



XVII ENCONTRO CIENTÍFICO DA UNDB
COMUNIDADES TRADICIONAIS: DESAFIOS E PERSPECTIVAS
(XVII EC 2024)

Detecção De Ervas Daninhas Em Talhões De Soja Usando Visão Computacional Por Meio De Imagens Aéreas¹

Leandro Sanches Launé²
Lucas Gabriel Sousa da Fonseca³
Luis Eduardo José de Carvalho⁴
Thomas Airan Coutinho Gomes⁵
Luis Impieri Oliveira⁶
Carlos Antonio Cantanhede de Araújo⁷
Giovanni Lucca França da Silva⁸

ABSTRACT

This paper explores the significance of soybean production in Maranhão, a vital contributor to the regional economy. Despite its economic benefits, weed infestations pose a major challenge, competing for resources and diminishing crop yields. This study proposes the application of Convolutional Neural Networks (CNNs) to classify soybeans and weeds using images captured by unmanned aerial vehicles (UAVs). This approach aims to optimize agricultural management by enabling faster identification of infestations, thereby enhancing the efficiency and sustainability of soybean production.

Keywords: Convolutional Neural Network (CNN). Soybean. Weeds. Unmanned Aerial Vehicle (UAV). Agricultural.

RESUMO

Este artigo discute a relevância da produção de soja no Maranhão, essencial para a economia regional. Apesar dos benefícios, às plantas daninhas representam um desafio significativo, competindo por recursos e reduzindo o rendimento das lavouras. O projeto propõe a aplicação de Redes Neurais Convolucionais (CNN) para classificar soja e plantas daninhas, utilizando imagens de veículos aéreos não tripulados (VANT). Essa abordagem visa otimizar o manejo agrícola, permitindo uma identificação mais rápida das infestações e aumentando a eficiência e sustentabilidade da produção.

Palavras-chave: Rede Neural Convolucional(CNN). Soja. Plantas Daninhas. Veículo Aéreo Não Tripulado(VANT). Agrícola.

¹Artigo proveniente de desafio.

²Graduando em Engenharia de Software, UNDB e leandroabc1401@gmail.com.

³Graduando em Engenharia de Software, UNDB e lucasfonseca.software@gmail.com.

⁴Graduando em Engenharia de Software, UNDB e eduardocarvdev@gmail.com.

⁵Graduando em Engenharia de Software, UNDB e thomasairancoutinhogomes@gmail.com.

⁶Graduando em Engenharia de Software, UNDB e luis.impieri.oliveira@gmail.com.

⁷Graduando em Engenharia de Software, UNDB e carlos-antonio21@live.com.

⁸Professor orientador. Ph.D. em ciência da computação pela UFMA, giovanni.silva@undb.edu.br



XVII ENCONTRO CIENTÍFICO DA UNDB
COMUNIDADES TRADICIONAIS: DESAFIOS E PERSPECTIVAS
(XVII EC 2024)

1. INTRODUÇÃO

A produção de soja no Maranhão desempenha um papel fundamental na economia regional, de acordo com a conab (Companhia Nacional de Abastecimento) o maranhão compõe o top três dos Estados do Nordeste líderes na produção de soja (AGROFY, 2023), sendo uma das principais fontes de renda e desenvolvimento para o estado.

Segundo Garcia et al.(2022), a cultura da soja impulsiona investimentos no setor agrícola, criando oportunidades de emprego e fortalecendo a infraestrutura rural. No entanto, a presença de plantas daninhas representa um desafio significativo para a produtividade dessa cultura. Segundo ANSELMO et al.(2022) a presença e crescimento vigoroso das plantas ocasiona na competição por luz, nutrientes e água, afetando diretamente o crescimento e o rendimento da soja, o que pode levar a perdas econômicas consideráveis para os produtores.

Neste contexto, o objetivo deste projeto é desenvolver um modelo de classificação utilizando Redes Neurais Convolucionais (CNN) que identifique plantas daninhas e soja em plantações no Maranhão, utilizando imagens capturadas por VANT(veículo aéreo não tripulado). Essa abordagem visa otimizar o manejo agrícola, permitindo a identificação rápida e precisa de áreas infestadas, o que facilita intervenções direcionadas para o controle de plantas invasoras e, assim, promove maior eficiência e produtividade na cultura da soja.

A estrutura do trabalho está separada em 4 Seções, a partir desta introdução. A apresentação de matérias e o método utilizados no desenvolvimento do projeto na Seção 2. Os resultados alcançados sobre o trabalho na Seção 3. Por fim a conclusão da pesquisa e seus trabalhos futuros.

2. MATERIAIS E MÉTODO

2.1. BASE DE DADOS

Para o desenvolvimento do projeto foi-se utilizada a base de dados pública **“Data for: Weed Detection in Soybean Crops Using ConvNets”** (FERREIRA et al., 2017) acessível em Mendeley Data. A mesma contém um conjunto de 15.336 imagens

com resoluções variadas, contendo 7.376 imagens de soja, 3.249 imagens de solo, 3.520 imagens de grama e 1.191 imagens de plantas daninhas.




Figura 1. Exemplos de imagens da base de dados. (a) Planta daninha. (b) Soja

2.2. PRÉ-PROCESSAMENTO:

O pré-processamento de uma Rede Neural Convolucional (CNN) é de suma importância na área da inteligência artificial, pois ao utilizar vários métodos de pré-processamento, podemos melhorar a qualidade e competência do modelo CNN, logo o uso do pré-processamento é crucial para o melhor funcionamento do projeto (EITCA Academy, 2023). A fim de gerar o modelo com maior eficácia o mesmo foi subjugado as seguintes técnicas de pré-processamento:

- **Normalização de dados:** A normalização de dados é uma etapa que consiste em escalar os resultados de entrada para um intervalo padrão, geralmente utilizando 0 ou 1, Essa prática é fundamental porque alinha os recursos em uma escala semelhante, evitando que alguns dominem o aprendizado devido a valores maiores. Com a normalização de dados, garantimos que cada recurso colabore proporcionalmente para o processo de aprendizado, levando a uma melhor convergência e generalização do modelo (EITCA Academy, 2023).
- **Data Augmentation:** O aumento de dados (Data Augmentation) é um método que aplica diversas transformações nos dados existentes, como rotação, translação ou inversão com a intenção de gerar amostras de treinamento. Essa técnica melhora a habilidade do modelo em identificar objetos sob diversas perspectivas (EITCA Academy, 2023).

2.3. APRENDIZADO DE MÁQUINA

As Redes Neurais Convolucionais (CNNs) são um tipo de arquitetura de rede neural profunda mais eficiente e amplamente utilizada para processamento e análise de dados visuais, especialmente imagens [7]. Inspiradas no funcionamento do cérebro

humano, elas são projetadas para capturar características locais e hierárquicas em imagens, permitindo reconhecimento de padrões e objetos com alta precisão. Consistem em uma sequência de camadas especializadas que processam a imagem em diferentes níveis de abstração, permitindo a extração de características relevantes.

As principais camadas são: convolucional, pooling e totalmente conectada. A camada convolucional aplica filtros para extrair características locais; a de pooling reduz a dimensionalidade, mantendo as informações mais relevantes e tornando a rede mais eficiente; e a totalmente conectada atua como classificador, integrando as características aprendidas para gerar uma saída final, como uma classificação. Juntas, essas camadas permitem que as CNNs sejam altamente eficazes em tarefas de visão computacional.

Um aspecto fundamental das CNNs é sua capacidade de aprendizado hierárquico, onde camadas iniciais detectam características básicas como bordas e texturas, enquanto camadas mais profundas identificam estruturas complexas [8]. Esta arquitetura, aliada a técnicas modernas de otimização, tem revolucionado áreas como diagnóstico médico, sistemas de vigilância e reconhecimento facial, estabelecendo novos padrões de precisão em visão computacional [9].

2.4. VALIDAÇÃO DOS RESULTADOS

As métricas de desempenho são essenciais para avaliar a eficácia de um modelo de aprendizado de máquina (SOUTO, 2024). Para calcular o desempenho determinamos os seguintes valores:

- Positivo Verdadeira(PV): planta daninha classificado como planta daninha
- Positivo Falso(PF): Planta daninha classificada como soja
- Negativo Verdadeiro(NV): Soja classificada como soja
- Negativo Falso(NF): Soja classificada como planta daninha

Os resultados acima são utilizados para calcular a Acurácia, Sensibilidade(Recall), Precisão e Especificidade, apresentados nas equações (1), (2), (3) e (4), respectivamente:

$$\text{Acurácia} = \frac{PV+NV}{PV+NV+PF+NF} \quad (1)$$

$$\text{Recall} = \frac{PV}{PV+NF} \quad (2)$$

$$\text{Precisão} = \frac{PV}{PV+PF} \quad (3)$$

$$\text{Especificidade} = \frac{NV}{NV+NF} \quad (4)$$

3. RESULTADOS E DISCUSSÃO

3.1. DIVISÃO DA BASE

A divisão das bases de dados é uma etapa crucial no desenvolvimento de modelos de aprendizado de máquina, pois permite uma avaliação eficaz da performance do modelo. Em geral, o conjunto de dados é dividido em três partes principais: treinamento, usado para treinar o modelo CNN, validação, utilizado para ajustar os hiperparâmetros e avaliar o desempenho do modelo durante o treinamento, e o teste que fornece uma avaliação imparcial do modelo treinado final (EITCA Academy, 2023).

Neste contexto foi submetido pela equipe a separação de 1.327 imagens para treino sendo 667 de plantas daninhas e 660 de soja, 559 imagens para validação sendo 252 de plantas daninhas e 307 de soja, 662 imagens para teste sendo 271 de plantas daninhas e 391 de soja, a fim de elaborar um classificador preciso, capaz de distinguir eficazmente entre as culturas de interesse e as plantas invasoras nas lavouras, contribuindo assim para o manejo mais eficiente das plantações.

3.2. TREINAMENTO E TESTE DO MODELO

No desenvolvimento do modelo de classificação para diferenciação entre soja e plantas daninhas, alguns hiperparâmetros essenciais foram ajustados para garantir a eficácia da rede neural convolucional (CNN). Entre os principais hiperparâmetros configurados, estão o número de filtros nas camadas convolucionais e o tamanho dos kernels. Cada camada convolucional utiliza um kernel 3x3, o que permite ao modelo capturar padrões locais importantes nas imagens. O mesmo foi estruturado com três camadas convolucionais seguidas de camadas de pooling, onde foram utilizados filtros de 32, 64 e 128, respectivamente, promovendo uma hierarquia crescente de complexidade na extração de características (Souto, 2024).

Outro hiperparâmetro fundamental foi a taxa de aprendizado, definida pelo otimizador Adam, que adapta a taxa de aprendizado ao longo do processo de treinamento para facilitar a convergência do modelo. A função de ativação "ReLU" foi aplicada para introduzir não-linearidade, na camada de saída a função "sigmoid" foi empregada para a classificação binária, já que o objetivo é diferenciar duas classes. O tamanho do lote

(batch size) foi ajustado para 32, balanceando o uso eficiente da memória e a estabilidade do gradiente. A função de perda utilizada foi "binary_crossentropy", apropriada para problemas de classificação binária, como destacado em pesquisas recentes de Souto (2024), que aponta esses parâmetros como cruciais para a obtenção de resultados robustos em modelos de visão computacional de baixo custo.

No processo de teste, um conjunto que inclui imagens não vistas pelo modelo durante o treinamento e a validação, é usado para medir a acurácia final e gerar uma matriz de confusão, comparando as previsões com as classificações reais.

Ambos os métodos de treino e teste foram submetidos em 10, 20 e 30 épocas, a fim de uma melhor comparação, apresentado nos dados abaixo:

Tabela 1: Métricas de desempenho com base na matriz de confusão


Épocas	Acc.	Recall	Precisão	Especificidade
10	94%	97%	89%	98%
20	98%	99%	97%	99%
30	95%	99%	89%	99%

Tabela 2: Métrica de acurácia no treino

Épocas	Acurácia
10	97.66%

20	97.66%
30	93.37%

Imagem 1: Gráfico de medição de acurácia em 20 épocas



3.3. ESTUDO DO CASO

As Figuras 2 (a) e (b) indicam predições incorretas, sendo uma planta daninha identificada com soja e uma planta de soja infestada por plantas daninhas, respectivamente. Observa-se que, na Figura 2 (a), existem folhas de soja em maior densidade que as plantas daninhas, o que pode ter levado o modelo preditivo a classificar incorretamente como livre de infestação. Paralelamente, a Figura 2 (b) possui áreas

amareladas nas bordas, o que pode ocasionar uma falsa predição do modelo, identificando como plantas daninhas.




Figura 2 Caso de erro no modelo de classificação. (a) Erro em planta daninha. (b) Erro em soja

4. CONCLUSÃO

Este projeto apresentou o desenvolvimento de um modelo de classificação utilizando Redes Neurais Convolucionais (CNN) para identificar plantas daninhas e soja em lavouras no Maranhão, com imagens capturadas por VANT. A proposta contribui para a otimização do manejo agrícola, possibilitando uma identificação rápida e precisa de áreas infestadas e potencializando o controle de plantas invasoras. Os melhores resultados obtidos foram alcançados com o treinamento do modelo em 20 épocas, alcançando 98% de acurácia, 99% de *recall*, 97% de precisão e 99% de especificidade.

Quanto a trabalhos futuros, propõe-se a implementação de novos meios de pré-processamento e pós processamento, a fim de melhoria de classificação do modelo, além disso a integração de um sistema de detecção com base no YOLO com a finalidade de aprimorar o sistema tornando-o mais eficaz.

REFERÊNCIAS

AGROFY. Região Nordeste ultrapassa Índia na produção de soja. Disponível em: <https://news.agrofy.com.br/noticia/202514/regiao-nordeste-ultrapassa-india-na-producao-soja>. Acesso em: 30 out. 2024.

Anselmo, M. C.; Oliveira de Almeida, U.; Nogueira, A. E. .; Souza, R. C. .; Scalcon, J. L.; Silva Saraiva, F. J. . **LEVANTAMENTO FITOSSOCIOLÓGICO DE PLANTAS DANINHAS NA CULTURA DA SOJA, EM CUJUBIM-RO. Revista Científica da Faculdade de Educação e Meio Ambiente, [S. l.], v. 13, n. 1, p. 1–15, 2022. DOI: 10.31072/rcf.v13i1.1057.**Disponível em:<https://revista.faema.edu.br/index.php/Revista-FAEMA/article/view/1057/958>. Acesso em: 31 out. 2024.

EITCA Academy. **Why is it important to preprocess the dataset before training a CNN?** Disponível em: <https://eitca.org/artificial-intelligence/eitc-ai-dlpp-deep-learning-with-python-and-pytorch/convolution-neural-network-cnn/introduction-to-convnet-with-pytorch/examination-review-introduction-to-convnet-with-pytorch/why-is-it-important-to-preprocess-the-dataset-before-training-a-cnn/>. Acesso em: 31 out. 2024.

Ferreira, A. S.; Pistori, H.; Matte Freitas, D.; Gonçalves da Silva, G. (2017), “**Data for: Weed Detection in Soybean Crops Using ConvNets**”, Mendeley Data, V2, Disponível em: <https://data.mendeley.com/datasets/3fmjm7ncc6/2>. Acesso em: 20 jun. 2024.

Garcia, U. S.; Ribeiro, L. A.; Piffer, M. **LOCALIZAÇÃO E CONCENTRAÇÃO DA PRODUÇÃO DA SOJA NO MARANHÃO (2010 E 2020).** In: Anais do 60º Congresso da Sociedade Brasileira de Economia, Administração e Sociologia Rural (SOBER). Anais...Natal(RN) UFRN, 2022. Disponível em: <https://www.even3.com.br/anais/sober2022/486103-localizacao-e-concentracao-da-producao-da-soja-no-maranhao-/>. Acesso em: 31 out. 2024.

SOUTO, A. M. **Desenvolvimento de modelos de visão computacional e aprendizado de máquina para balança inteligente de baixo custo.** 2024. Disponível em: <http://dspace.sti.ufcg.edu.br:8080/xmlui/handle/riufcg/38600>. Acesso em: 30 out. 2024.

[7]Yann LeCun, Yoshua Bengio, and Geoffrey Hinton, “Deep Learning”, Nature 521, pp.436-444,2015.

[8] LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. Nature, v. 521, n. 7553, p. 436-444, 2015.

[9] KRIZHEVSKY, A.; SUTSKEVER, I.; HINTON, G. E. ImageNet Classification with Deep Convolutional Neural Networks. Advances in Neural Information Processing Systems, v. 25, p. 1097-1105, 2012.