

# Aplicação de processamento de imagem e aprendizado de máquina na detecção de ervas daninhas em culturas de soja

André Ferreira Cordeiro<sup>1</sup>, Alan Salvany Felinto<sup>1</sup>

<sup>1</sup>Departamento de Computação – Universidade Estadual de Londrina (UEL)  
Caixa Postal 10.011 – CEP 86057-970 – Londrina – PR – Brasil

andre.ferreira@uel.br, alan@uel.br

***Abstract.** Soybeans has been one of the main export products of Brazil and, with the country being responsible for a large part of the world's production, infestations such as weed can result in great economic losses. In addition, dealing with the presence of weeds in a non-localized manner requires the excessive use of herbicides, which, besides being quite expensive, can lead to a lot of damages to the environment. With this in mind, it is possible to use technologies like image processing and machine learning to create automated solutions for detection and mapping of infestations in a more efficient and localized way.*

***Resumo.** O Brasil tem a soja como um dos seus principais produtos de exportação e, sendo responsável por grande parte da produção do mundo, infestações como a de ervas daninhas podem resultar em grandes prejuízos econômicos para o país. Além disso, combater a presença de ervas daninhas de maneira não-localizada necessita da utilização excessiva de herbicidas, algo que, além de ser bastante custoso, pode provocar danos ao meio ambiente. Tendo isso em vista, o objetivo deste TCC é utilizar das tecnologias atuais de processamento de imagem e aprendizado de máquina para criar soluções automatizadas de detecção e mapeamento de infestações nas culturas de soja, de forma a combater esse tipo de infestação de maneira mais eficiente e localizada.*

## 1. Introdução

A cultura de soja tem se mostrado crucial para a economia do Brasil, e dados da EM-BRAPA sobre a produção no país no período de 2020/2021 informam que foram produzidas cerca de 135 milhões de toneladas da *commodity* no período, cerca de 37% de toda produção mundial [1].

Dada a importância dessa cultura, existe uma grande demanda para aplicações de técnicas voltadas ao aumento da produtividade e qualidade do produto [5], bem como para a diminuição de custos. Algumas dessas demandas são voltadas para a detecção de infestações como a das ervas daninhas.

A motivação para o estudo do problema deriva do fato de que a infestação em culturas agrícolas causadas por ervas daninhas acarreta numa redução muito significativa dos rendimentos da produção, com perdas podendo ser da ordem de 13,5% da produção [7]. Além disso, o combate à essas plantas invasoras muitas vezes é feito com a utilização excessiva de agrotóxicos, que, além de serem prejudiciais à saúde do consumidor, demandam bastante investimento financeiro [3].

Somado à isso, provou-se ser possível reduzir consideravelmente os gastos com herbicidas (com uma diminuição de cerca de 72% de seus gastos na produção de soja) quando sua aplicação for feita de forma localizada, mediante uma análise de infestação que determina quais ações devem ser tomadas dadas as condições de um terreno [7].

Tendo isso em vista, o foco deste trabalho será em desenvolver um mecanismo de reconhecimento e classificação de plantações de soja com a presença de ervas daninhas, possibilitando quantificar e definir o grau de infestação de um terreno, para que, posteriormente, decisões mais eficientes possam ser feitas para tratar o problema.

Para melhor entendimento, este documento está dividido em 6 seções. A seção 2 apresenta a fundamentação teórica; a seção 3 descreve os objetivos a serem alcançados; na seção 4 é descrita a metodologia utilizada; já na seção 5 é apresentado o cronograma de execução; e, por fim, a seção 6 discute quais são os resultados esperados e as contribuições que pretendem ser geradas para a comunidade científica.

## **2. Fundamentação Teórico-Metodológica e Estado da Arte**

Com o grande crescimento do poder computacional nos últimos anos, tem sido possível utilizar de técnicas como aprendizado de máquina, redes neurais e processamento digital de imagem para lidar com problemas cada vez mais complexos [3]. Assim sendo, faz-se uma união dessas áreas, de forma que um modelo de aprendizado de máquina possa ser treinado recebendo como entrada informações retiradas a partir do processamento de imagens. Esse modelo então será utilizado para resolver diversos problemas, como os de classificação e regressão.

Para isso, nesta seção será feita uma revisão sobre os conceitos e técnicas que têm sido utilizadas em trabalhos recentes para resolver problemas semelhantes ao proposto neste trabalho.

### **2.1. Processamento de imagem**

Processamento de imagem pode ser definido como um conjunto de técnicas que podem ser aplicadas sobre imagens, com intuito de melhorar a sua qualidade, eliminar ruídos e distorções, extrair elementos desejados, etc. Para tratar de problemas como o apresentado neste trabalho, técnicas como essas são utilizadas para segmentação de imagens e para extração de descritores.

#### **2.1.1. Segmentação**

O processo de segmentar uma imagem consiste em dividi-la em partes, de forma a enfatizar os objetos de interesse. Dentre os métodos de segmentação, existem os monocromáticos, que se baseiam ou na descontinuidade, dividindo a imagem com base na alteração brusca dos níveis de cor (presente em bordas, pontos isolados e linhas), ou na similaridade. Existem também os métodos baseados em cores e os métodos treináveis por meio de redes neurais artificiais. Dado o tema deste trabalho, vale ressaltar também a existência da segmentação de imagem por detecção de verde, cujo objetivo é separar plantas do solo baseando-se na intensidade das cores [9].

### 2.1.2. Obtenção de descritores

Descritores são informações obtidas sobre um objeto que nos permitem determinar algo sobre o mesmo, por exemplo, pontos com cores anormais em uma folha podem indicar a presença de manchas representando a proliferação de uma doença. Existe uma gama muito grande de descritores que podem ser obtidos, podendo ser descritores de forma, cor, textura, etc [2], escolhidos com base no tipo de problema a ser resolvido.

Para a aquisição das imagens, as técnicas mais inovadoras tem sido baseadas na utilização de aeronaves remotamente pilotadas, também chamadas de drones [4]. Na detecção de ervas daninhas em lavouras, em [5] foram processadas imagens coletadas por VANTs (Veículos aéreos não tripulados) que, posteriormente, foram classificadas em quatro classes distintas: solo, soja, gramíneas e folhas largas. Também foi desenvolvido um software que realiza a segmentação das imagens utilizando o algoritmo SLIC (*Simple Linear Iterative Clustering*) Superpixel.

## 2.2. Aprendizado de Máquina

Aprendizado de máquina é um ramo da Inteligência Artificial focado no desenvolvimento de algoritmos que simulam o aprendizado humano. Esses modelos aprendem, por meio de treinamento com um conjunto de dados, a tomar decisões, identificar padrões e fazer previsões [2]. Um modelo de classificação, por exemplo, após ser treinado deve ser capaz de receber um conjunto de amostras e atribuir uma classe ou rótulo para cada uma das instâncias.

Dentre as técnicas de aprendizado de máquina mais citadas na literatura quando o assunto é detecção de ervas daninhas estão: Máquina de Vetores de Suporte (*Support Vector Machine*), Florestas Aleatórias (*Random Forest*), Redes Neurais Artificiais e Redes Neurais Convolucionais [6].

Trabalhos recentes destacam a importância das Redes Neurais Convolucionais para a detecção de ervas daninhas na soja, pois técnicas de aprendizado profundo como essa aprendem a extrair características a partir do dado bruto, sem a necessidade de aplicação de um algoritmo extrator de atributos [5]. Por outro lado, o treinamento desse modelo requer uma quantidade de amostras relativamente grande [6].

Em [8] foram testados cinco métodos de aprendizado profundo, são eles: *ResNet50*, *MobileNet*, *4-Layer CNN Network*, *5-Layer CNN Network* e *8-Layer CNN Network*, sendo os três últimos modelos de rede neural convolucional customizados. A avaliação desses métodos se deu com base nos parâmetros de uso de memória, latência e acurácia, dessa forma, constatou-se que o modelo de melhor desempenho foi o de *5-Layer CNN Network*, obtendo acurácia de 97%.

Nos testes executados em [5] foram comparados os resultados dos seguintes algoritmos: Máquina de Vetores de Suporte, Florestas Aleatórias, AdaBoost M1 e Redes Neurais Convolucionais. Da mesma forma, constatou-se um desempenho superior na utilização das Redes Neurais Convolucionais, com 98% precisão na classificação de todas as classes, número superior se comparado aos outros algoritmos.

Como o intuito do trabalho será de analisar, e possivelmente, testar a aplicação de várias técnicas de aprendizado de máquina sobre os dados coletados, é necessário

possuir uma forma de comparar o desempenho dessas técnicas, de forma a determinar quais obtiveram melhores resultados. Para isso, em princípio, a análise será auxiliada pela utilização da ferramenta Weka.

### **2.2.1. Weka**

O Weka (*Waikato Environment for Knowledge Analysis*) é um software de código aberto que permite a aplicação de métodos de aprendizado de máquina para mineração de dados. Por meio dele é possível trabalhar com problemas de classificação, regressão, entre outros. No contexto deste trabalho, a ferramenta será utilizada para que diversos classificadores possam ser aplicados sobre o conjunto de dados (descritores) coletados das imagens.

Além disso, o Weka fornece métricas que permitem avaliar a comparação e o desempenho dos algoritmos de classificação.

### **2.2.2. Métricas**

Existem diversas métricas que podem ser utilizadas para avaliar diferentes aspectos de um modelo, algumas delas são: acurácia, precisão, sensibilidade, F-score, Curva ROC, Coeficiente KAPPA entre outros. A acurácia, por exemplo, indica a frequência de acerto do modelo com relação ao total de amostras fornecidas [2].

### **2.2.3. Técnicas de seleção de atributos**

Para melhorar o desempenho de um modelo de aprendizado de máquina também se faz necessário definir um bom conjunto de atributos. Tanto a presença de um atributo irrelevante quanto um conjunto de atributos muito grande podem tanto aumentar a complexidade de um modelo quanto gerar resultados indesejados. Para isso, existem métodos de seleção que auxiliam na escolha dos atributos mais relevantes para determinado problema, que podem ser divididos em: métodos de filtragem, métodos de conjuntos e métodos embutidos [2].

## **3. Objetivos**

O objetivo principal desse trabalho é desenvolver um mecanismo de reconhecimento de ervas daninhas nas culturas de soja, utilizando de processamento de imagem e aprendizado de máquina para classificar imagens coletadas por drones.

## **4. Procedimentos metodológicos**

O processo de execução do projeto seguirá o modelo *Scrum*, onde serão definidas metas de execução para cada semana. Além disso, reuniões semanais serão feitas, permitindo avaliar o que foi produzido durante a semana, verificar a existência de dificuldades, bem como planejar futuras atividades.

De maneira geral, o desenvolvimento do projeto é dividido nas etapas a seguir, cada uma delas podendo também ser separada em atividades menores:

1. Identificação dos descritores de imagem necessários para resolução do problema;
2. Segmentação das imagens fornecidas pelo professor Osvaldo Coelho Pereira Neto do Departamento de Geologia e Geomática do CCE;
3. Extração dos descritores presentes nas imagens;
4. Aplicação de algoritmos de aprendizado de máquina no processo de classificação das imagens;
5. Comparação dos resultados obtidos pelos classificadores por meio de métricas, como: Curva ROC, FSCORE, Coeficiente KAPPA entre outros;
6. Implementação, utilizando a linguagem de programação PYTHON e a biblioteca OpenCV, do método de classificação de melhor desempenho;

## 5. Cronograma de Execução

Atividades:

1. Revisão bibliográfica;
2. Estudo da ferramenta Weka para aplicação de algoritmos de classificação;
3. Levantamento dos descritores;
4. Segmentação das imagens;
5. Obtenção dos descritores;
6. Aplicação dos classificadores;
7. Comparação do desempenho dos classificadores;
8. Implementação da ferramenta em Python;
9. Escrita do TCC

**Tabela 1. Cronograma de Execução**

	ago	set	out	nov	fev	mar	abr	mai	jun
Atividade 1	x	x							
Atividade 2	x	x							
Atividade 3			x						
Atividade 4			x						
Atividade 5				x					
Atividade 6				x					
Atividade 7				x					
Atividade 8					x				
Atividade 9						x	x		

## 6. Contribuições e/ou Resultados esperados

Com o desenvolvimento deste trabalho, pretende-se contribuir para o desenvolvimento de técnicas relacionadas à detecção de ervas daninhas em culturas de soja, por meio do estudo, aplicação e avaliação de resultados de técnicas de processamento digital e aprendizado de máquina.

## 7. Espaço para assinaturas

Londrina, 12 de Setembro de 2022.

---

Aluno

---

Orientador

### Referências

- [1] José Gabriel Madureira ADAMI and Flávia Luíze Pereira de SOUZA. Análise de imagens coletadas por drones para identificação da soja. 2021.
- [2] Murilo Barbosa. Abordagem baseada na extração de atributos do pixel para quantificar a severidade da ferrugem asiática em imagens de folha de soja, 2021.
- [3] Diego Falkowski Carboni. Sistema para identificação de plantas invasoras em lavouras com detectores de objetos aplicados a imagens e vídeos. 2021.
- [4] Alan Carlos de Oliveira Castro et al. Mapeamento digital de plantas daninhas em áreas de produção de soja utilizando aeronaves remotamente pilotadas. 2022.
- [5] Alessandro dos Santos Ferreira. Redes neurais convolucionais profundas na detecção de plantas daninhas em lavoura de soja. 2017.
- [6] Luiz Carlos Marques and José Alfredo Covolan Ulson. A aplicação de redes neurais profundas para detecção e classificação de plantas daninhas e seu estado da arte. *REGRAD-Revista Eletrônica de Graduação do UNIVEM-ISSN 1984-7866*, 11(01):391–403, 2018.
- [7] Osvaldo Coelho Pereira Neto. *Mapeamento de feições agrícolas através de redes neurais artificiais com fotos obtidas por veículo aéreo não-tripulado (VANT)*. PhD thesis, State University of Londrina, Paraná, Brazil, 2007.
- [8] Najmeh Razfar, Julian True, Rodina Bassiouny, Vishaal Venkatesh, and Rasha Kashef. Weed detection in soybean crops using custom lightweight deep learning models. *Journal of Agriculture and Food Research*, 8:100308, 2022.
- [9] Matheus Cassali da Rosa. Redes neurais convolutivas aplicadas à detecção de ervas daninhas. 2019.