

**CLASSIFICAÇÃO E
DETECÇÃO AUTOMÁTICA
DE SEMENTES DE SOJA
POR MEIO DE VISÃO
COMPUTACIONAL E
APRENDIZADO PROFUNDO**

**AUTOMATIC CLASSIFICATION AND DETECTION OF SOYBEAN SEEDS
USING COMPUTER VISION AND DEEP LEARNING**

Ciências Exatas e da Terra, Ciências Agrárias, Engenharias • 19/06/2026

REGISTRO DOI: [10.70773/revistatopicos/781811144](https://doi.org/10.70773/revistatopicos/781811144)

Luís Impieri Oliveira¹
Benjamim Eliel Nicácio Ribeiro²
Isabela Maria Gonçalves Cardoso³
Johão Vyctor Nunes Campêlo⁴
Luiz Felipe Cerqueira Guimarães⁵
João Gabriel Silva dos Santos⁶
Luis Eduardo José de Carvalho⁷
Sthefane Dias Silva⁸
João Arthur Pereira de Souza⁹
Leandro Sanches Launé¹⁰
Giovanni Lucca França da Silva¹¹

RESUMO

A garantia da qualidade das sementes de soja é um fator determinante para o sucesso da produção agrícola global, dada a relevância desta cultura como fonte de proteína e óleo. Este trabalho apresenta o desenvolvimento de um sistema de visão computacional estruturado em seis fases experimentais evolutivas para a detecção e classificação automatizada de sementes. Inicialmente, um modelo baseline baseado em Redes Neurais Convolucionais treinado do zero demonstrou limitações severas, com acurácia de apenas 20%. A introdução de técnicas de *transfer learning* com a arquitetura profunda *EfficientNet* elevou significativamente o desempenho para 90%. O refinamento do pipeline, aliado a técnicas de interpretabilidade via *Grad-CAM*, permitiu atingir 92% de acurácia, validando o foco da rede nas áreas de dano. Por fim, visando a aplicação em cenários industriais reais, iniciou-se a estruturação de uma arquitetura híbrida integrando o modelo *YOLO* para a detecção de múltiplas sementes em tempo real e a rede *EfficientNet* para a classificação final. Os resultados confirmam que a combinação de arquiteturas profundas pré-treinadas e métodos de detecção de objetos oferece uma solução robusta para a triagem qualitativa de grãos.

Palavras-chave: Visão Computacional; Aprendizado Profundo; Redes Neurais Convolucionais; Classificação de grãos de soja; Agricultura de Precisão.

ABSTRACT

Ensuring soybean seed quality is a decisive factor for the success of global agricultural production, given the crop's relevance as a source of protein and oil. This study presents the development of a computer vision system structured across six evolutionary experimental phases for automated seed detection and

classification. Initially, a baseline model based on Convolutional Neural Networks trained from scratch showed severe limitations, with an accuracy of only 20%. The introduction of transfer learning techniques using the EfficientNet deep architecture significantly improved performance to 90%. Pipeline refinement, combined with interpretability techniques via Grad-CAM, allowed the model to reach 92% accuracy, validating the network's focus on damaged areas. Finally, aiming for application in real-world industrial scenarios, the structuring of a hybrid architecture began, integrating the YOLO model for multi-seed detection in real-time and the EfficientNet network for final classification. The results confirm that the combination of pre-trained deep architectures and object detection methods offers a robust solution for the qualitative screening of grains.

Keywords: Computer Vision; Deep Learning; Convolutional Neural Networks; Soybean Seed Classification; Precision Agriculture.

1. INTRODUÇÃO

A contínua expansão da demanda global por suprimentos agrícolas coloca a cultura da soja no epicentro das estratégias de segurança alimentar e de produção de biocombustíveis. Sendo um dos principais pilares do agronegócio mundial, a produtividade e a rentabilidade desta commodity estão intrinsecamente ligadas ao vigor, à pureza e à integridade de seu material propagativo e de processamento. Nesse macrocenário, o controle rigoroso da qualidade das sementes transcende a mera exigência regulatória, configurando-se como um vetor crítico para assegurar altas taxas de germinação no campo, mitigar a disseminação de patógenos e maximizar o valor comercial do produto final na indústria de beneficiamento. (FRANÇA NETO et al., 2016).

Apesar dos avanços substanciais na agricultura de precisão e no monitoramento mecanizado de safras, a etapa de classificação de qualidade pós-colheita ainda enfrenta um severo gargalo tecnológico. Historicamente, a triagem e a identificação de anomalias morfofisiológicas dependem de forma quase exclusiva da inspeção visual humana. Trata-se de um método inerentemente subjetivo, de baixa vazão e altamente suscetível a vieses e erros induzidos pela fadiga do operador em linhas de processamento contínuas (Lin et al., 2019). A ausência de padronização e a lentidão na detecção de danos mecânicos, grãos imaturos ou infecções resultam em perdas econômicas significativas e ineficiência operacional na cadeia de suprimentos (CHIMLEK; CHIMLEK, 2019).

Para mitigar essas limitações, a interseção entre a Visão Computacional e o Aprendizado Profundo tem se consolidado como o paradigma definitivo para a automação da fenotipagem de sementes (SUN et al., 2025). Mais especificamente, as Redes Neurais Convolucionais provaram ser ferramentas excepcionais na extração de representações visuais hierárquicas e complexas, permitindo análises não destrutivas, escaláveis e de alta precisão diretamente a partir de dados de imagem (UZAL et al., 2018; MEDEIROS et al., 2020).

Diante desta demanda tecnológica do setor, o presente trabalho tem como objetivo projetar, desenvolver e avaliar um pipeline de inteligência artificial robusto, capaz de categorizar automaticamente sementes de soja em cinco classes específicas de qualidade. Adotando uma metodologia científica evolutiva, a pesquisa avança desde a estruturação de um baseline exploratório inicial até a concepção de um sistema complexo e interpretável que integra detecção de objetos e classificação em múltiplas etapas, visando


transpor as barreiras laboratoriais e viabilizar a implantação destas tecnologias em cenários reais do agronegócio.

2. FUNDAMENTAÇÃO TEÓRICA

Esta seção apresenta o arcabouço tecnológico e os conceitos computacionais que embasam a metodologia adotada neste estudo. Serão detalhados os fundamentos das Redes Neurais Convolucionais (CNNs), as estratégias de aprendizado por transferência, as especificidades da arquitetura profunda EfficientNet, os métodos de interpretabilidade visual via Grad-CAM e, por fim, os princípios de detecção de objetos baseados na arquitetura YOLO.3.1 Redes Neurais Convolucionais.

As Redes Neurais Convolucionais representam uma categoria proeminente de modelos de inteligência artificial desenhados para processar dados dispostos em topologias de grade, como imagens digitais bidimensionais. No contexto da visão computacional aplicada, as CNNs destacam-se por sua notável capacidade de aprender representações visuais complexas diretamente a partir de imagens em estado bruto, dispensando a engenharia manual de características (JAVANMARDI et al., 2021). A Figura 1 ilustra a arquitetura típica de uma CNN, evidenciando seu encadeamento hierárquico de camadas.

Figura 1 - Arquitetura CNN



Fonte: Carvalho e Carvalho (2020).

A estrutura típica de uma CNN é composta por um encadeamento hierárquico de camadas, destacando-se:

1. Camadas Convolucionais (Conv2D): Operam aplicando filtros móveis (kernels) sobre a imagem de entrada, gerando mapas de ativação que capturam padrões locais essenciais, evoluindo de bordas e texturas simples nas camadas iniciais para formas morfolologicamente complexas nas camadas mais profundas.
2. Camadas de Agrupamento (Pooling): Executadas tipicamente após as convoluções (ex: MaxPooling), possuem a função de reduzir a dimensionalidade espacial dos mapas de características. Isso diminui a carga computacional e confere invariância translacional à rede, tornando-a robusta a pequenas distorções anatômicas nas sementes.
3. Camadas Densas (Fully Connected / Dense): Localizadas no estágio final da rede após a vetorização dos dados (Flatten), são responsáveis por agregar as características extraídas de alto nível e realizar o mapeamento não linear para as classes de saída. Para problemas multiclasse, como a categorização de sementes, emprega-se a função de ativação Softmax para gerar uma distribuição de probabilidade sobre as classes possíveis.

4. Aprendizado por Transferência (Transfer Learning) O treinamento de CNNs profundas a partir do zero exige volumes massivos de dados rotulados. No domínio agrícola, a aquisição e a anotação de grandes datasets de sementes com anomalias específicas consistem em um gargalo operacional. Diante disso, o aprendizado por transferência (Transfer Learning) surge como uma estratégia analítica fundamental. Essa abordagem permite aproveitar o conhecimento previamente aprendido por modelos treinados em bases de dados genéricas de larga escala, como o ImageNet.


A técnica melhora significativamente a capacidade de generalização em problemas com conjuntos de dados relativamente limitados (YANG et al., 2021). O protocolo padrão envolve instanciar a rede pré-treinada, congelar os pesos de suas camadas iniciais (que atuam como extratores genéricos de bordas e texturas) e substituir o cabeçote de classificação original por uma nova camada densa configurada para as categorias do problema alvo (ex: cinco neurônios correspondentes às condições da soja).

2.1. Arquitetura Efficientnet

A seleção da arquitetura de extração de características configura-se como um vetor crítico para o equilíbrio entre a carga computacional e a precisão analítica. A EfficientNet representa uma família contemporânea de modelos concebida para maximizar essa eficiência operacional por meio de uma estratégia matemática de escalonamento balanceado da rede neural. Tal princípio pode ser observado na representação esquemática apresentada na Figura 2, em contraste com arquiteturas que expandem de forma arbitrária a profundidade, a largura ou a resolução da imagem. A EfficientNet

propõe um coeficiente composto que dimensiona esses três fatores simultaneamente e de forma uniforme, conferindo ao modelo uma capacidade proeminente de extração de representações visuais com um volume substancialmente menor de parâmetros em comparação a arquiteturas convencionais, assegurando alto desempenho em tarefas complexas de categorização fenotípica.

Figura 2 - Arquitetura EfficientNET



2.2. Interpretabilidade Visual com Grad-CAM

A implementação de redes profundas em sistemas de controle de qualidade industrial esbarra na falta de transparência inerente a esses modelos, frequentemente descritos como "caixas-pretas". Para mitigar esse paradigma, técnicas de interpretabilidade são aplicadas para decodificar o comportamento da rede neural. O método Grad-CAM (Gradient-weighted Class Activation Mapping) é utilizado para gerar mapas de ativação (mapas de calor) que destacam, de forma visual, as regiões da imagem mais relevantes para a predição final do modelo. Ao rastrear os gradientes da classe alvo fluindo para a última camada convolucional, o Grad-CAM comprova se o modelo baseia sua decisão em características patológicas reais da semente, como rupturas ou manchas na casca, elevando o grau de confiabilidade e validação científica do sistema.

2.3. Detecção de Objetos e a Arquitetura YOLO

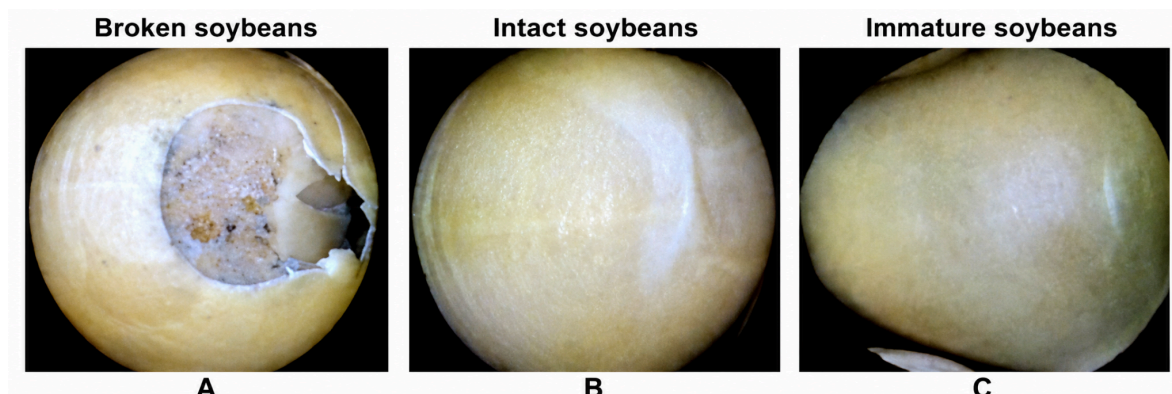
Enquanto os modelos de classificação operam sob a premissa de que a imagem contém uma única instância centralizada, aplicações agrícolas reais exigem a análise de múltiplas sementes distribuídas aleatoriamente em uma cena. Para realizar a transição do laboratório para o cenário industrial, faz-se necessário o uso de modelos de detecção de objetos (GUERRA; RIBEIRO, 2025). A arquitetura YOLO destaca-se por realizar a detecção de forma extremamente veloz e precisa. Diferente de modelos em duas etapas, que são baseadas em propostas de regiões, o YOLO trata a detecção como um problema único de regressão. O algoritmo divide a imagem em uma grade de células, onde cada célula prevê, simultaneamente, múltiplas *bounding boxes* (caixas delimitadoras), o nível de confiança da presença do objeto e a probabilidade das classes. Essa formulação unificada permite a localização e o isolamento automático de múltiplos grãos em tempo real, fornecendo os recortes necessários para alimentar a rede de classificação subsequente.

3. METODOLOGIA

A metodologia adotada para a consecução deste estudo estruturou-se em etapas interdependentes e evolutivas, como se observa na Figura 3, avançando sistematicamente desde a aquisição dos dados brutos até a concepção de uma arquitetura híbrida para a detecção e classificação automatizada de sementes de soja. O arcabouço de dados abrangeu cinco categorias morfológicas distintas, representadas na ilustração: a Figura 3-A corresponde às sementes quebradas, evidenciando danos físicos e perda de integridade estrutural; a Figura 3-B apresenta sementes intactas, com conformação visual preservada; e a Figura 3-C retrata sementes imaturas, caracterizadas por aspecto fenotípico ainda não completamente desenvolvido. Esse conjunto foi complementado

pelo *Soybean Detection Dataset* (Roboflow), destinado a viabilizar a localização espacial por meio de anotações no formato YOLO.

Figura 3 - Tipos de semente



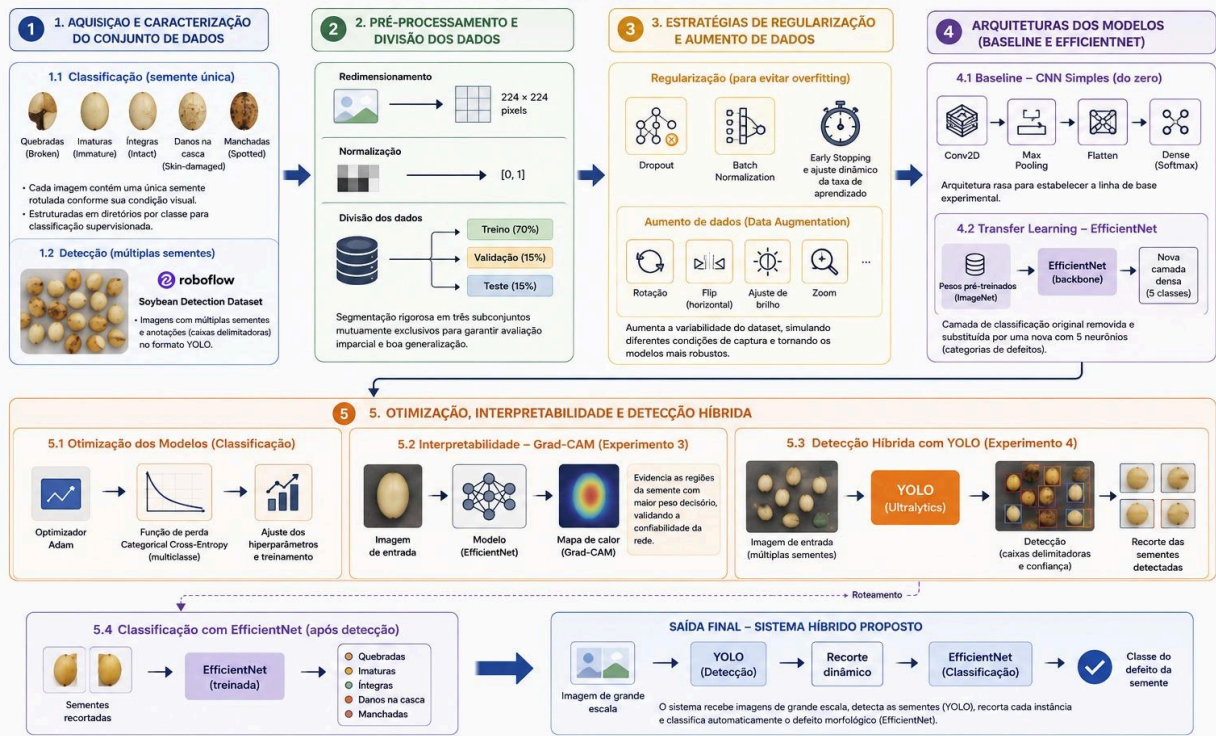
Fonte: Roboflow.

O protocolo de pré-processamento envolveu o redimensionamento das imagens para o padrão de 224×224 pixels e a normalização de intensidades, além da aplicação de técnicas de *data augmentation* e estratégias de regularização via *Dropout* e *Batch Normalization* para mitigar o *overfitting*. A definição das arquiteturas seguiu uma progressão rigorosa, como sintetiza a Figura 4: estabeleceu-se inicialmente uma CNN simples como *baseline* exploratório que demonstrou limitações com apenas 20% de acurácia, avançando-se para o paradigma de *transfer learning* com a família EfficientNet (B0, B2 e B3). O modelo B3, sob *fine-tuning* avançado, atingiu o ápice de 92% de acurácia, sendo validado qualitativamente por mapas de calor Grad-CAM. Por fim, a integração do modelo YOLO (Ultralytics) consolidou a arquitetura híbrida final, na qual cenas complexas com múltiplas sementes são submetidas à detecção e recorte dinâmico, sendo os fragmentos resultantes roteados à rede EfficientNet para a classificação automatizada do defeito morfológico.

Figura 4 - Fluxo da metodologia

FLUXO DA METODOLOGIA

Visão geral das etapas e experimentos realizados no estudo



Fonte: autoria própria (2026).

3.1. Aquisição e Caracterização do Conjunto de Dados

O estudo empregou conjuntos de dados de imagens de sementes de soja organizadas em cinco categorias morfológicas distintas: sementes quebradas (*Broken soybeans*), imaturas (*Immature soybeans*), intactas (*Intact soybeans*), com danos na casca (*Skin-damaged soybeans*) e manchadas (*Spotted soybeans*). Cada imagem de classificação contém uma única semente rotulada de acordo com sua respectiva condição visual, estruturada em diretórios por classe para permitir o uso direto em métodos de classificação supervisionada. Para viabilizar a etapa avançada de localização espacial (Experimento 4), incorporou-se o "Soybean Detection Dataset", hospedado na plataforma Roboflow. Este conjunto fornece imagens de cenários mais complexos com múltiplas sementes e suas respectivas anotações de caixas delimitadoras exportadas no formato YOLO, sendo um insumo

fundamental para o treinamento de modelos de detecção de objetos.

3.2. Pré-processamento

A fim de assegurar uniformidade dimensional e estabilidade durante o treinamento das redes neurais, implementaram-se etapas sistemáticas de pré-processamento. Inicialmente, todas as imagens destinadas à classificação, independentemente de sua resolução nativa, foram redimensionadas para as dimensões padronizadas de 224×224 pixels, formato amplamente adotado por garantir compatibilidade estrutural com arquiteturas modernas de redes convolucionais profundas. Em sequência, os valores de intensidade dos pixels originais foram normalizados para o intervalo de ponto flutuante $[0, 1]$, mitigando discrepâncias de iluminação e facilitando a convergência matemática do modelo durante o ajuste dos pesos.

3.3. Estratégias de Regularização e Aumento de Dados

Reconhecendo a complexidade visual do problema — onde as fronteiras discriminativas entre classes de sementes podem ser sutis —, e visando superar as severas limitações identificadas no *pipeline* do experimento inicial, foi implementada uma robusta estratégia de regularização. Para contornar a adaptação excessiva (*overfitting*) aos dados de treino, foram aplicadas as técnicas de *Dropout* e *Batch Normalization*, que injetam ruído estocástico e normalizam as ativações intermediárias, respectivamente, promovendo maior estabilidade. Adicionalmente, o diagnóstico inicial determinou a necessidade da aplicação de técnicas de aumento de dados (*data augmentation*) para elevar substancialmente a variabilidade do *dataset*, simulando condições variadas de captura e orientando o

desenvolvimento de experimentos mais robustos. O controle de qualidade do treinamento foi garantido mediante o uso de parada antecipada (*Early stopping*) e ajuste dinâmico da taxa de aprendizado, interrompendo a otimização assim que a melhoria na validação estagnava.

3.4. Arquiteturas dos Modelos (Baseline e Efficientnet)

A definição da arquitetura classificadora seguiu um princípio metodológico evolutivo. O primeiro estágio estabeleceu um *baseline* experimental por meio de uma Rede Neural Convolutiva simples, instanciada do zero, compreendendo operações sequenciais de convolução (Conv2D), agrupamento espacial (MaxPooling), vetorização (Flatten) e uma camada densa finalizada com a ativação *Softmax*. Evidenciada a capacidade limitada dessa topologia rasa, o estudo avançou para o paradigma de aprendizado por transferência (*Transfer Learning*), adotando a arquitetura EfficientNet. Projetada para maximizar a eficiência computacional por meio de escalonamento balanceado, a EfficientNet foi inicializada com pesos pré-treinados em repositórios massivos, sendo sua camada de classificação original suprimida e substituída por uma nova configuração contendo cinco neurônios correspondentes às categorias do agronegócio.

4. RESULTADOS E DISCUSSÕES

A progressão metodológica adotada neste estudo refletiu-se de maneira expressiva nas métricas de desempenho obtidas ao longo de cinco fases de experimentação. O projeto evoluiu de uma classificação básica com arquiteturas rasas para a proposição de um sistema completo de visão computacional, culminando em um

pipeline híbrido projetado para aplicações reais na agricultura de precisão.

4.1. Experimento 1: Avaliação do Modelo Baseline (CNN)

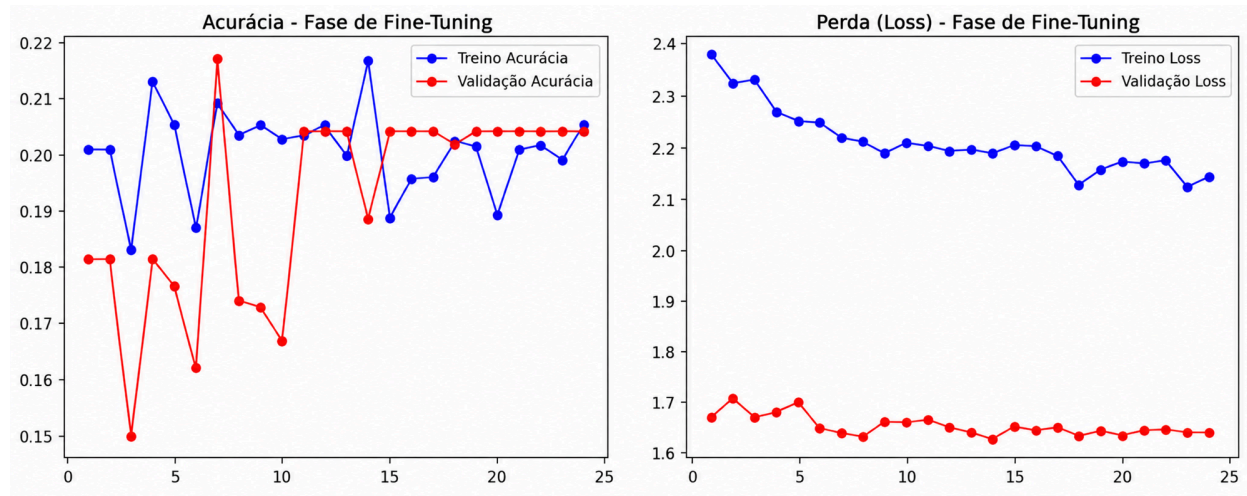
Avaliação do Modelo Baseline O primeiro experimento teve como objetivo criar um modelo inicial de classificação para testar a hipótese de que uma Rede Neural Convolutiva simples poderia aprender os padrões básicos das sementes. A rede foi construída do zero (sem transfer learning) e treinada com pesos aleatórios. Os resultados confirmaram a limitação de arquiteturas de baixa capacidade para este problema complexo. O modelo obteve uma acurácia de aproximadamente 20%, um índice que equivale estatisticamente ao desempenho de um classificador puramente aleatório em um espaço amostral de cinco classes. A rede não foi capaz de aprender os padrões morfológicos das sementes, evidenciando a necessidade de modelos mais robustos.

4.2. Experimento 2: Introdução Ao Transfer Learning (Efficientnetb0)

Para superar a barreira representacional da CNN simples, o Experimento 2 introduziu o paradigma de transfer learning utilizando a arquitetura pré-treinada EfficientNetB0, adaptando a camada final para as 5 classes do estudo e aplicando técnicas de data augmentation. Houve um salto qualitativo expressivo: o modelo demonstrou aprendizado real de padrões visuais, elevando a acurácia para a faixa de 88% a 90%. Conforme evidenciado na Figura 5, as curvas de acurácia e perda do modelo EfficientNetB0 na fase de fine-tuning mostram a evolução do aprendizado e a estabilidade relativa da validação. Embora o desempenho tenha sido

substancialmente superior, observou-se um leve overfitting e confusão residual entre classes com altíssima similaridade visual.

Figura 5 - Curvas de acurácia e perda do modelo EfficientNetB0 na fase de fine-tuning

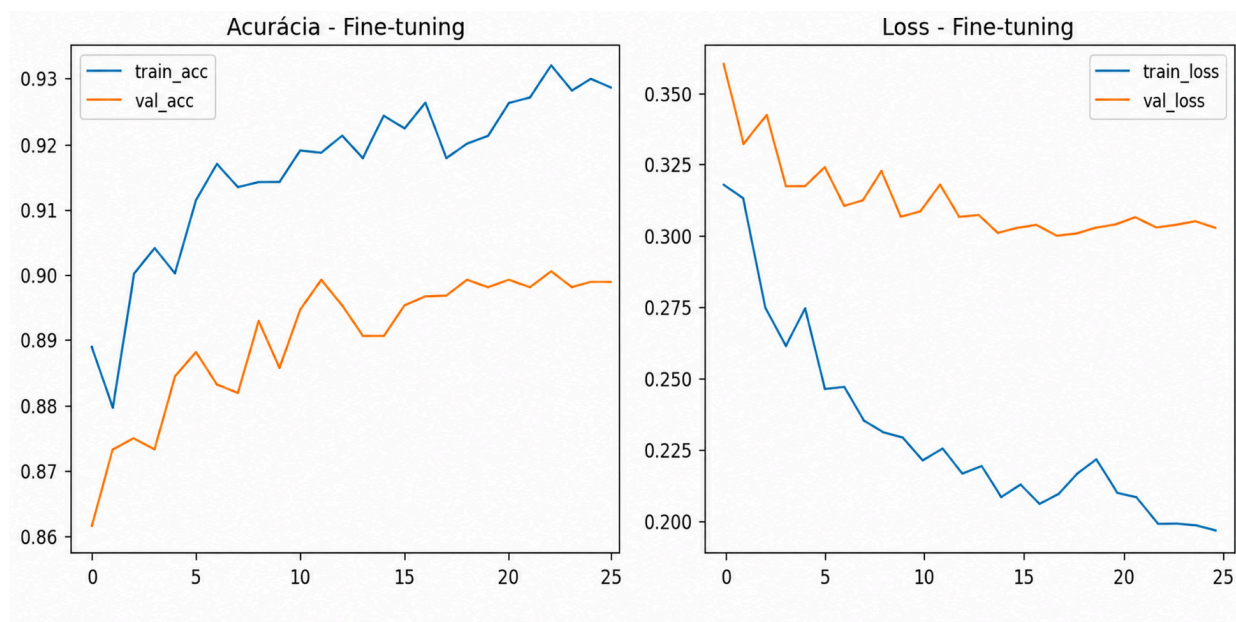


Fonte: autoria própria (2026).

4.3. Experimento 3: Aumento de Capacidade e Generalização (*EfficientNetB2*)

Buscando refinar a generalização e reduzir as confusões entre classes, o Experimento 3 adotou uma arquitetura mais profunda, a *EfficientNetB2*. O treinamento incorporou *fine-tuning* parcial, ajuste rigoroso de hiperparâmetros, callbacks e técnicas de regularização. A Figura 6 evidencia o comportamento das curvas de acurácia e perda do modelo *EfficientNetB2* durante a fase de *fine-tuning*, indicando desempenho mais consistente e melhor equilíbrio na discriminação das classes. O aumento da profundidade da rede resultou em um desempenho mais consistente e um melhor equilíbrio na discriminação das classes. O *overfitting* foi reduzido a níveis muito baixos, consolidando uma acurácia global em torno de 91%, justificando o aumento no custo computacional.

Figura 6 - Curvas de acurácia e perda do modelo *EfficientNetB0* na fase de fine-tuning

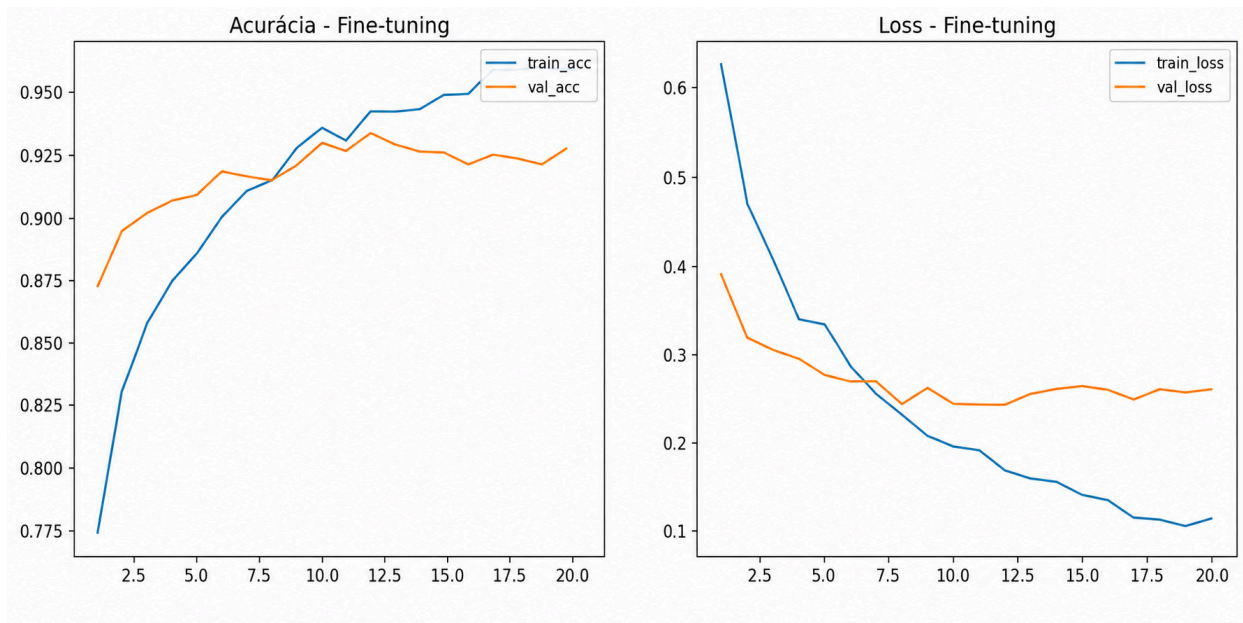


Fonte: autoria própria (2026).

4.4. Experimento 4: Maximização do Desempenho e Interpretabilidade (*EfficientNetB3*)

O quarto experimento representou o ápice do classificador isolado. A arquitetura *EfficientNetB3* foi submetida a um fine-tuning avançado, integrando camadas de Batch Normalization e Dropout no pipeline. Este foi o melhor modelo de classificação do projeto, atingindo 92% de acurácia. Na Figura 7, observa-se o desempenho do *EfficientNetB3* durante o fine-tuning, evidenciando melhor estabilidade das curvas de aprendizado e maior consistência entre treinamento e validação. Além da alta confiabilidade das métricas, o modelo foi validado qualitativamente via algoritmo Grad-CAM. Os mapas de ativação confirmaram que a rede efetivamente direcionou seu foco de inferência para as regiões fenotípicas críticas da semente, atestando a validade agrônômica do aprendizado.

Figura 7 - Curvas de acurácia e perda do modelo *EfficientNetB3* na fase de fine-tuning



Fonte: autoria própria (2026).

4.5. Experimento 5: Detecção e Localização em Cenários Reais (YOLO)

A fim de transpor a classificação de amostras isoladas para a dinâmica operacional de esteiras industriais, o Experimento 5 focou na detecção de múltiplas sementes em imagens amplas. Utilizou-se o modelo *YOLO (Ultralytics)*, treinado sobre um *dataset* mapeado com *bounding boxes*. A Tabela X sintetiza o desempenho do modelo em diferentes combinações de *confidence* e *IoU*, com precisão notável de 0,97 e mAP50 de 0,87 em sua melhor configuração. Embora o Recall (0.75) indique margem para melhoria na captura de todos os grãos presentes na cena, a altíssima precisão garante que as sementes detectadas sejam localizadas com grande exatidão.

Tabela 1 - Desempenho do modelo YOLO em diferentes combinações de confidence e IoU

	conf	iou	precision_all	recall_all	f1_all	mAP50_all
0	0.25	0.45	0.973031	0.759259	0.852955	0.871322
1	0.25	0.55	0.973031	0.759259	0.852955	0.871322
2	0.25	0.65	0.971983	0.759259	0.852552	0.870934
3	0.25	0.75	0.969892	0.759259	0.851747	0.870436
4	0.35	0.45	0.978597	0.692761	0.811237	0.839626
5	0.35	0.55	0.978597	0.692761	0.811237	0.839626
6	0.35	0.65	0.977435	0.692761	0.810837	0.839260
7	0.35	0.75	0.976275	0.692761	0.810438	0.838932
8	0.45	0.45	0.984476	0.640572	0.776135	0.815000
9	0.45	0.55	0.984476	0.640572	0.776135	0.815000

Fonte: autoria própria (2026)

4.6. Otimização, Interpretabilidade e Detecção Híbrida

O processo de otimização de ambas as redes utilizou o algoritmo Adam, minimizando a função de perda *Categorical Cross-Entropy*, ideal para categorização multiclasse. Como forma de elevar o rigor científico, o refinamento do modelo profundo (Experimento 3) introduziu o Grad-CAM, técnica de interpretabilidade visual que gera mapas térmicos para evidenciar as regiões da semente com maior peso decisório, validando a confiabilidade extrativa da rede.

Por fim, para superar a limitação de operar apenas com instâncias de sementes únicas e recortadas, o quarto estágio metodológico estabeleceu a fundação de um sistema de detecção utilizando o modelo YOLO, via biblioteca Ultralytics. Tratando a detecção como um problema de regressão unificada, o YOLO foi configurado para identificar múltiplas sementes simultaneamente, gerando caixas delimitadoras e níveis de confiança. Esse desenvolvimento consolida a arquitetura híbrida final proposta pelo estudo: a submissão de imagens de grande escala ao YOLO para recorte dinâmico dos grãos,

seguido do roteamento imediato à EfficientNet para a classificação automatizada do defeito morfológico.

5. CONCLUSÃO

Os resultados apresentados confirmam a eficácia e a viabilidade da metodologia baseada em aprendizado profundo e visão computacional para a inspeção e classificação automática de sementes de soja. A evolução metodológica evidenciou de forma clara a importância das escolhas arquitetônicas: enquanto o modelo *baseline* inicial obteve um desempenho substancialmente limitado, com acurácia próxima a 20% , a adoção do aprendizado por transferência por meio da arquitetura EfficientNet permitiu um salto expressivo para 90% de acurácia no segundo estágio. Com o refinamento das estratégias de regularização e otimização conduzidas no terceiro experimento, o modelo gerado apresentou um desempenho ainda mais consistente, atingindo 92% de acurácia.

Além do alto desempenho quantitativo, a validação qualitativa suportada pela técnica Grad-CAM assegurou que o sistema atue com alta confiabilidade. Os mapas de ativação comprovaram que as previsões do algoritmo estão corretamente ancoradas nas características morfológicas vitais dos grãos, como fissuras e manchas, mitigando o efeito "caixa-preta" e garantindo o rigor metodológico exigido pelo setor agrícola. Ademais, a implementação preliminar do modelo YOLO marcou um passo decisivo na transição tecnológica da pesquisa, transformando um modelo laboratorial restrito à classificação de recortes individuais em uma infraestrutura completa de detecção de objetos aplicável ao mundo real.

Em síntese, os resultados alcançados evidenciam que o *pipeline* elaborado é plenamente apto a distinguir de maneira eficiente as diferentes anomalias e condições das sementes, reforçando o enorme potencial desta abordagem para compor sistemas inteligentes de vigilância, triagem e controle de qualidade contínuo no agronegócio.

5.1. Limitações e Trabalhos Futuros

A análise dos resultados evidencia de forma clara as principais limitações do estudo em seu estágio atual, bem como sugere direcionamentos relevantes para investigações futuras. A principal limitação inicial superada ao longo da pesquisa referia-se à dependência analítica de imagens contendo um único grão previamente centralizado, um cenário idealizado que não reflete a distribuição estocástica e a complexidade visual das esteiras de processamento agroindustrial. Embora o Experimento 4 tenha estruturado a fundação do *pipeline* de detecção para contornar essa restrição técnica, o modelo YOLO inserido ainda carece de validação quantitativa exaustiva frente a dados inéditos.

Neste contexto, recomenda-se como estratégia futura:

- Realizar o treinamento completo do modelo YOLO sobre o conjunto de dados anotados, executando uma avaliação rigorosa de desempenho por meio de métricas balizadoras em detecção de objetos, notadamente a *mean Average Precision* (mAP), precisão e revocação (*recall*);
- Consolidar a arquitetura híbrida contínua, construindo um *pipeline* totalmente automatizado no qual o YOLO executa a localização espacial e a segmentação simultânea das sementes,

repassando os recortes de forma dinâmica para a EfficientNet efetuar a classificação dos defeitos;

- Validar o modelo integrado em ambientes simulados de operação real, submetendo o algoritmo a diferentes condições de campo e maquinário (como variações de iluminação, fundo ruidoso e oclusão parcial dos grãos), que representam o verdadeiro desafio operacional na agricultura de precisão;
- Explorar a fusão de dados multimodais em abordagens futuras, integrando métricas globais de campo, como o índice NDVI (ESTEVAM et al., 2023), para correlacionar estatisticamente a saúde geral da planta durante o ciclo de cultivo com as características fenotípicas do grão classificado no pós-colheita.

Essas recomendações buscam consolidar a robustez e a aplicabilidade prática dos sistemas de visão computacional voltados ao agronegócio, promovendo avanços significativos na eficiência, automação e adaptabilidade do monitoramento de qualidade na produção de soja.

REFERÊNCIAS BIBLIOGRÁFICAS

AHMED, Tashin; SABAB, Noor Hossain Nuri. ***Classification and understanding of cloud structures via satellite images with EfficientUNet.*** arXiv, 2020. DOI: 10.48550/arXiv.2009.12931. Disponível em: <https://arxiv.org/abs/2009.12931>. Acesso em: 21 maio 2026.

CARVALHO, Edelson Damasceno; CARVALHO, Edson Damasceno. ***Classification of CT images in COVID-19 and Non-COVID-19 using CNN to extract features and multiple classifiers.*** In: ESCOLA REGIONAL DE COMPUTAÇÃO CEARÁ, MARANHÃO, PIAUÍ

(ERCEMAPI), 8., 2020. Anais [...]. Porto Alegre: Sociedade Brasileira de Computação, 2020. DOI: 10.5753/ercemapi.2020.11493. Disponível em: <https://doi.org/10.5753/ercemapi.2020.11493>. Acesso em: 21 maio 2026.

CHIMLEK, Sutasinee; CHIMLEK, Pawat. **Quality grading of soybean seeds using image analysis**. International Journal of Electrical and Computer Engineering (IJECE), v. 9, n. 5, p. 3495-3503, 2019. Disponível em: <https://ijece.iaescore.com/index.php/IJECE/article/view/15417>. Acesso em: 20 mar. 2026.

ESTEVAM, Vitória da Silva; REGES, Nívea Patrícia Ribeiro; SANTOS, Marcos Paulo dos. **Use of the NDVI index for phenological determination of soybean**. Revista Uniaraguaia, Goiânia, v. 18, n. 1, p. 106-116, jan./abr. 2023. Disponível em: <https://revistas.animaeducacao.com.br/index.php/uniaraguaia/article/view/118>. Acesso em: 28 abr. 2026.

FRANÇA NETO, José de Barros et al. **Tecnologia da produção de semente de soja de alta qualidade**. Londrina: Embrapa Soja, 2016.

GUERRA, Matheus M.; RIBEIRO, Lucas de Almeida. **Detecção e quantificação de grãos de soja pós-colheita utilizando visão computacional e aprendizado profundo**. Anais da Escola Regional de Informática de Goiás (ERIGO), Goiânia, 2025. Disponível em: <https://sol.sbc.org.br/index.php/erigo/article/view/39542/>. Acesso em: 28 abr. 2026.

JAVANMARDI, Shima et al. **Computer-vision classification of corn seed varieties using deep convolutional neural network**. Journal of Stored Products Research, v. 92, p. 101800, 2021. Disponível em: <https://doi.org/10.1016/j.jspr.2021.101800>. Acesso em: 28 abr. 2026.

LIN, Ping et al. ***Rapidly and exactly determining postharvest dry soybean seed quality based on machine vision technology.***

Scientific Reports, v. 9, p. 17143, 2019. Disponível em: <https://doi.org/10.1038/s41598-019-53796-w>. Acesso em: 28 abr. 2026.

MEDEIROS, André Dantas de et al. ***Interactive machine learning for soybean seed and seedling quality classification.***

Scientific Reports, v. 10, p. 11267, 2020. Disponível em: <https://doi.org/10.1038/s41598-020-68273-y>. Acesso em: 28 abr. 2026.

SUN, Huihui et al. ***Empowering smart soybean farming with deep learning: progress, challenges, and future perspectives.***

Agronomy, v. 15, n. 8, p. 1831, 2025. Disponível em: <https://doi.org/10.3390/agronomy15081831>. Acesso em: 28 abr. 2026.

UZAL, Lucas C. et al. ***Seed-per-pod estimation for plant breeding using deep learning. Computers and Electronics in Agriculture,*** v.

150, p. 196-204, 2018. Disponível em: <https://doi.org/10.1016/j.compag.2018.04.020>. Acesso em: 28 abr. 2026.

YANG, Si et al. ***High-throughput soybean seeds phenotyping with convolutional neural networks and transfer learning.***

Plant Methods, v. 17, p. 50, 2021. Disponível em: <https://doi.org/10.1186/s13007-021-00749-y>. Acesso em: 28 abr. 2026.

¹ Discente do Curso Superior de Engenharia de Software da Universidade Dom Bosco. E-mail: [acesse o artigo original para visualizar o e-mail](#)

² Discente do Curso Superior de Engenharia de Software da Universidade Dom Bosco. E-mail: [acesse o artigo original para](#)

[visualizar o e-mail](#)

³ Discente do Curso Superior de Engenharia de Software da Universidade Dom Bosco. E-mail: [acesse o artigo original para visualizar o e-mail](#)

⁴ Discente do Curso Superior de Engenharia de Software da Universidade Dom Bosco. E-mail: [acesse o artigo original para visualizar o e-mail](#)

⁵ Discente do Curso Superior de Engenharia de Software da Universidade Dom Bosco. E-mail: [acesse o artigo original para visualizar o e-mail](#)

⁶ Discente do Curso Superior de Engenharia de Software da Universidade Dom Bosco. E-mail: [acesse o artigo original para visualizar o e-mail](#)

⁷ Discente do Curso Superior de Engenharia de Software da Universidade Dom Bosco. E-mail: [acesse o artigo original para visualizar o e-mail](#)

⁸ Discente do Curso Superior de Engenharia de Software da Universidade Dom Bosco. E-mail: [acesse o artigo original para visualizar o e-mail](#)

⁹ Discente do Curso Superior de Engenharia de Software da Universidade Dom Bosco. E-mail: [acesse o artigo original para visualizar o e-mail](#)

¹⁰ Discente do Curso Superior de Engenharia de Software da Universidade Dom Bosco. E-mail: [acesse o artigo original para visualizar o e-mail](#)

¹¹ Docente do Curso Superior de Engenharia de Software da Universidade Dom Bosco. E-mail: [acesse o artigo original para visualizar o e-mail](#)