http://journal.unoeste.br/index.php/ce/index
DOI: 10.5747/ce.2026.v18.e445
ISSN on-line 2178-8332

Colloquium Exactarum

Submetido: 17/12/2025 Revisado: 05/05/2026 Aceito: 18/05/2026

AUTOMATIZAÇÃO DA CONTAGEM E ANÁLISE DE SEMENTES DE ORQUÍDEA POR MEIO DE VISÃO COMPUTACIONAL E APRENDIZADO DE MÁQUINA

Automated Orchid Seed Counting and Analysis Using Computer Vision and Machine Learning

Paulo Martin Carreño Ferreira da Motta, Mário Augusto Pazoti, Nelson Barbosa Machado Neto

Universidade do Oeste Paulista - UNOESTE, Presidente Prudente, SP, Brasil
E-mail: paulomcfm@gmail.com, mario@unoeste.br, nbmneto@unoeste.br

RESUMO – A automatização na análise de sementes de orquídeas surge como uma necessidade em meio aos avanços da agricultura e da computação. Neste contexto, este trabalho desenvolveu e validou um sistema automatizado, empregando a arquitetura de segmentação de instâncias YOLOv8 para otimizar a contagem e classificação de sementes viáveis e inviáveis, baseada no teste de tetrazólio. O modelo treinado alcançou uma Precisão Média Média (mAP50) de 91,9% em um conjunto de teste desafiador, demonstrando alta precisão na distinção das classes. A solução foi materializada em um protótipo de *software* que, além de automatizar a contagem, extrai informações morfológicas e gera relatórios detalhados com as dimensões de altura e largura das sementes, contribuindo para a conservação e propagação da espécie.
Palavras-chave: Sementes de Orquídea, Visão Computacional, YOLOv8.

ABSTRACT – The automation of orchid seed analysis emerges as a necessity amid advancements in agriculture and computing. In this context, this project developed and validated an automated system using the YOLOv8 instance segmentation architecture to optimize the counting and classification of viable and non-viable seeds based on the tetrazolium test. The trained model achieved a mean Average Precision (mAP50) of 91,9% on a challenging test set, demonstrating high precision in class distinction. The solution was materialized in a functional software prototype that not only automates the counting process but also extracts morphological information, generating detailed reports with the height and width dimensions of the seeds, thereby contributing to the conservation and propagation of the species.
Keywords: Orchid Seeds, Computer Vision, YOLOv8.

1. INTRODUÇÃO

No campo das plantas ornamentais e medicinais, a família Orchidaceae se destaca por sua diversidade e popularidade, sendo amplamente cultivada tanto para fins ornamentais quanto medicinais (Mattiuz *et al.*, 2006, *apud* Macedo *et al.*, 2011) e suas sementes são extremamente pequenas e leves, embora sejam produzidas em grande quantidade (Arditti; Ghani, 2000, *apud* Pereira, 2020). Soares *et al.* (2021) afirma que a criação de bancos de sementes é essencial para proteger a biodiversidade dessas plantas, que estão ameaçadas. Além disso, a viabilidade das sementes em bancos é fundamental para a propagação e conservação da espécie, sendo o teste de tetrazólio um método crucial para essa análise (Marcos Filho, 2015, *apud* Soares *et al.*, 2021).

O teste de tetrazólio avalia a viabilidade das sementes com base na atividade das enzimas desidrogenases em tecidos vivos, indicando a viabilidade pela coloração das áreas ativas (França Neto *et al.*, 1998, *apud* Soares *et al.*, 2021). Além de determinar a viabilidade, o teste auxilia no controle de qualidade durante o armazenamento e processamento das sementes (Vieira; Carvalho, 1994; Delouche *et al.*, 1976, *apud* Zorzal *et al.*, 2015). A análise dessas sementes, especialmente em orquídeas, depende cada vez mais de tecnologias como a captura de imagens (Custódio; Hosomi; Machado Neto, 2021).

Nesse contexto, a visão computacional surge como uma área da ciência da computação capaz de processar e interpretar informações visuais de forma automática (Oliveira; Melo, 2024). Combinada com técnicas de aprendizado de máquina, como as redes neurais profundas, essa tecnologia permite criar sistemas que podem "ver" e tomar decisões baseadas em padrões visuais, replicando e até superando a percepção humana em tarefas específicas (Fleck *et al.*, 2016). A aplicação dessas ferramentas na análise de produtos agrícolas tem revolucionado o setor, automatizando processos e aumentando a precisão (LIN *et al.*, 2019; Mahajan *et al.*, 2018, *apud* Medeiros, 2023).

Apesar da existência de estudos focados na automação da análise de sementes de culturas como soja e milho (Watanabe, 2019; Bordignon; Alves; Oliveira, 2017), soluções para sementes de orquídeas ainda são escassas. As características únicas dessas sementes — como seu tamanho diminuto e a vasta quantidade produzida por vagem — tornam a análise manual não apenas demorada, mas suscetível a erros significativos. Detalhes cruciais para a determinação da viabilidade, que dependem da interpretação do teste de tetrazólio, podem não ser percebidos a olho nu, exigindo uma precisão que as ferramentas manuais não conseguem alcançar de forma consistente e eficiente.

Diante do exposto, este trabalho teve como objetivo o desenvolvimento de um sistema automatizado que emprega técnicas de processamento de imagens e redes neurais para a contagem e classificação de sementes de orquídeas viáveis e inviáveis, a partir de imagens do teste de tetrazólio. O protótipo desenvolvido otimizou o processo em termos de precisão e eficiência e demonstrou a capacidade de gerar relatórios detalhados com informações morfológicas, como altura e largura, contribuindo assim para a conservação, propagação e estudos de melhoramento da espécie.

O presente artigo está organizado da seguinte forma. Inicialmente, na seção de Trabalhos Relacionados é revisada a literatura pertinente, contextualizando as abordagens existentes na automação da análise de sementes e identificando a lacuna que o presente estudo visa preencher. Na seção de Conceitos Fundamentais é apresentada a base teórica de aprendizado de máquina e detalhada a arquitetura YOLO. Em seguida, na Metodologia é detalhada a abordagem completa do projeto, desde a aquisição e o pré-processamento das imagens até a arquitetura, o treinamento e os parâmetros de avaliação do modelo de aprendizado de máquina. Posteriormente, na seção de Resultados e Discussões são apresentadas as métricas de desempenho quantitativas do modelo, analisada a saída do sistema e descrito em detalhes o protótipo de *software* desenvolvido, o "Orchid Seed Analyzer", e suas funcionalidades. Por fim, nas Considerações Finais são sintetizadas as principais conclusões do trabalho, destacadas suas contribuições científicas e práticas e propostas direções para pesquisas futuras.

2. TRABALHOS RELACIONADOS

A aplicação de visão computacional e aprendizado profundo para a análise de sementes agrícolas tem se consolidado como uma área de intensa pesquisa, visando substituir ou complementar métodos manuais demorados e suscetíveis a erros. A literatura recente demonstra o sucesso de Redes Neurais Convolucionais (CNNs), especialmente da família YOLO (*You Only Look Once*), na classificação, contagem e avaliação da qualidade de sementes de diversas culturas. Esta seção revisa os trabalhos mais pertinentes,

contextualizando as abordagens existentes e destacando a lacuna que o presente estudo se propõe a preencher.

Diversos estudos validam a eficácia da arquitetura YOLO para tarefas de análise de sementes. Kundu, Rani e Dhaka (2022), por exemplo, utilizaram o YOLOv5 para desenvolver um sistema de classificação e teste de qualidade de sementes. O modelo alcançou uma precisão média (mAP) de 98,3%, superando métodos tradicionais de segmentação como o *K-means* e demonstrando a robustez da abordagem para classificação geral. De forma ainda mais alinhada a este trabalho, Tian *et al.* (2024) aplicaram diferentes versões do YOLO, incluindo o YOLOv8s, para avaliar o vigor da germinação de sementes de tomate. O sistema automatizado obteve uma correlação de 98,7% com as avaliações manuais, provando a alta eficácia do YOLOv8 para análises fenotípicas detalhadas. Embora esses estudos comprovem o poder da família YOLO, seu foco reside em sementes de culturas maiores ou na detecção de germinação, não abordando o desafio específico da classificação de viabilidade em sementes microscópicas.

Além da família YOLO, outras arquiteturas de aprendizado profundo têm sido exploradas, com destaque para modelos de segmentação por instância que, assim como o YOLOv8-seg, fornecem um contorno preciso do objeto. Yang *et al.* (2021) desenvolveram um sistema de fenotipagem de sementes de soja utilizando a arquitetura *Mask* R-CNN. O modelo foi capaz de segmentar sementes sobrepostas com altíssima precisão (AP50 de 99%), um desafio comum em análises de grande volume. A comparação com o *Mask* R-CNN é relevante, pois, embora ambas as arquiteturas realizem segmentação por instância, o YOLOv8-seg pertence à classe de detectores de estágio único, que geralmente oferecem um melhor equilíbrio entre velocidade e precisão, tornando-o ideal para aplicações que demandam alta performance e eficiência.

Outra abordagem comum na literatura combina a extração de características de visão computacional tradicional com classificadores de aprendizado de máquina. Pereira *et al.* (2019) propuseram um sistema para classificar o vigor de sementes de soja a partir do teste de tetrazólio, similar ao objetivo deste trabalho. No entanto, o método deles se baseava na extração manual de características de cor, textura e forma, que eram então fornecidas a algoritmos como *Random Forest* (RF) e *Support Vector Machine* (SVM). Embora eficaz, essa abordagem em múltiplos estágios pode não capturar a complexidade das características visuais de forma tão robusta quanto um modelo de aprendizado profundo ponta a ponta. Diferentemente, arquiteturas como o YOLOv8-seg aprendem a extrair as características mais discriminativas diretamente dos dados de imagem, eliminando a necessidade de engenharia de características manual e potencialmente descobrindo padrões que não seriam evidentes a um especialista humano.

A análise da literatura revela uma lacuna notável: a escassez de estudos que aplicam essas técnicas avançadas, especialmente a segmentação por instância, à análise de sementes de orquídeas. As características únicas dessas sementes, seu tamanho diminuto e a sutileza dos indicadores de viabilidade no teste de tetrazólio, representam um desafio significativamente maior do que o encontrado em culturas como soja, arroz ou tomate. O presente trabalho se insere neste contexto, propondo um sistema inovador que utiliza a precisão do YOLOv8-seg para automatizar a contagem e a classificação de viabilidade de sementes de orquídea, oferecendo uma solução específica para um problema até então pouco explorado pela comunidade científica.

3. CONCEITOS FUNDAMENTAIS

Para o desenvolvimento do sistema de detecção e classificação de sementes, este trabalho fundamenta-se nos princípios de Visão Computacional e Aprendizado Profundo, com destaque para as arquiteturas de detecção de objetos de estágio único.

3.1. Redes Neurais Convolucionais e o Processo de Aprendizado

A base da visão computacional é o aprendizado de máquina, um campo que permite aos computadores aprenderem padrões a partir de dados em vez de serem exclusivamente programados (Fleck *et al.*, 2016). No contexto da classificação de sementes, utiliza-se a abordagem de aprendizado supervisionado, onde o modelo é treinado com um conjunto de dados previamente rotulado por um especialista (Medeiros, 2023). Para essa tarefa, as Redes Neurais Convolucionais se destacam, pois são capazes de extrair características relevantes de forma automática e hierárquica diretamente das imagens,

que são tratadas como matrizes numéricas (Redmon *et al.*, 2016). Diferente de métodos clássicos, as CNNs aprendem sozinhas a identificar os padrões visuais mais discriminativos, como alterações minúsculas de cor ou textura, conferindo alta confiabilidade à análise (BORDIGNON; ALVES; DE OLIVEIRA, 2017).

3.2. A Família YOLO (You Only Look Once) e a Arquitetura YOLOv8

Dentre as diversas arquiteturas de CNNs, a família YOLO é notável por analisar a imagem em uma única passada, diferenciando-se de métodos em múltiplos passos (como R-CNN) ao oferecer um processo rápido e ideal para aplicações de alta performance (Gandhi, 2018). Este trabalho utilizou a arquitetura YOLOv8, que combina alta precisão com velocidade de inferência (Hussain, 2024). Seu princípio baseia-se na divisão da imagem em uma grade onde o modelo prediz, de forma simultânea, a máscara de segmentação de instância, a pontuação de confiança e as probabilidades de classe, eliminando a necessidade de *pipelines* complexos (Redmon *et al.*, 2016).

Para realizar essas predições avançadas, a estrutura da YOLOv8 é organizada em três estágios fundamentais, como demonstrado na Figura 1: *Backbone*, *Neck* e *Head*, que trabalham em conjunto para processar a imagem (Terven; Córdova-Esparza; Romero-González, 2023).

A função primordial do *Backbone* é converter a imagem de entrada em uma representação hierárquica de características. O módulo C2f, central na arquitetura do YOLOv8, otimiza este processo e tem sua origem no conceito de CSPNet (*Cross Stage Partial Network*). A principal motivação por trás desta abordagem é aumentar a eficiência e a capacidade de aprendizado da rede. Esse objetivo é alcançado particionando o mapa de características da camada base em duas partes e, em seguida, mesclando-as por meio de uma hierarquia de estágios cruzados (Wang *et al.*, 2019, p. 2).

Em seguida, o *Neck* processa esses dados para lidar com o desafio crítico de detectar objetos diminutos, como sementes de orquídea. Para isso, utiliza redes de agregação (como a PANet, ilustrada na Figura 2) que fundem a informação semântica das camadas profundas com a localização precisa das camadas iniciais de alta resolução, preservando os detalhes espaciais necessários (Liu *et al.*, 2018; Jocher; Chaurasia; Qiu, 2023; Hussain, 2024).

Figura 1. YOLOv8-Seg *network*

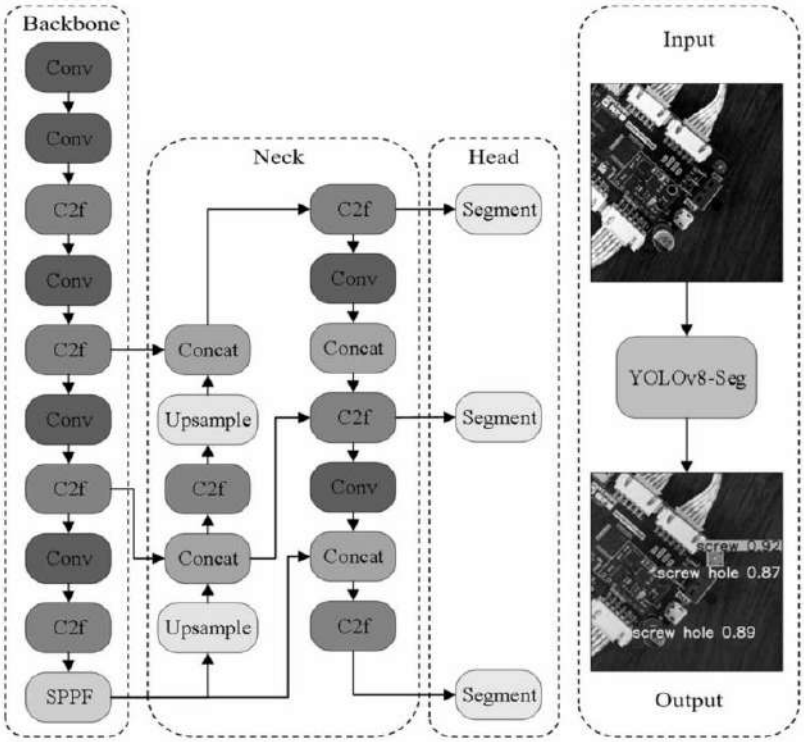

Fonte: (Chao *et al.*, 2025).

Figura 2. (a) *Backbone* FPN; (b) Aumentação do caminho *bottom-up*; (c) *Pooling* adaptativo de características; (d) Ramo da caixa (*Box branch*); (e) Fusão totalmente conectada.

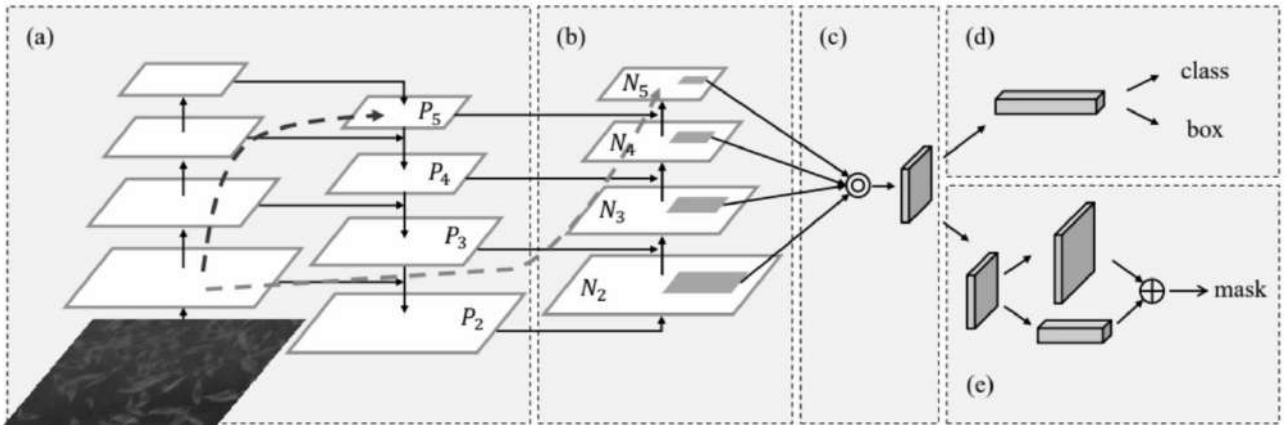

Fonte: Adaptação (Liu *et al.*, 2018)

Finalmente, o *Head* gera as predições finais empregando uma cabeça desacoplada, que separa as tarefas de classificação e regressão em ramos paralelos para evitar conflitos e melhorar a precisão geral (Ge *et al.*, 2021). Adicionalmente, a arquitetura opera no formato *anchor-free*, predizendo a segmentação diretamente pixel a pixel, dispensando o ajuste complexo de caixas de referência pré-definidas e tornando o processo de detecção mais simples (Tian *et al.*, 2019).

4. METODOLOGIA

O desenvolvimento do sistema automatizado para análise de sementes de orquídea seguiu uma abordagem estruturada, dividida em etapas sequenciais que compõem um fluxo de visão computacional, conforme ilustrado na Figura 3.

Figura 3. Fluxograma de Processo da Visão Computacional.

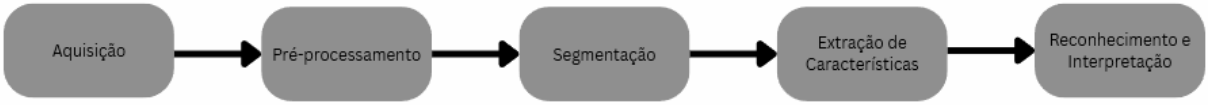

Fonte: Os autores.

A metodologia abrange desde a captura das imagens até a interpretação final dos resultados pelo modelo de aprendizado de máquina. As seções a seguir detalham cada um desses estágios: aquisição da imagem, pré-processamento, segmentação, extração de características, e, por fim, reconhecimento e interpretação.

4.1. Aquisição de Imagens

Esta etapa inicial foi focada na criação de um conjunto de dados visualmente rico e representativo, que serviu como base para o treinamento e a validação do modelo. O material de estudo consistiu em um dataset de 280 imagens digitais de sementes de orquídea. A avaliação da viabilidade de sementes de orquídea pelo teste de tetrazólio frequentemente envolve um protocolo que inclui um pré-condicionamento das sementes, seguido pela imersão em uma solução de tetrazólio sob condições controladas de temperatura e tempo. Hosomi (2017) detalha um procedimento no qual as sementes, após pré-condicionamento com soluções como sacarose ou glicose, são incubadas em banho-maria a 40°C no escuro. O objetivo dessa incubação é permitir que as enzimas desidrogenases presentes nos tecidos vivos reajam com o sal de tetrazólio, resultando em uma coloração que indica viabilidade. De forma análoga a esses procedimentos, a geração do *dataset* deste projeto submeteu as sementes a um protocolo de teste de viabilidade por tetrazólio com variações de temperatura e tempo de incubação, como 30°C por 24h, 40°C por 12h, 25°C por 12h, 45°C por 6h e 30°C por 12h. Essa diversidade de condições visou criar um conjunto de dados representativo de diferentes resultados do teste.

Para a aquisição das imagens, as amostras de sementes incubadas foram dispostas em lâminas de vidro. Em cada captura, uma régua foi posicionada ao lado da amostra para servir como referência de escala física. A digitalização, como ilustra a Figura 4, foi realizada utilizando um scanner de mesa, modelo HP Scanjet G2710, configurado para uma resolução óptica de 3600 DPI, o que resultou em imagens de alta definição com dimensões aproximadas de 12000x6000 pixels.

Figura 4. Foto de Sementes de Orquídea Submetidas ao Teste de Tetrazólio.

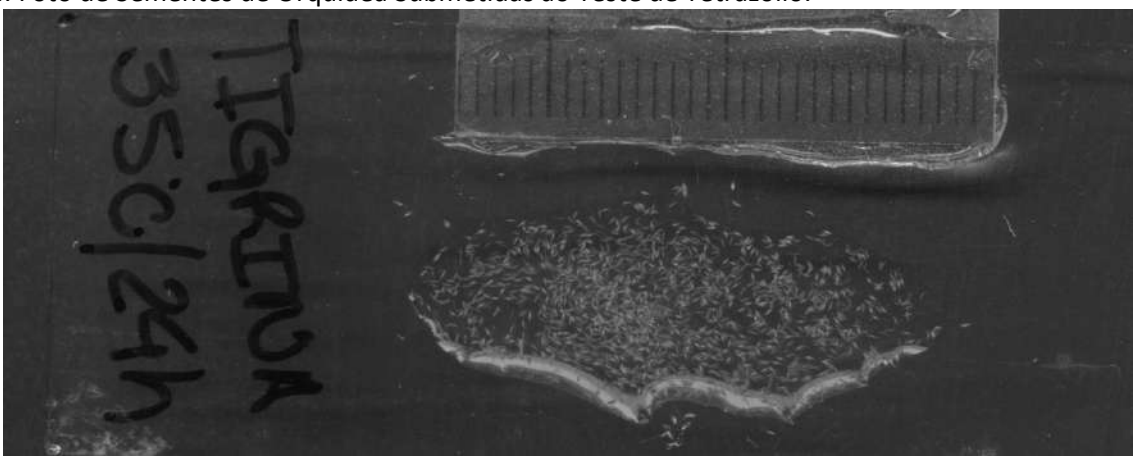

Fonte: Os autores.

4.2. Pré-processamento

O objetivo desta fase foi padronizar e otimizar as imagens originais, garantindo que elas tivessem um formato consistente e adequado para a entrada no modelo de aprendizado de máquina. Dado o tamanho excessivo das imagens originais, foi necessário um pré-processamento para padronizar a entrada do modelo. Com base em um subconjunto de 100 imagens que já haviam sido previamente contadas e analisadas manualmente e que possuíam uma área de interesse média de 946x946 pixels, este foi o tamanho padrão adotado. Portanto, todas as imagens do *dataset* foram recortadas, como demonstrado na Figura 5, para estas dimensões (946x946 pixels) antes de serem utilizadas nas etapas de treinamento, validação e contagem pelo protótipo desenvolvido.

4.3. Segmentação

Nesta etapa crucial, o foco foi "ensinar" o modelo a identificar e delinear as sementes, um processo conhecido como anotação ou rotulagem, que é fundamental para o aprendizado supervisionado. Para o treinamento do modelo de aprendizado supervisionado, foi construído um conjunto de dados a partir das imagens originais que não possuíam análise prévia. Um total de 198 imagens, no formato padronizado de 946x946 pixels, foi selecionado para o processo de anotação manual. A plataforma Roboflow foi utilizada para realizar a rotulagem por meio de segmentação de instâncias, onde polígonos foram desenhados para delinear o contorno exato de cada semente individualmente.

Figura 5. Foto do Recorte Utilizado de Sementes de Orquídea Submetidas ao Teste de Tetrazólio.

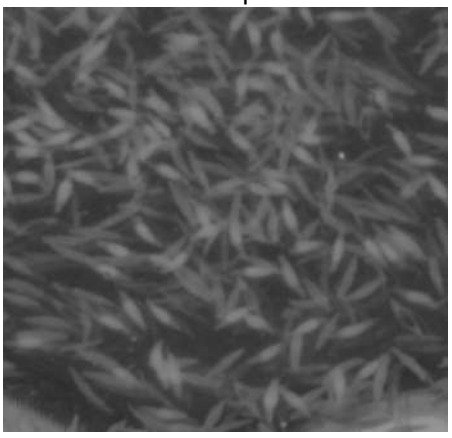

Fonte: Os autores.

As sementes foram classificadas em duas categorias distintas: 'viável' e 'inviável'. O critério para essa classificação foi estritamente visual, baseado no resultado do teste de tetrazólio: sementes que apresentavam um núcleo com qualquer grau de coloração avermelhada foram rotuladas como 'viáveis', enquanto aquelas com núcleo de coloração branca ou opaca foram rotuladas como 'inviáveis'. Uma decisão metodológica importante foi a de não anotar as sementes visivelmente vazias (sem núcleo), tratando-as efetivamente como fundo. Esta abordagem direciona o modelo a focar exclusivamente na distinção entre as sementes que contêm embrião.

Após a conclusão da anotação, o dataset foi automaticamente dividido pela plataforma Roboflow em três subconjuntos para o ciclo de vida do modelo: 122 imagens originais para o conjunto de treinamento (61,6%), 38 para validação (19,2%) e 38 para teste (19,2%).

Para aumentar a variabilidade do conjunto de dados de treinamento, mitigar o risco de *overfitting* e melhorar a capacidade de generalização do modelo, foi empregada uma estratégia de *data augmentation offline*. Foram aplicadas transformações geométricas, nas 122 imagens do conjunto de treinamento, que preservam as características morfológicas e de cor das sementes, sendo eles: inversão horizontal, inversão vertical, rotação de 90° e rotação de 180°, gerando 488 novas imagens.

Utilizando um *script* em Python com a biblioteca OpenCV, foram aplicadas quatro transformações geométricas que preservam as características morfológicas e de cor das sementes: inversão horizontal, inversão vertical, rotação de 90° e rotação de 180°. Cada imagem original gerou quatro novas variações posicionais e de espelhamento. Esse procedimento expandiu o conjunto de treinamento. Todo o processo de *augmentation* e o subsequente treinamento do modelo foram realizados na plataforma Google Colab, utilizando um ambiente com uma GPU NVIDIA T4. A expansão do *dataset* foi crucial para expor o modelo a uma gama maior de orientações e posicionamentos das sementes, tornando-o mais robusto para a análise de novas amostras.

O treinamento do modelo de segmentação foi realizado utilizando a biblioteca Ultralytics em um ambiente Google Colab com uma GPU NVIDIA T4. Foi selecionada a arquitetura YOLOv8m-seg, uma versão de porte médio pré-treinada no *dataset* COCO, escolhida por seu bom equilíbrio entre capacidade de aprendizado e eficiência computacional.

4.4. Extração de Características

Com o dataset preparado, a etapa seguinte consistiu em utilizar a arquitetura YOLOv8m-seg para analisar as imagens e extrair as características visuais (como cor, forma e textura) que distinguem sementes viáveis das inviáveis.

As imagens padronizadas foram processadas pela rede neural, que utilizou seus recursos internos de convolução para captar os sutis detalhes morfológicos e as variações de tonalidade geradas pelo teste de tetrazólio no embrião de cada semente. Por fim, o modelo foi configurado para gerar uma predição dupla: identificar e classificar cada semente como "viável" ou "inviável" e gerar a respectiva máscara de segmentação de instâncias de alta precisão, delineando o contorno exato para permitir a posterior análise morfológica.

4.5. Reconhecimento e Interpretação

Esta é a fase final do fluxo, na qual o modelo utiliza as características extraídas para tomar a decisão final: classificar cada semente e gerar uma máscara de segmentação precisa.

Para essa tarefa, o modelo foi treinado por um total de 110 épocas, com um mecanismo de *early stopping* configurado com uma paciência de 30 épocas para evitar o *overfitting*. As imagens de entrada foram redimensionadas para uma alta resolução de 960x960 pixels, uma decisão crucial para garantir que as características diminutas das sementes fossem preservadas. Devido às restrições de memória da GPU, foi utilizado um batch size de 2.

5. RESULTADOS E DISCUSSÕES

A avaliação do sistema proposto foi realizada por meio de um conjunto de experimentos estruturados para treinar, validar e testar o modelo de visão computacional. Esta seção detalha a configuração experimental, apresenta os resultados quantitativos de desempenho do modelo e discute a saída gerada pelo protótipo e suas implicações práticas.

A fase de treinamento foi configurada com uma série de hiperparâmetros específicos, visando extrair o máximo de desempenho da arquitetura YOLOv8m-seg. Uma decisão metodológica central foi a utilização de uma alta resolução de imagem de entrada (imgsz=960), essencial para preservar os detalhes das sementes microscópicas e evitar a perda de informação durante o processamento pela rede neural. Devido à alta demanda de memória desta resolução na GPU NVIDIA T4, foi necessário utilizar um tamanho de lote de 2. O modelo foi configurado para treinar por um máximo de 200 épocas, com um mecanismo de parada antecipada (patience=30) para evitar o superajuste, interrompendo o treinamento caso não houvesse melhora no desempenho do conjunto de validação por 30 épocas consecutivas. Para focar na precisão da classificação, que é o desafio central do projeto, o peso da função de perda de classificação foi aumentado para cls=1.5, forçando o modelo a penalizar mais severamente os erros de classificação entre sementes viáveis e inviáveis. Adicionalmente, foi aplicada uma taxa de regularização *dropout* de 0.2 para melhorar a capacidade de generalização do modelo. Embora parâmetros iniciais de otimização tenham sido definidos, o treinamento empregou a funcionalidade optimizer='auto' da biblioteca Ultralytics, que selecionou o otimizador AdamW com uma taxa de aprendizado de 0.001667, ajustando-o dinamicamente para uma convergência mais eficaz. O otimizador AdamW é uma versão aprimorada do algoritmo Adam, projetado para melhorar o processo de regularização durante o treinamento de modelos de aprendizado profundo. Sua principal função é aplicar a técnica de "decaimento de peso" de uma maneira mais eficaz para prevenir o superajuste, que ocorre quando um modelo se ajusta excessivamente aos dados de treinamento e perde a capacidade de generalizar para novos dados (Loshchilov; Hutter, 2019).

Concluído o treinamento, a avaliação final e a geração de resultados seguiram um protocolo rigoroso para garantir uma análise imparcial e limpa. O modelo salvo na época 76 foi carregado para ser avaliado no conjunto de teste, que não foi utilizado em nenhuma etapa do treinamento ou ajuste. Para esta validação, foram mantidos os mesmos parâmetros de resolução (imgsz=960) para consistência. Para a geração das saídas visuais e dos arquivos de contagem (a etapa de predição), foram aplicados parâmetros de pós-processamento otimizados. Foi estabelecido um limiar de confiança de 0.45, um valor relativamente alto para filtrar detecções de baixa certeza e garantir que apenas as sementes identificadas com alta probabilidade fossem consideradas, resultando em uma maior precisão. O processo de Supressão Não-Máxima (NMS) utilizou um limiar de Intersecção sobre União (iou) de 0.5 para eliminar detecções sobrepostas da mesma classe. De forma crucial, a NMS foi configurada como "agnóstica" (agnostic_nms=True), tratando todas as classes como uma só durante a supressão. Esta escolha foi fundamental para impedir que o modelo atribuísse duas classificações diferentes (uma "viável" e uma "inviável") para a mesma semente, garantindo uma classificação única e uma contagem precisa por objeto.

A performance do modelo final foi submetida a uma avaliação rigorosa e abrangente. Para testar não apenas a acurácia, mas também a capacidade de generalização do sistema, o conjunto de teste foi composto por 38 imagens e um total de 1.614 instâncias de sementes (688 inviáveis e 926 viáveis), garantindo que o modelo fosse avaliado sob múltiplas orientações e posicionamentos, simulando uma maior variabilidade de cenários de análise.

Na análise quantitativa do conjunto de teste, o modelo alcançou uma Precisão Média Média (mAP) de 91,9% com limiar de 0.50, conforme detalhado na Curva de Precisão-Revocação (Figura 6). A precisão geral foi de 84,6%, indicando alta assertividade na classificação das sementes. A partir da análise detalhada das predições, obteve-se uma revocação geral de 90,5% e um F1-Score médio de 87,0%. A estabilidade do modelo é demonstrada especialmente na detecção da classe 'viável', que alcançou um mAP individual de 91,9%, uma revocação de 92,6% e um F1-Score individual de 88,9%, validando a confiabilidade do sistema para não descartar indevidamente sementes com potencial de germinação.

Figura 6. Curva de Precisão-Revocação.

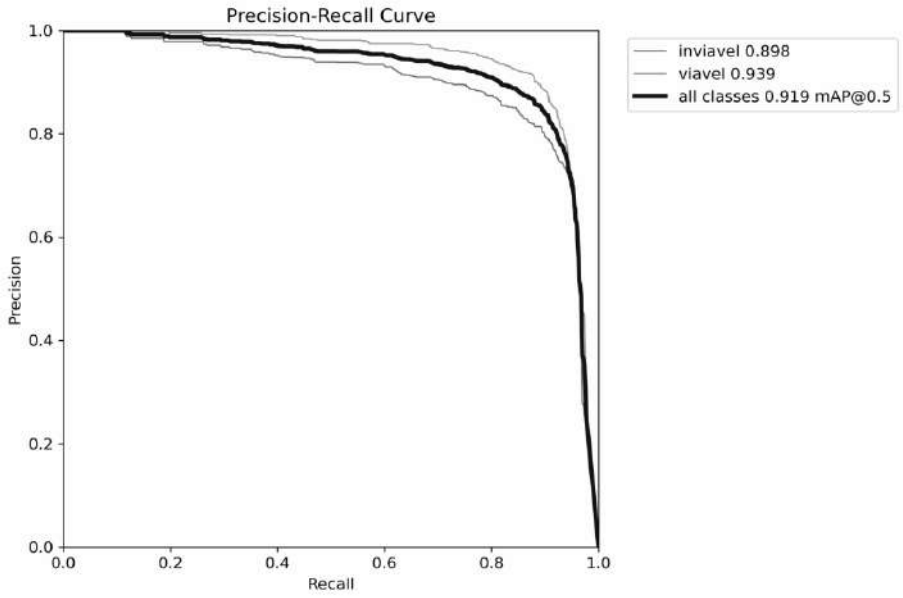

Fonte: Elaboração Própria com Ultralytics.

A acurácia da classificação pode ser observada na Matriz de Confusão (Figura 7). O modelo identificou corretamente 609 sementes inviáveis e 858 sementes viáveis. No contexto da aplicação prática do sistema em conservação de espécies, a matriz revela apenas 34 falsos negativos (sementes viáveis classificadas como inviáveis). Isso demonstra que o sistema raramente descarta material genético com potencial de germinação, validando sua confiabilidade para a triagem e seleção em bancos de sementes.

Figura 7. Matriz de Confusão.

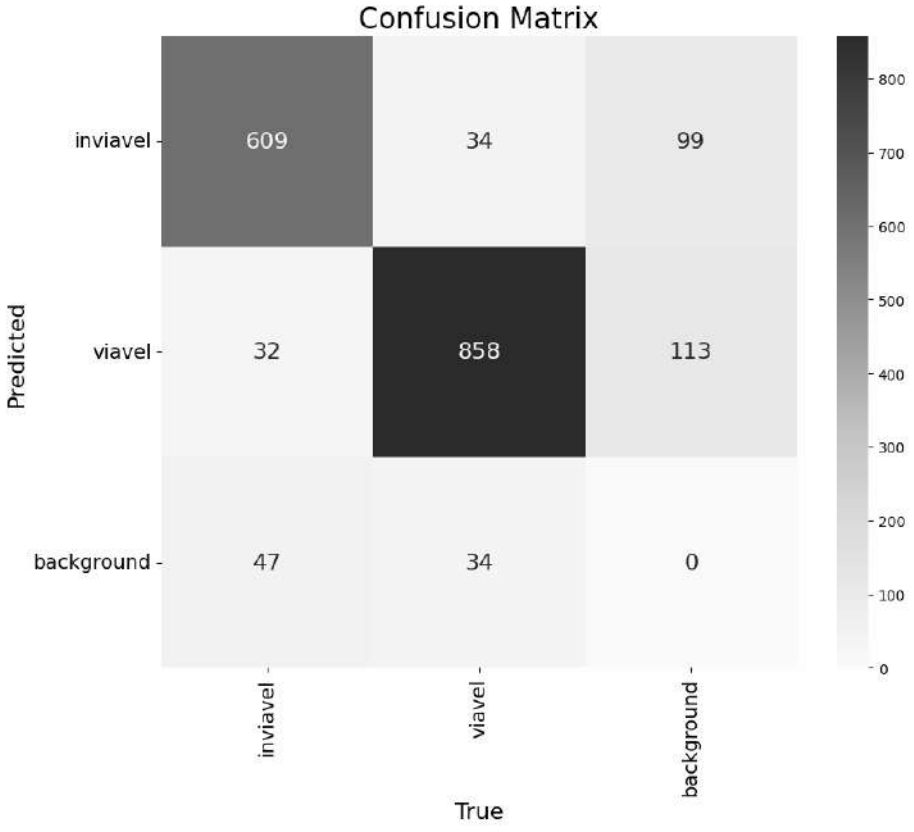

Fonte: Elaboração Própria com Ultralytics.

O resultado prático da pesquisa consolidou-se no desenvolvimento do “Orchid Seed Analyzer”, um *software desktop* criado em Python, com interface construída via *framework* PyQt6 e operações sustentadas pelas bibliotecas Ultralytics, Pillow e NumPy. O sistema foi concebido para operar localmente, garantindo a privacidade dos dados, e integra a inferência da rede neural à curadoria por especialistas em um único fluxo de trabalho contínuo.

Para garantir a consistência científica e a comparabilidade dos resultados, a aplicação inicia-se com a padronização dimensional das imagens originais de alta resolução através da definição de uma Área de Interesse (ROI) com dimensões fixas de 5676x1892 pixels. O sistema oferece flexibilidade metodológica, permitindo tanto o processamento do lote a partir da delimitação manual da ROI, quanto o carregamento direto de imagens previamente formatadas ou sessões de análise já iniciadas. Uma vez delimitada a região útil, o software realiza um fatiamento sistemático da área em uma grade padronizada de 6 colunas por 2 linhas. Este processo transforma a imagem original em 12 recortes isolados com dimensões de 946x946 pixels, adequando as amostras aos requisitos exatos de entrada do modelo YOLOv8-seg e eliminando vieses de escala.

Cada recorte padronizado é então submetido à inferência pelo modelo pré-carregado. Como retorno, o sistema extrai não apenas a contagem bruta, mas uma lista estruturada contendo a classificação espacial das sementes (viável ou inviável), seus respectivos scores de confiança e as coordenadas dos polígonos de segmentação que delineiam o contorno exato de cada objeto. Para assegurar a rastreabilidade e permitir a editabilidade posterior, a análise de cada recorte é armazenada estruturalmente em formato JSON, preservando os dados brutos da predição.

Visando refinar a predição automatizada, o sistema transita para um ambiente de curadoria visual onde as máscaras de segmentação são sobrepostas à imagem original. O especialista pode então interagir com os resultados através de ferramentas de edição não destrutivas, permitindo alternar a classificação biológica das sementes ou ocultar falsos positivos, garantindo a integridade dos dados para futuras auditorias. Em paralelo à contagem, o protótipo incorpora um módulo de análise dimensional avançada fundamentado na Análise de Componentes Principais (PCA). Utilizando as coordenadas dos polígonos segmentados, o algoritmo determina a orientação primária de cada semente no plano e mensura suas larguras e alturas ao longo de eixos ortogonais, comportando-se como uma caixa delimitadora orientada. Esse método normaliza a medição independentemente do posicionamento original da semente na imagem, gerando dados morfológicos.

A culminação do fluxo de trabalho no "Orchid Seed Analyzer" ocorre na geração do relatório final, o resultado tangível da análise. Após o especialista revisar e atribuir um status final ("Confirmado" ou "Removido") a cada recorte, e tendo preenchido os metadados do experimento na interface, o sistema habilita a funcionalidade de exportação. Com um clique, a aplicação consolida todos os dados das imagens confirmadas em um único arquivo de formato CSV (Comma-Separated Values), nomeado dinamicamente com o código da análise e um carimbo de data e hora para garantir a unicidade e a fácil organização. O relatório, como observado na Figura 8, é estruturado em duas seções claras: um cabeçalho que apresenta os metadados essenciais — Código da Análise, Espécie, Temperatura e Tempo — e uma tabela detalhada que quantifica os resultados por imagem. Para cada recorte confirmado, uma linha é gerada, contendo o nome do arquivo, a contagem total de sementes, os totais de sementes viáveis e inviáveis, o percentual de viabilidade calculado para aquela imagem, e as médias de largura e altura em pixels, extraídas da análise dimensional.

Figura 8. Relatório de Análise.

Informações da Análise						
Análise	Nome do Lote					
Espécie	Espécie analisada					
Temperatura	30 °C					
Tempo	24 h					
Imagem	Total Sementes	Sementes Viáveis	Sementes Inviáveis	% Viabilidade	Largura Média (px)	Altura Média (px)
digitalizar0001_1.png	40	27	13	67.50%	161.72	51.2
digitalizar0001_2.png	26	19	7	73.08%	162.04	49.73
digitalizar0001_3.png	20	14	6	70.00%	155.78	44.1
digitalizar0001_4.png	25	20	5	80.00%	173.47	48.1
digitalizar0001_5.png	20	16	4	80.00%	163.28	46.52
digitalizar0001_6.png	18	13	5	72.22%	164.9	53.14
digitalizar0001_7.png	29	19	10	65.52%	162.45	53.54
digitalizar0001_8.png	25	20	5	80.00%	159.52	52.8
digitalizar0001_9.png	27	14	13	51.85%	166.24	41.19
digitalizar0001_10.png	19	14	5	73.68%	178.21	53.06
digitalizar0001_11.png	17	15	2	88.24%	177.43	52.6
digitalizar0001_12.png	17	15	2	88.24%	164.51	44.01
TOTAL	283	206	77	72.79%	165.21	49.29

Fonte: Os autores.

O relatório é concluído com uma linha de "TOTAL", que agrega os dados de todas as imagens individuais para fornecer uma visão geral do lote. Nesta seção consolidada, são apresentadas as contagens totais, o percentual de viabilidade geral de todo o experimento e as médias de largura e altura de todas as sementes analisadas no lote, oferecendo um perfil morfológico da amostra. Este documento final converte o processamento visual em um conjunto de dados quantitativos e estruturados. Dessa forma, o protótipo cumpre integralmente seu objetivo, entregando aos pesquisadores não apenas uma automação do processo, mas também uma base de dados estruturada, pronta para análises estatísticas e para a tomada de decisões informadas sobre a conservação e propagação das espécies.

Quando comparamos os resultados obtidos com a literatura recente, o mAP de 91,9% se mostra bastante competitivo, principalmente se levarmos em conta a complexidade das sementes de orquídea. Trabalhos como os de Kundu, Rani e Dhaka (2022) e Yang *et al.* (2021) alcançaram métricas superiores (acima de 98% de precisão) usando modelos como YOLOv5 e Mask R-CNN. Porém, é importante notar que essas pesquisas avaliaram sementes maiores, como soja e tomate, em tarefas visualmente mais simples.

Mesmo com o bom desempenho do modelo, cabe ressaltar uma limitação importante da pesquisa: o tamanho restrito do banco de dados. Embora o uso de data augmentation tenha ampliado esse conjunto, o volume total de dados ainda é considerado pequeno para os padrões usuais de treinamento de redes neurais profundas. Na prática, isso significa que o modelo pode ter dificuldades de generalização caso seja testado em cenários diferentes dos apresentados no estudo. Táticas como a taxa de dropout e o próprio aumento de dados evitaram o overfitting na amostra atual. Contudo, para consolidar o uso do *software* em larga escala, estudos futuros deverão focar na ampliação do dataset, incluindo imagens de diferentes laboratórios e condições de teste.

6. CONSIDERAÇÕES FINAIS

O presente trabalho abordou o desafio da análise de viabilidade de sementes de orquídea, um processo tradicionalmente manual, demorado e suscetível a erros, propondo e desenvolvendo um sistema automatizado baseado em visão computacional e aprendizado profundo. Utilizando a arquitetura de segmentação de instâncias YOLOv8-seg, foi treinado um modelo capaz de identificar, classificar e delinear com precisão sementes viáveis e inviáveis a partir de imagens do teste de tetrazólio. A solução foi materializada no protótipo de *software* "Orchid Seed Analyzer", uma ferramenta de desktop projetada para automatizar a contagem, classificação e análise morfológica. Os resultados quantitativos, juntamente com a funcionalidade do protótipo, demonstraram a eficácia da abordagem, cumprindo integralmente o objetivo central do projeto de oferecer uma alternativa precisa e eficiente aos métodos manuais.

As contribuições deste trabalho estendem-se tanto ao campo científico quanto à aplicação prática. No âmbito científico, a principal contribuição reside na validação da eficácia da arquitetura YOLOv8-seg para a análise de sementes microscópicas, um problema que representa um desafio significativamente maior do que o encontrado em culturas agrícolas com sementes maiores e que, até então, era pouco

explorado com técnicas de segmentação de instâncias de ponta. Do ponto de vista prático, a contribuição mais notável é a entrega de um sistema de software funcional e completo, o "Orchid Seed Analyzer". Diferente de estudos que se limitam a apresentar um modelo, este projeto desenvolveu um fluxo de trabalho que integra a automação da IA com a curadoria do especialista humano. Essa abordagem não apenas acelera drasticamente o processo de análise, mas também garante a acurácia dos dados finais, ao mesmo tempo que extrai informações morfológicas valiosas e gera relatórios quantitativos prontos para uso em pesquisas.

Embora os resultados demonstrem o sucesso da abordagem, o presente estudo também abre diversas avenidas para trabalhos futuros. A principal sugestão é a expansão do conjunto de dados, incluindo uma maior diversidade de espécies de orquídeas e diferentes condições do teste de tetrazólio, o que aprimoraria a capacidade de generalização do modelo. Outra linha de pesquisa seria a exploração de arquiteturas de modelos alternativas, como versões mais recentes ou mais leves da família YOLO, para avaliar o balanço entre precisão e velocidade de inferência. No que tange ao protótipo, futuras versões poderiam incorporar novas funcionalidades de análise morfológica, como a medição de circularidade e a análise de textura do embrião. Finalmente, a integração de novas tecnologias de imagem, como a captura hiperespectral, poderia ser investigada para extrair características não visíveis ao olho humano, potencialmente aprimorando a capacidade de classificação e abrindo novas fronteiras na análise de viabilidade de sementes.

REFERÊNCIAS

BASSOI, L.H.; INAMASU, R.Y.; BERNARDI, A.C de C.; VAZ, C.M.P.; SPERANZA, E.A.; CRUVINEL, P.E. Agricultura de precisão e agricultura digital. **Agricultura Digital**, n. 20, 2019. DOI: https://doi.org/10.23925/1984-3585.2019i20p17-36.

BORDIGNON, L. A.; ALVES, J. H.; OLIVEIRA, L. F. **Identificação de amostras de sementes utilizando visão computacional.** 2017. Trabalho de Conclusão de Curso (Graduação em Engenharia de Bioprocessos e Biotecnologia) - Universidade Federal do Paraná, Curitiba. DOI: https://doi.org/10.22456/2175-2745.71439. Disponível em: https://www.researchgate.net/publication/320172106_Identificacao_de_amostras_de_sementes_utilizando_VisaoComputacional. Acesso em: 05 out. 2024.

CASTANHO, R. B.; TEIXEIRA, M. E. S. A evolução da agricultura no mundo: da gênese até os dias atuais. **Brazilian Geographical Journal,** v. 8, n. 2, 2017. Disponível em: https://seer.ufu.br/index.php/braziliangeojournal/article/view/50874. Acesso em: 03 out. 2024.

CHAO, Y.; LU, H.; ZHU, H.; TAN, C.; DAI, G. YOLOv8-SM-seg for screw hole localisation and vision-guided tracking in digital twin. **Digital Twin,** 05 set. 2025. DOI: https://doi.org/10.1080/27525783.2025.2551315.

CUSTÓDIO, C. C.; HOSOMI, S. T.; MACHADO NETO, N. B. Teste de tetrazólio em sementes de orquídeas. **Boletim de Pesquisa,** Universidade do Oeste Paulista, Presidente Prudente, São Paulo, 2021. Disponível em: https://sites.unoeste.br/boletimppga/wp-content/uploads/2021/09/BoletimPPGAV22021-54-59.pdf. Acesso em: 06 out. 2024.

FLECK, L.; TAVARES, M. H. F.; EYNG, E.; HELMANN, A. C.; ANDRADE, M. A. M. Redes neurais artificiais: princípios básicos. **Revista Eletrônica Científica da UERGS**, v. 2, n. 1, p. 88-102, 2016. DOI: https://doi.org/10.3895/recit.v7.n15.4330.

GANDHI, R. **R-CNN, Fast R-CNN, Faster R-CNN, YOLO — Object Detection Algorithms.** Towards Data Science, 2018. Disponível em: https://towardsdatascience.com/r-cnn-fast-r-cnn-faster-r-cnn-yolo-object-detection-algorithms-36d53571365e. Acesso em: 22 out. 2025.

GE, Z.; LIU, S.; WANG, F.; LI, Z.; SUN, J. YOLOX: Exceeding YOLO Series in 2021. **ArXiv** preprint arXiv:2107.08430, 2021. DOI: 10.48550/arXiv.2107.08430. Disponível em: https://arxiv.org/abs/2107.08430. Acesso em: 19 out. 2025.

HOSOMI, S. T. **Sementes de orquídeas:** conservação e avaliação de viabilidade. 2017. 157 f. Tese (Doutorado em Agronomia) – Universidade do Oeste Paulista, Presidente Prudente. Disponível em: http://bdtd.unoeste.br:8080/jspui/handle/jspui/1057. Acesso em: 08 out. 2025.

HUSSAIN, M. YOLOV5, YOLOV8 and YOLOv10: the go-to detectors for real-time vision. **ArXiv** preprint arXiv:2407.02988, 2024. DOI: 10.48550/arXiv.2407.02988. Disponível em: https://arxiv.org/abs/2407.02988. Acesso em: 14 out. 2025.

ISPA. INTERNATIONAL SOCIETY OF PRECISION AGRICULTURE. **Precision ag definition.** 2024. Disponível em: https://www.ispag.org/about/definition. Acesso em: 06 out. 2024.

JOCHER, G.; CHAURASIA, A.; QIU, J. **Ultralytics YOLOv8.** 2023. Disponível em: https://github.com/ultralytics/ultralytics. Acesso em: 25 out. 2025.

KUNDU, N.; RANI, G.; DHAKA, V. S. Seeds classification and quality testing using deep learning and YOLO v5. *In*: INTERNATIONAL CONFERENCE ON DATA SCIENCE, MACHINE LEARNING AND ARTIFICIAL INTELLIGENCE, 2021, New York. **Anais** [...]. New York: Association for Computing Machinery, 2022. p. 153-160. DOI: https://doi.org/10.1145/3484824.3484913.

LIU, S.; QI, L.; QIN, H.; SHI, J.; JIA, J. Path aggregation network for instance segmentation. **ArXiv** preprint arXiv: 1803.01534, 2018. DOI: 10.48550/arXiv.1803.01534. Disponível em: https://arxiv.org/abs/1803.01534. Acesso em: 11 out. 2025.

LOSHCHILOV, I.; HUTTER, F. Decoupled Weight Decay Regularization. *In*: INTERNATIONAL CONFERENCE ON LEARNING REPRESENTATIONS, 2019, New Orleans. ***Anais*** [...]. New Orleans, 2019. DOI: 10.48550/arXiv.1711.05101. Disponível em: https://arxiv.org/abs/1711.05101. Acesso em: 17 nov. 2025.

MACEDO, M. C.; ROSA, Y. B. C. J.; SCALON, S. P.Q.; ROSA JÚNIOR, E. J.; VIEIRA, M. C.; TATARA, M. B. Substratos e intensidades de luz no cultivo de orquídea denfal. **Horticultura Brasileira**, v. 29, p. 168-173, 2011. DOI: https://doi.org/10.1590/S0102-05362011000200006.

MEDEIROS, A.D. **Aplicações avançadas de aprendizado de máquina e ferramentas de análise de imagens para classificação e fenotipagem de sementes.** 2023. Tese (Doutorado em Genética e Melhoramento) - Universidade Federal de Viçosa, Viçosa, 2023. DOI: https://doi.org/10.47328/ufvbbt.2024.038.

OLIVEIRA, B.V.N.; MELO, F.T. Fundamentos da visão computacional: arcabouço teórico do reconhecimento artificial de imagens e vídeos. **Revista Humanidades e Inovação**, Palmas, TO, v. 10, n. 17, 2024. Disponível em: https://revista.unitins.br/index.php/humanidadeseinovacao/article/view/9078. Acesso em: 02 out. 2024.

PEREIRA, S. T. S. **Germinação de sementes e conservação de orquídeas nativas das Américas.** 2020. Tese (Doutorado em Agronomia - Produção Vegetal) - Universidade Estadual Paulista, Jaboticabal. DOI: https://doi.org/10.1145/3330204.3330266. Disponível em: http://hdl.handle.net/11449/192448. Acesso em: 04 out. 2024.

PEREIRA, D. F.; BUGATTI, P. H.; LOPES, F. M.; SOUZA, A. L. S. M.; SAITO, P. T. M. An Intelligent System to Enhance the Productivity and Sustainability in Soybean Crop Enterprises. *In*: BRAZILIAN SYMPOSIUM ON INFORMATION SYSTEMS, 15., 2019, New York. **Proceedings** […]. New York: Association for Computing Machinery, 2019. p. 1–8. DOI: https://doi.org/10.1145/3330204.3330266. Acesso em: 04 out. 2024.

REDMON, J.; DIVVALA, S.; GIRSHICK, R.; FARHADI, A. You only look once: unified, real-time object detection. **ArXiv** preprint arXiv1506.02640, 2016. DOI: 10.48550/arXiv.1506.02640. Disponível em: https://arxiv.org/abs/1506.02640. Acesso em: 07 out. 2025.

SOARES, J. S.; SORGATO, J. C.; RIBEIRO, L. M.; RAMOS, J. M. C. Teste de viabilidade de sementes de orquídeas nativas do Cerrado brasileiro**. Pesquisa Agropecuária Tropical,** Goiânia, v. 51, e67069, 2021. Disponível em: https://revistas.ufg.br/pat/article/view/67069. Acesso em: 02 out. 2024.

TERVEN, J.; CÓRDOVA-ESPARZA, D.-M.; ROMERO-GONZÁLEZ, J.-A. A Comprehensive Review of YOLO Architectures in Computer Vision: From YOLOv1 to YOLOv8 and YOLO-NAS**. Machine Learning and Knowledge Extraction**, v. 5, n. 4, p. 1680-1716, 2023. DOI: https://doi.org/10.3390/make5040083.

TIAN, L.; FANG, Z.; JIANG, H.; LIU, S.; ZHANG, H.; FU, X. Assessment of germination vigor in tomato seeds across the full-time sequence**. SSRN**, 2024. DOI: http://dx.doi.org/10.2139/ssrn.4713198.

TIAN, Z.; SHEN, C.; CHEN, H.; HE, T. FCOS: Fully convolutional one-stage object detection. **ArXiv** preprint arXiv:1904.01355, 2019. DOI: 10.48550/arXiv.1904.01355. Disponível em: https://arxiv.org/abs/1904.01355. Acesso em: 01 out. 2025.

WANG, C.-Y.; LIAO, H.-Y. M.; YEH, I.-H.; WU, Y.-H.; CHEN, P.-Y.; HSIEH, J.-W. CSPNET: a new backbone that can enhance learning capability of cnn**. ArXiv** preprint arXiv:1911.11929, 2019. DOI: 10.48550/arXiv.1911.11929Disponível em: https://arxiv.org/abs/1911.11929. Acesso em: 29 out. 2025.

WATANABE, D.T. **Sistema de visão computacional para a contagem de sementes de soja.** 2019. Monografia (Graduação em Engenharia Elétrica) - Universidade Tecnológica Federal do Paraná, Curitiba, 2019. Disponível em: http://repositorio.utfpr.edu.br:8080/jspui/handle/1/17103. Acesso em: 06 out. 2024.

YANG, S.; ZHENG, L.; HE, P.; *et al.* High-throughput soybean seeds phenotyping with convolutional neural networks and transfer learning**. Plant Methods**, v. 17, n. 50, 2021. DOI: https://doi.org/10.1186/s13007-021-00749-y.

ZORZAL, T.A.; FANTINATO, D.E.; CAMPOS, L. M.; LUZ, A. C. C.; CORTE, V.B. Teste do tetrazólio para estimativa da viabilidade de sementes. **Natureza on line**, v. 13, n. 3, p. 144-149, 2015. Disponível em: https://www.naturezaonline.emnuvens.com.br/revista/article/view/163. Acesso em: 05 out. 2024.