

Classificação de Defeitos em Grãos de Soja por Visão Computacional e Redes Neurais Convolucionais

Gesmar de Paula Santos Júnior¹, Alexandre Cardoso¹, Pedro Cunha Antero de Carvalho², Leonardo Garcia Marques¹, Bruno Sousa Pereira¹, Gabriel Henrique Camargo Silva¹

¹Universidade Federal de Uberlândia (UFU)

Av. João Naves de Ávila, 2121 - Santa Mônica - Uberlândia - MG - Brazil

²Grider Automação e Tecnologia LTDA

Av. Sacadura Cabral, 478 - Alto Umarama - Uberlândia - MG - Brazil

{gesmarjunior,alexandre}@ufu.br, pedro.carvalho@grider.com.br,
{leonardo.mqs,gabrielhcs1411,brunosousapereira.az}@gmail.com

Abstract. *This paper presents an approach for automatic classification of soybean grain defects using RGB images, automatic segmentation, and a ResNet50 convolutional neural network. The images are acquired in a controlled environment with standardized lighting and a contrasting background. The proposed pipeline performs preprocessing, color space conversion, grain segmentation, individual cropping, dataset organization, and classification. The method was evaluated with 34,049 segmented images divided into training, validation, and test sets. The results indicate the potential of RGB computer vision as a support tool for soybean grain quality classification.*

Resumo. *Este artigo apresenta uma abordagem para classificação automática de defeitos em grãos de soja utilizando imagens RGB, segmentação automática e uma rede neural convolucional ResNet50. As imagens são adquiridas em ambiente controlado, com iluminação padronizada e fundo contrastante. O pipeline proposto realiza pré-processamento, conversão de espaço de cor, segmentação dos grãos, recorte individual das amostras, organização do dataset e classificação. O método foi avaliado com 34.049 imagens segmentadas, divididas em conjuntos de treinamento, validação e teste. Os resultados indicam o potencial da visão computacional RGB como ferramenta de apoio à classificação de qualidade de grãos de soja.*

1. Introdução

A classificação de grãos de soja é uma etapa importante no controle de qualidade agrícola, pois permite identificar características físicas associadas à integridade, maturação e presença de defeitos. Tradicionalmente, esse processo depende de inspeção visual realizada por especialistas, o que pode introduzir subjetividade, variação entre avaliadores e baixa repetibilidade. Nesse contexto, técnicas de visão computacional e aprendizado profundo têm sido aplicadas para automatizar a análise visual de sementes e grãos, reduzindo a dependência da avaliação manual e favorecendo maior padronização [Yang et al. 2021; Zhao et al. 2021].

Imagens digitais associadas a redes neurais convolucionais têm apresentado resultados relevantes em tarefas como fenotipagem, contagem e identificação de defeitos em

sementes de soja. Yang et al. [2021] exploraram redes convolucionais em fenotipagem de sementes, enquanto Zhao et al. [2021] propuseram um sistema de reconhecimento em tempo real para defeitos na superfície de sementes de soja. Além disso, métodos baseados em processamento digital de imagens têm sido empregados para a detecção automática de sementes colhidas, explorando características visuais e morfológicas extraídas das imagens [Sonawane and Mohanty 2021].

Apesar dos avanços, o desempenho de sistemas baseados em visão computacional depende diretamente da qualidade das imagens e da padronização do conjunto de dados. Imagens capturadas com sombras, reflexos, iluminação irregular ou baixo contraste entre objeto e fundo podem prejudicar a segmentação e afetar o treinamento dos modelos. Por isso, a aquisição em ambiente controlado e a segmentação automática dos grãos são etapas relevantes para reduzir ruídos, remover informações irrelevantes e padronizar as amostras fornecidas à rede neural.

Este artigo apresenta uma abordagem para classificação automática de defeitos em grãos de soja utilizando imagens RGB segmentadas e uma rede neural convolucional ResNet50. O método integra aquisição controlada das imagens, segmentação automática, organização do dataset e treinamento do modelo para classificação. As principais contribuições são: i) a estruturação de um pipeline baseado em imagens RGB adquiridas em ambiente controlado; ii) a aplicação de técnicas clássicas de processamento de imagens para segmentação e recorte individual dos grãos; e iii) a validação inicial do dataset por meio do treinamento de uma arquitetura ResNet50. Como trabalhos futuros, pretende-se incorporar imagens multiespectrais e avaliar outras arquiteturas convolucionais.

2. Materiais e Métodos

O método proposto é composto por quatro etapas principais: aquisição controlada das imagens RGB, pré-processamento e segmentação automática dos grãos, organização do dataset por classes e treinamento de uma rede neural convolucional para classificação dos defeitos. A Figura 1 apresenta uma visão geral do fluxo adotado, desde a captura das imagens até a predição da classe do grão.



Figura 1. Fluxo geral do método proposto.

2.1. Aquisição controlada das imagens RGB

As imagens dos grãos de soja foram obtidas em ambiente controlado, utilizando uma estrutura de aquisição composta por câmera RGB, fonte de iluminação artificial, base contrastante e caixa de isolamento. O objetivo dessa configuração foi reduzir interferências externas, como variações de iluminação, sombras e reflexos, garantindo maior repetibilidade entre as capturas.

Os grãos foram distribuídos sobre a base de aquisição, conforme mostra a Figura 2, buscando minimizar sobreposição entre amostras. Após a captura, as imagens foram armazenadas em formato digital RGB e encaminhadas ao pipeline de processamento.

Essa etapa é fundamental, pois a qualidade da imagem de entrada influencia diretamente a segmentação e o desempenho da rede neural durante o treinamento.




Figura 2. Setup / cabine de aquisição RGB

2.2. Dataset e segmentação automática dos grãos

O dataset foi organizado em seis classes visuais de grãos de soja, definidas a partir de características físicas observáveis em imagens RGB. Cada imagem segmentada foi armazenada em diretório correspondente à sua classe, permitindo a rotulação automática durante o carregamento dos dados para treinamento. Essa organização, feita através do software de forma automatizada, por pastas facilita a reprodução dos experimentos, a auditoria manual das amostras e a divisão do conjunto em treinamento, validação e teste.

A segmentação teve como objetivo isolar cada grão individualmente e remover regiões irrelevantes do fundo. Inicialmente, as imagens RGB foram convertidas para o espaço de cor CMYK, pois os tons amarelados predominantes da soja apresentam maior contraste no canal amarelo em relação ao fundo de aquisição. Em seguida, o canal de maior contraste foi submetido à suavização e à limiarização automática pelo método de Otsu, gerando uma máscara binária para separação entre grãos e fundo.

Após a binarização, foram aplicadas operações de refinamento, incluindo detecção de bordas pelo algoritmo de Canny Edge e extração de contornos com a função findContours da biblioteca OpenCV. Para cada contorno válido, foi calculada uma caixa delimitadora, utilizada para recortar o grão na imagem original. Regiões com área inferior a um limiar mínimo foram descartadas para evitar que ruídos ou fragmentos fossem tratados como amostras válidas. Ao final, cada grão foi salvo individualmente, compondo o conjunto de imagens RGB segmentadas utilizado no treinamento da ResNet50.

2.3. Arquitetura da rede neural convolucional

Para a classificação automática dos grãos, foi utilizada uma arquitetura ResNet50, responsável pela extração automática de padrões visuais relacionados à forma, textura, coloração e presença de danos nos grãos. Após a extração de características, os mapas resultantes são convertidos em vetor e encaminhados a camadas totalmente conectadas.

Tabela 1. Estrutura geral da CNN.

Etapa	Operação	Função
Entrada	Imagem RGB redimensionada	Padronização da entrada
Bloco 1	Convolução + ativação + pooling	Extração de padrões simples
Bloco 2	Convolução + ativação + pooling	Extração de padrões intermediários
Bloco 3	Convolução + ativação + pooling	Extração de padrões complexos
Classificador	Camadas totalmente conectadas	Combinação das características
Saída	Neurônios	Predição da classe do grão

A rede foi treinada como um problema de classificação multiclasse. A função de perda utilizada foi a entropia cruzada categórica, adequada para problemas nos quais cada amostra pertence a apenas uma classe. O otimizador adotado foi o Adam, por sua estabilidade em problemas de treinamento com redes convolucionais.

2.4. Protocolo experimental

O conjunto de imagens segmentadas foi dividido em subconjuntos de treinamento, validação e teste. O conjunto de treinamento foi utilizado para ajuste dos pesos da CNN, o conjunto de validação para acompanhamento do desempenho durante o treinamento e o conjunto de teste para avaliação final do modelo. As imagens do conjunto de treinamento foram submetidas a operações simples de aumento de dados, como rotações leves, com o objetivo de aumentar a variabilidade das amostras e reduzir sobreajuste. Para validação e teste, foram aplicadas apenas transformações determinísticas, como conversão para tensor e normalização.

3. Resultados e Discussão

A aplicação do pipeline proposto resultou na geração de um conjunto de imagens RGB segmentadas de grãos de soja, organizadas em classes de qualidade e defeitos. Neste experimento, foi utilizada a versão do dataset sem fundo, obtida após a etapa de segmentação automática, remoção do fundo e recorte individual dos grãos. A Tabela 2 apresenta a configuração geral do experimento.

Tabela 2. Configuração experimental do treinamento.

Arquitetura	ResNet50	Treinamento	27.239 imagens
Tipo de imagem	Grãos segmentados sem fundo	Validação	3.404 imagens
Total de imagens	34.049	Teste	3.406 imagens
Épocas	20	Batch size	4

Para a etapa de classificação, foi utilizada a arquitetura ResNet50, uma rede neural convolucional profunda baseada em conexões residuais. Embora o objetivo central deste trabalho seja avaliar a classificação de grãos a partir de imagens RGB segmentadas, o uso da ResNet50 permite verificar o desempenho de uma arquitetura consolidada em visão computacional aplicada ao dataset gerado pelo pipeline proposto. O treinamento foi realizado com imagens sem fundo, considerando o redimensionamento das amostras e o ajuste dos pesos da rede a partir das classes definidas no conjunto de dados.

Durante o treinamento, observou-se redução progressiva da função de perda no conjunto de treinamento. Os resultados neste treinamento, apresentados na figura 4, indicam que a combinação entre aquisição controlada, segmentação automática e classificação por rede neural convolucional é promissora para a análise visual de defeitos em grãos de soja.




Figura 4. A - Histórico do treinamento. B - Perda do treinamento e validação. C - Matriz de confusão.

A segmentação individual dos grãos também favorece a padronização das entradas da rede. Ao trabalhar com recortes isolados, o modelo recebe imagens mais homogêneas e

com menor interferência de elementos externos, o que tende a melhorar a estabilidade do treinamento. Além disso, a organização do dataset em classes permite que o processo seja reproduzido e ampliado com novas amostras, mantendo a mesma estrutura de treinamento, validação e teste.

De modo geral, o comportamento observado no treinamento reforça a viabilidade do pipeline proposto para classificação automática de defeitos visíveis em grãos de soja. A etapa de aquisição controlada contribui para a qualidade das imagens, a segmentação reduz a influência do fundo e a ResNet50 demonstra capacidade de aprendizado sobre o conjunto segmentado. Como continuidade, pretende-se avaliar as métricas finais no conjunto de teste e, em trabalhos futuros, explorar imagens multiespectrais e comparar diferentes arquiteturas de redes neurais convolucionais.

4. Conclusão

Este trabalho apresentou uma abordagem para classificação automática de defeitos em grãos de soja utilizando imagens RGB segmentadas e uma rede neural convolucional ResNet50. O método integrou aquisição em ambiente controlado, remoção do fundo, recorte individual dos grãos, organização do dataset e treinamento do modelo. O conjunto utilizado foi composto por 34.049 imagens segmentadas, divididas em treinamento, validação e teste, e os resultados parciais indicaram comportamento promissor durante o treinamento.

A utilização de imagens sem fundo contribuiu para reduzir interferências externas e padronizar as entradas da rede, favorecendo o aprendizado de características visuais como forma, cor, textura e manchas superficiais. Como limitação, imagens RGB não capturam defeitos internos ou alterações físico-químicas não visíveis. Como trabalhos futuros, pretende-se avaliar métricas finais por classe, ampliar a base de imagens, comparar diferentes arquiteturas convolucionais e incorporar imagens multiespectrais nas faixas NIR e SWIR.

Referências

- Sonawane, S. and Mohanty, B. K. (2021). “An improved image processing scheme for automatic detection of harvested soybean seeds”. *Journal of Food Measurement and Characterization*, v. 15, n. 6, p. 5607–5621. <https://doi.org/10.1007/s11694-021-01124-0>
- Villaverde, J. E. and Cleva, M. (2024). “Volume estimation of unbroken soybeans samples using digital image processing techniques”. *Revista de Investigaciones Agropecuarias (RIA)*, v. 50, n. 1, p. 8–13. <https://doi.org/10.58149/7aj0-5549>
- Yang, S. et al. (2021). “High-throughput soybean seeds phenotyping with convolutional neural networks and transfer learning”. *Plant Methods*, v. 17, p. 50. <https://doi.org/10.1186/s13007-021-00749-y>
- Zhao, G. et al. (2021). “Real-time recognition system of soybean seed full-surface defects based on deep learning”. *Computers and Electronics in Agriculture*, v. 187, 106230. <https://doi.org/10.1016/j.compag.2021.106230>