. A. De Wit, "Planetary boundaries: Guiding human development on a changing planet," *Science*, vol. 347, no. 6223, p. 1259855, 2015.
- [9] 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.
- [10] J. Hu, J. He, Y. Wang, Y. Wu, C. Chen, Z. Ren, X. Li, S. Shi, Y. Du, and P. He, "Design and study on lightweight organic fertilizer distributor," *Computers and Electronics in Agriculture*, vol. 169, p. 105149, 2020.
- [11] E. Mavridou, E. Vrochidou, G. A. Papakostas, T. Pachidis, and V. G. Kaburlasos, "Machine vision systems in precision agriculture for crop farming," *Journal of Imaging*, vol. 5, no. 12, p. 89, 2019.
- [12] J. Wang, H. Chen, R. Ma, J. Shao, S. Huang, Y. Liu, Y. Jiang, and D. Cheng, "Novel water-and fertilizer-management strategy: Nutrient-water carrier," *Journal of Cleaner Production*, vol. 291, p. 125961, 2021.
- [13] B. Wang, S. Zhong, T.-L. Lee, K. S. Fancey, and J. Mi, "Non-destructive testing and evaluation of composite materials/structures: A state-of-the-art review," *Advances in Mechanical Engineering*, vol. 12, no. 4, pp. 1–28, 2020.
- [14] J. F. I. Nturambirwe and U. L. Opara, "Machine learning applications to non-destructive defect detection in horticultural products," *Biosystems Engineering*, vol. 189, pp. 60–83, 2020.
- [15] N. Otsu, "A threshold selection method from gray-level histograms," *IEEE Transactions on Systems, Man, and Cybernetics*, vol. 9, no. 1, pp. 62–66, 1979.
- [16] S. Lloyd, "Least squares quantization in PCM," *IEEE Transactions on Information Theory*, vol. 28, no. 2, pp. 129–137, 1982.
- [17] J. Canny, "A computational approach to edge detection," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 6, pp. 679–698, 1986.
- [18] S. Minaee, Y. Y. Boykov, F. Porikli, A. J. Plaza, N. Kehtarnavaz, and D. Terzopoulos, "Image segmentation using deep learning: A survey," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2021.
- [19] Ç. Kaymak and A. Uçar, "A brief survey and an application of semantic image segmentation for autonomous driving," in *Handbook of Deep Learning Applications*. Springer, 2019, pp. 161–200.
- [20] X. Zhang and W. Dahu, "Application of artificial intelligence algorithms in image processing," *Journal of Visual Communication and Image Representation*, vol. 61, pp. 42–49, 2019.
- [21] N. Liang, S. Sun, J. Yu, M. F. Taha, Y. He, and Z. Qiu, "Novel segmentation method and measurement system for various grains with complex touching," *Computers and Electronics in Agriculture*, vol. 202, p. 107351, 2022.
- [22] Q. Liu, W. Liu, Y. Liu, T. Zhe, B. Ding, and Z. Liang, "Rice grains and grain impurity segmentation method based on a deep learning algorithm-NAM-EfficientNetv2," *Computers and Electronics in Agriculture*, vol. 209, p. 107824, 2023.
- [23] 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.
- [24] A. Kamilaris and F. X. Prenafeta-Boldú, "Deep learning in agriculture: A survey," *Computers and Electronics in Agriculture*, vol. 147, pp. 70–90, 2018.

- [25] Y. Lu and S. Young, "A survey of public datasets for computer vision tasks in precision agriculture," *Computers and Electronics in Agriculture*, vol. 178, p. 105760, 2020.
- [26] S. Bonadies and S. A. Gadsden, "An overview of autonomous crop row navigation strategies for unmanned ground vehicles," *Engineering in Agriculture, Environment and Food*, vol. 12, no. 1, pp. 24–31, 2019.
- [27] G. Ronchetti, A. Mayer, A. Facchi, B. Ortuani, and G. Sona, "Crop row detection through UAV surveys to optimize on-farm irrigation management," *Remote Sensing*, vol. 12, no. 12, p. 1967, 2020.
- [28] A. M. Hasan, F. Sohel, D. Diepeveen, H. Laga, and M. G. K. Jones, "A survey of deep learning techniques for weed detection from images," *Computers and Electronics in Agriculture*, vol. 184, p. 106067, 2021.
- [29] H. Pathak, C. Igathinathane, Z. Zhang, D. Archer, and J. Hendrickson, "A review of unmanned aerial vehicle-based methods for plant stand count evaluation in row crops," *Computers and Electronics in Agriculture*, vol. 198, p. 107064, 2022.
- [30] A. Biglia, S. Zaman, P. Gay, D. R. Aimonino, and L. Comba, "3D point cloud density-based segmentation for vine rows detection and localisation," *Computers and Electronics in Agriculture*, vol. 199, p. 107166, 2022.
- [31] Z. Diao, P. Guo, B. Zhang, D. Zhang, J. Yan, Z. He, S. Zhao, and C. Zhao, "Maize crop row recognition algorithm based on improved unet network," *Computers and Electronics in Agriculture*, vol. 210, p. 107940, 2023.
- [32] X. Liu, J. Qi, W. Zhang, Z. Bao, K. Wang, and N. Li, "Recognition method of maize crop rows at the seedling stage based on MS-ERFNet model," *Computers and Electronics in Agriculture*, vol. 211, p. 107964, 2023.
- [33] É. C. Gonçalves, G. P. de Almeida, E. L. Da Silva, T. T. Schein, P. J. D. de Oliveira Evald, and P. L. J. Drews-Jr, "Line detection and segmentation of annual crops using hybrid method," in *2023 Latin American Robotics Symposium (LARS)*. IEEE, 2023, pp. 472–477.
- [34] D. A. Bondre and S. Mahagaonkar, "Prediction of crop yield and fertilizer recommendation using machine learning algorithms," *International Journal of Engineering Applied Sciences and Technology*, vol. 4, no. 5, pp. 371–376, 2019.
- [35] S. Njoroge, A. G. T. Schut, K. E. Giller, and S. Zingore, "Learning from the soil's memory: Tailoring of fertilizer application based on past manure applications increases fertilizer use efficiency and crop productivity on kenyan smallholder farms," *European Journal of Agronomy*, vol. 105, pp. 52–61, 2019.
- [36] L. Meng, H. Liu, S. L. Ustin, and X. Zhang, "Predicting maize yield at the plot scale of different fertilizer systems by multi-source data and machine learning methods," *Remote Sensing*, vol. 13, no. 18, p. 3760, 2021.
- [37] S. A. Irfan, B. Azeem, K. Irshad, S. Algarni, K. KuShaari, S. Islam, and M. A. H. Abdelmohimen, "Machine learning model for nutrient release from biopolymers coated controlled-release fertilizer," *Agriculture*, vol. 10, no. 11, p. 538, 2020.
- [38] Y. Yue, J.-H. Li, L.-F. Fan, L.-L. Zhang, P.-F. Zhao, Q. Zhou, N. Wang, Z.-Y. Wang, L. Huang, and X.-H. Dong, "Prediction of maize growth stages based on deep learning," *Computers and Electronics in Agriculture*, vol. 172, p. 105351, 2020.
- [39] U. Sarkar, G. Banerjee, and I. Ghosh, "A machine learning based fertilizer recommendation system for paddy and wheat in west bengal," in *International Conference on Computational Intelligence in Communications and Business Analytics*. Springer, 2021, pp. 163–174.
- [40] D. P. Manoj Kumar, N. Malyadri, and M. S. Srikanth, "A machine learning model for crop and fertilizer recommendation," *Natural Volatiles & Essential Oils Journal*, pp. 10531–10539, 2021.
- [41] L. Drees, L. V. Junker-Frohn, J. Kierdorf, and R. Roscher, "Temporal prediction and evaluation of brassica growth in the field using conditional generative adversarial networks," *Computers and Electronics in Agriculture*, vol. 190, p. 106415, 2021.
- [42] S. R. Juhireshma and D. J. Aravindhar, "Fertilizer estimation using deep learning approach," *Natural Volatiles & Essential Oils Journal*, pp. 5745–5752, 2021.
- [43] S. Luo, Y. Li, P. Gao, Y. Wang, and S. Serikawa, "Meta-seg: A survey of meta-learning for image segmentation," *Pattern Recognition*, p. 108586, 2022.
- [44] F. Yang, D. Zhang, Y. Zhang, Y. Zhang, Y. Han, Q. Zhang, Q. Zhang, C. Zhang, Z. Liu, and K. Wang, "Prediction of corn variety yield with attribute-missing data via graph neural network," *Computers and Electronics in Agriculture*, vol. 211, p. 108046, 2023.
- [45] J. Leukel, T. Zimpel, and C. Stumpe, "Machine learning technology for early prediction of grain yield at the field scale: A systematic review," *Computers and Electronics in Agriculture*, vol. 207, p. 107721, 2023.
- [46] J. Desloires, D. Ienco, and A. Botrel, "Out-of-year corn yield prediction at field-scale using sentinel-2 satellite imagery and machine learning methods," *Computers and Electronics in Agriculture*, vol. 209, p. 107807, 2023.
- [47] D. A. Goulart, N. D. F. Traversi, J. C. O. Mendonça, R. N. Rodrigues, E. da S D Estrada, P. L. Drews, V. M. Oliveira, and S. S. Botelho, "Grain surface simulator to averiguate the overlapping and noise problems on computer vision granulometry of fertilizers," in *18th International Conference on Industrial Informatics (INDIN)*, vol. 1. IEEE, 2020, pp. 374–379.
- [48] J. C. O. Mendonça, D. A. Goulart, N. d. F. Traversi, R. N. Rodrigues, E. da S D Estrada, P. L. Drews Jr, and S. S. Botelho, "Simulated dataset to verify the overlapping and segregation problem on computer vision granulometry of fertilizers," *IFAC-PapersOnLine*, vol. 53, no. 2, pp. 12032–12037, 2020.
- [49] N. d. F. Traversi, D. A. Goulart, J. C. O. Mendonça, S. S. C. Botelho, L. B. Soares, E. S. D. Estrada, P. L. J. Drews, and V. M. Oliveira, "VBM granulometry for real applications in the fertilizer industry," in *18th Latin American Robotics Symposium (LARS)*. IEEE, 2021, pp. 276–281.
- [50] N. de Faria Traversi, P. J. D. de Oliveira Evald, J. M. Dias, D. A. Goulart, P. L. J. Drews, and S. S. da Costa Botelho, "A neural network for segmentation of fertilizer grain with multiple sizes and without background," in *48th Annual Conference of the IEEE Industrial Electronics Society (IECON)*. IEEE, 2022, pp. 1–6.
- [51] N. D. F. Traversi, P. J. D. O. Evald, J. V. Dos Santos, P. L. J. D. Junior, and S. S. D. C. Botelho, "Development of comprehensive fertilizer datasets: Enhancing precision agriculture through data-driven insights," in *IEEE 22nd International Conference on Industrial Informatics (INDIN)*. IEEE, 2024, pp. 1–6.
- [52] A. Kirillov, E. Mintun, N. Ravi, H. Mao, C. Rolland, L. Gustafson, T. Xiao, S. Whitehead, A. C. Berg, W.-Y. Lo, P. Dollár, and R. Girshick, "Segment anything," 2023. [Online]. Available: <https://arxiv.org/abs/2304.02643>
- [53] L. Yang, X. Wu, D. Zhao, H. Li, and J. Zhai, "An improved prewitt algorithm for edge detection based on noised image," in *2011 4th International Congress on Image and Signal Processing*, vol. 3, 2011, pp. 1197–1200.