

Detecção e Quantificação de Grãos de Soja Pós-Colheita Utilizando Visão Computacional e Aprendizado Profundo

Matheus M. Guerra¹, Dr. Lucas de Almeida Ribeiro¹

¹Instituto Federal de Educação, Ciência e Tecnologia de Goiás
Câmpus Luziânia – Bacharelado em Sistemas de Informação
Luziânia – GO – Brasil

matheus.guerra@estudante.ifg.edu.br, lucas.ribeiro@ifg.edu.br

Abstract. *Traditional manual methods for quantifying post-harvest soybean losses are time-consuming and imprecise. This work presents a computer vision system based on YOLOv5 for automatic detection and quantification of soybean grains on the ground after harvest. A customized dataset was prepared via Roboflow and the model trained under various environmental conditions. Results show high accuracy in ideal scenarios and highlight limitations under challenging conditions, indicating the need for more diverse data augmentation to ensure robustness. The proposed approach offers a promising tool for precision agriculture.*

Resumo. *Métodos manuais tradicionais para quantificação de perdas de soja pós-colheita são demorados e imprecisos. Este trabalho apresenta um sistema de visão computacional baseado no YOLOv5 para detecção e quantificação automática de grãos de soja no solo após a colheita. Um dataset customizado foi preparado via Roboflow e o modelo treinado em diferentes condições ambientais. Os resultados mostraram alta precisão em cenários ideais e apontaram limitações em condições desafiadoras, indicando a necessidade de maior diversificação do dataset e novas técnicas de aumento de dados para robustez. A abordagem proposta é promissora para aplicações em agricultura de precisão.*

1. Introdução

A agricultura moderna busca aumentar a produtividade e reduzir perdas, com foco na sustentabilidade e na rentabilidade. No cultivo da soja, as perdas pós-colheita representam um problema econômico relevante [da Costa et al. 2018]. Os métodos manuais de medição, embora comuns, são lentos, pouco representativos e propensos a erros [Paixão et al. 2022].

A falta de padronização e de dados em tempo real dificulta a identificação das causas das perdas, como falhas na regulação da colheitadeira, resultando em prejuízos e menor eficiência [Bock et al. 2020].

Nesse cenário, a Visão Computacional e o Aprendizado Profundo (*Deep Learning*) surgem como alternativas promissoras [LeCun et al. 2015]. Essas tecnologias permitem automatizar a análise de imagens e estimar de forma rápida e precisa as perdas no campo [Kamilaris and Prenafeta-Boldú 2018].

Este trabalho propõe um sistema baseado nessas abordagens, utilizando modelos de detecção de objetos, como a arquitetura YOLO, para fornecer estimativas mais precisas e escaláveis em relação aos métodos tradicionais [Redmon et al. 2016].

2. Revisão Bibliográfica

O Processamento Digital de Imagens (PDI) envolve a manipulação e análise de imagens por meio de algoritmos, passando por etapas como aquisição, pré-processamento, segmentação e extração de características [Gonzalez and Woods 2018]. Essas técnicas são essenciais para preparar as imagens antes do uso em modelos de *Deep Learning*, garantindo padronização e melhor qualidade visual para a detecção de objetos.

2.1. Visão Computacional e *Deep Learning* na Agricultura

A combinação de Visão Computacional (VC) e *Deep Learning* (DL) tem transformado a agricultura, permitindo automatizar tarefas antes manuais e melhorar o monitoramento e a gestão de cultivos [Liakos et al. 2018]. Essa integração possibilita identificar pragas, doenças, deficiências nutricionais e realizar classificações de culturas em tempo real [Kamilaris and Prenafeta-Boldú 2018].

Conhecida como Agricultura de Precisão, essa área busca otimizar o uso de recursos e reduzir impactos ambientais por meio da análise detalhada de dados de campo [Mavridou et al. 2019]. O uso de redes neurais convolucionais (CNNs) tem mostrado bons resultados em tarefas como detecção de frutas, ervas daninhas e análise de grãos [Zhang et al. 2020, Momin et al. 2017].

Entre os modelos de maior destaque, o YOLO (*You Only Look Once*) se sobressai pela eficiência e precisão. O YOLOv5 e suas versões mais recentes, têm sido amplamente aplicadas em tarefas agrícolas, incluindo detecção de ervas daninhas, classificação de culturas e identificação de doenças, contribuindo para uma agricultura mais precisa e sustentável [Alif and Hussain 2024].

3. Metodologia

O desenvolvimento do sistema seguiu uma abordagem estruturada, desde a coleta e preparação dos dados até o treinamento e avaliação do modelo. Foram utilizadas tecnologias amplamente adotadas em projetos de visão computacional e aprendizado profundo. O projeto foi implementado em Python (versão 3.12.6), utilizando o framework PyTorch (versão 2.7.1+cu128) e o modelo YOLOv5 para detecção de objetos. O OpenCV foi empregado para o processamento de imagens, e o Roboflow auxiliou na anotação e organização do *dataset*. O TensorBoard foi usado para o monitoramento do treinamento, realizado em uma GPU NVIDIA GeForce RTX 3060 Ti, com o desenvolvimento conduzido no ambiente PyCharm.

O *dataset* foi composto por 321 imagens de grãos de soja capturadas em campo, divididas em conjuntos de treino, validação e teste. As imagens foram anotadas manualmente e passaram por técnicas de aumento de dados, como rotações, flips, recortes, ajustes de brilho, contraste e adição de ruído, ampliando a diversidade do conjunto.

O modelo YOLOv5s, com pesos pré-treinados, foi treinado com imagens de 1280×1280 pixels, lote de 16 e 100 épocas. O treinamento e a análise dos resultados buscaram avaliar a capacidade do modelo em detectar grãos sob diferentes condições visuais, demonstrando o potencial da abordagem proposta para quantificação automática das perdas pós-colheita de soja.

4. Resultados Preliminares

O modelo treinado foi avaliado em um conjunto de imagens de teste sob diferentes condições o que é apresentado na figura 1.



(a) Original Próximo.



(b) Próximo com detecções.



(c) Original Afastado.



(d) Afastado com detecções.

Figura 1. Capturas de soja em diferentes perspectivas.

Cenários com grãos próximos ao solo (figura 1(a)) e boa iluminação apresentaram próximos de 100% de detecção, com alta confiança nas predições, figura 1(b). Já em ambientes visualmente poluídos (pedras, detritos, sombras - figura 1(c)), a detecção caiu e surgiram falsos positivos, o que pode ser percebido na figura 1(d).

Os resultados demonstram a eficácia do YOLOv5 em condições ideais, mas revelam a necessidade de dataset mais diversificado, incluindo diferentes tipos de solo e iluminações. Técnicas de augmentation mais agressivas podem potencialmente melhorar a robustez.

5. Conclusões e Próximos Passos

Conclui-se que a abordagem proposta mostrou-se viável para a detecção e quantificação de grãos de soja pós-colheita, evidenciando o potencial da Visão Computacional e do Aprendizado Profundo na agricultura de precisão. O modelo YOLOv5 obteve bons resultados em condições favoráveis, mas apresentou limitações em cenários complexos, com variações de iluminação, ângulo e ruído visual.

Como aprimoramentos futuros, destacam-se:

- Ampliar e diversificar o *dataset* com diferentes condições de solo, iluminação e distância.
- Testar arquiteturas mais recentes (ex: YOLOv8 e YOLOv10) e otimizar hiperparâmetros.
- Aplicar técnicas avançadas de *data augmentation* para aumentar a robustez do modelo.
- Integrar o sistema em uma aplicação prática, facilitando o uso em campo.

Essas melhorias visam aumentar a precisão e a aplicabilidade do sistema, contribuindo para uma agricultura mais eficiente e sustentável.

Referências

- Alif, M. A. R. and Hussain, M. (2024). Yolov1 to yolov10: A comprehensive review of yolo variants and their application in the agricultural domain. *arXiv preprint arXiv:2406.10139*.
- Bock, R., dos Santos Alonço, A., de Oliveira Dias, V., Possebom, G., Knierim, L. F., da Cruz, W. A. S., and Machado, A. P. Á. (2020). Perdas na colheita mecanizada da soja em função da velocidade de deslocamento e índice de molinete. *Brazilian Journal of Development*, 6(6):34707–34724.
- da Costa, C. C., Guilhoto, J. J. M., Burnquist, H. L., and CADEIAS, S. A. E. (2018). Impactos econômicos de reduções nas perdas pós-colheita de produtos agrícolas no brasil.
- Gonzalez, R. C. and Woods, R. E. (2018). *Digital Image Processing*. Pearson, 4th edition.
- Kamilaris, A. and Prenafeta-Boldú, F. X. (2018). Deep learning in agriculture: A survey. *Computers and electronics in agriculture*, 147:70–90.
- LeCun, Y., Bengio, Y., and Hinton, G. (2015). Deep learning. *nature*, 521(7553):436–444.
- Liakos, K. G., Busato, P., Moshou, D., Pearson, S., and Bochtis, D. (2018). Machine learning in agriculture: A review. *Sensors*, 18(8):2674.
- Mavridou, E., Vrochidou, E., Papakostas, G. A., Pachidis, T., and Kaburlasos, V. G. (2019). Machine vision systems in precision agriculture for crop farming. *Journal of Imaging*, 5(12):89.
- Momin, M. A., Yamamoto, K., Miyamoto, M., Kondo, N., and Grift, T. (2017). Machine vision based soybean quality evaluation. *Computers and Electronics in Agriculture*, 140:452–460.
- Paixão, C. S. S., Voltarelli, M. A., Souza, J. B. C., FILHO, A. L. D. B., and Da Silva, R. P. (2022). Loss sampling methods for soybean mechanical harvest. *Bioscience Journal*, 38(e38050):1981–3163.
- Redmon, J., Divvala, S., Girshick, R., and Farhadi, A. (2016). You only look once: Unified, real-time object detection. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 779–788.
- Zhang, Q., Liu, Y., Gong, C., Chen, Y., and Yu, H. (2020). Applications of deep learning for dense scenes analysis in agriculture: A review. *Sensors*, 20(5):1520.