

CNN Aplicada à Imagens de drone para Identificação de Famílias de Planta Daninha em pastagem

João Pedro dos S. Verçosa¹, Marcelo H. B. Medeiros², Mário H. G. Santos²,
Suzanne S. M. L. C. Silva², Gustavo H. G. Lima², Arthur C. F. Tavares²

¹Instituto de Computação – Universidade Federal de Alagoas (UFAL)
57.072-900 – Maceió – AL – Brazil

²Campus de Engenharias e Ciências Agrárias – Universidade Federal de Alagoas
(UFAL)
57.100-000 – Rio Largo – AL – Brazil

jpsv2@ic.ufal.br, {marcelo.medeiros, mario.santos, suzanne.silva, gustavo.lima, acftavar}@ceca.ufal.br

Abstract. *New agricultural technologies such as drone and Convolutional Neural Networks (CNN) can favor organic and conventional crops. This work developed an algorithm based on CNN to identify, in drone images, weeds in pasture, Panelas/PE. Fabaceae had the best results for its morphological characteristics and for its species Crotalaria micans, toxic to cattle. The CNN obtained 100% accuracy, for 10 training epochs using internet, smartphone and drone images. Despite the good accuracy result, it was observed the occurrence of overfitting, caused by the low quantity of drone images and the frequency of rainfall in the state of Pernambuco, in 2022.*

Resumo. *Novas tecnologias agrícolas como drone e Redes Neurais Convolucionais (CNN) podem favorecer os cultivos orgânico e convencional. Esse trabalho desenvolveu algoritmo baseado em CNN para identificar, em imagens de drone, plantas daninhas em pastagem, Panelas/PE. A Fabaceae teve os melhores resultados por suas características morfológicas e por sua espécie Crotalaria micans, tóxica ao gado. A CNN obteve 100% de acurácia, para 10 épocas de treinamento utilizando imagens da internet, do smartphone e de drone. Apesar do bom resultado da acurácia, observou-se a ocorrência de overfitting, causado pela baixa quantidade de imagens de drone e pela frequência de chuvas no Estado de Pernambuco, em 2022.*

1. Introdução

Em áreas de pastagem, o alimento e a nutrição dos animais são os fatores mais importantes para o produto final e, quando se encontram degradadas, uma das principais dificuldades no manejo dessas áreas é a presença de plantas daninhas, que podem competir com o pasto, reduzindo os níveis nutricionais da cultura e afetando a alimentação e a saúde do animal (DIAS FILHO, 2017).

Diferentes métodos tradicionais de controle de plantas daninhas, como a pulverização de herbicidas, além de aumentar os custos do produtor, também têm impacto negativo no meio ambiente. Uma boa alternativa seria a aplicação direta nos locais e no início da infestação (ZHANG et al, 2018).

A introdução de novas tecnologias que compõem parte da agricultura de precisão como drone, mais comumente chamada de drone, tem revolucionado a produção e manejo agrícolas. Com elas, o planejamento agrícola se tornou mais rápido e preciso, impactando no aumento da produtividade, qualidade e sustentabilidade das áreas cultivadas (AMARAL et al, 2020).

O processamento digital das imagens de drone pode ser realizado por softwares livres, como o ODM (OpenDroneMap), para confecção de ortomosaicos que serão utilizados no treinamento da CNN (BHARAMBE, 2021; OPENDRONEMAP, 2020).

Algumas técnicas de visão computacional têm sido desenvolvidas para realizar a diferenciação entre plantas cultivadas e plantas daninhas (DA ROSA, 2019).

O uso de imagens obtidas por drone, juntamente com a aplicação de Redes Neurais Convolucionais (CNN) possibilita a identificação e a localização de plantas daninhas em áreas agrícolas o que favorece a sustentabilidade de cultivo orgânico e incentiva o plantio convencional (LIANG; YANG; CHAO, 2019; TIAN, 2020).

A CNN é uma técnica do Deep learning que apresenta alto potencial na aplicação do agronegócio podendo desenvolver um papel importante no monitoramento e mapeamento preciso do ambiente para detectar áreas de pasto afetadas por plantas daninhas. Assim como, possibilita respostas rápidas para intervir solucionando esse problema antes que ocasione danos na produtividade (TEIXEIRA et al., 2020).

Em áreas de pastagem os requisitos de proteção ambiental para a redução do uso de agroquímicos, podem usar imagens obtidas por drone para fornecer dados às bases de treinamento de CNN. Essas tecnologias informam a localização de plantas daninhas para que ocorra a pulverização apenas nas áreas específicas, reduzindo o impacto aos animais e ao pasto (AITKENHEAD, 2003; PETRICH et al, 2020; YANG et al., 2022).

A associação do sistema de Manejo Integrado de Plantas Daninhas (MIPD) com o drone e as técnicas de CNN viabiliza um método de trabalho responsável com o meio ambiente e alta precisão no controle das plantas daninhas (ESPOSITO et al, 2021).

O objetivo desse trabalho foi desenvolver algoritmo baseado em CNN para identificar, em imagens de drone, famílias de plantas daninhas nas áreas de pastagem.

2. Metodologia

A área de estudo está localizada no município de Panelas – PE dentro de uma propriedade com área total de 74 hectares e área agricultável de cerca de 29,1 hectares.

Utilizou-se drone, modelo DJI Phantom 4 Advanced, com câmera de 20mpx, GPS (Global Position System) embarcado para constelações GNSS e Glonass, e autonomia de voo de até 31 minutos para captura de fotos da pastagem (Figura 1).



Figura 1 – Orthomosaico de fotos de drone, para identificação das plantas daninhas.

2.1 Material

Para planejamento de voos foram utilizados os softwares Google Earth Pro, como ferramenta de auxílio de geolocalização e pré-definição de áreas a serem imageadas, e o DJI Go e Drone Deploy, para configuração de área de sobrevoo, das altitudes e pontos de decolagem. Os voos automatizados ocorreram no dia 13/02/2022 entre 10:30 e 15:45h, e em 1/05/2022 entre 11:35 e 15:30h. As altitudes dos sobrevoos variaram entre 10 e 75 metros, com taxas de sobreposição vertical de 75% e longitudinal de 85%. Para a confecção dos ortomosaicos utilizou-se o software ODM (OPENDRONEMAP, 2020).

A família *Fabaceae* se enquadrou como grupo de plantas daninhas de melhores critérios e eficiência para identificação de características morfológicas a partir das imagens de smartphone (Figura 2). Dentro desta família encontra-se a espécie *Crotalaria micans* (Guizo-de-cobra), a qual se ingerida pelo gado pode levá-lo à óbito.

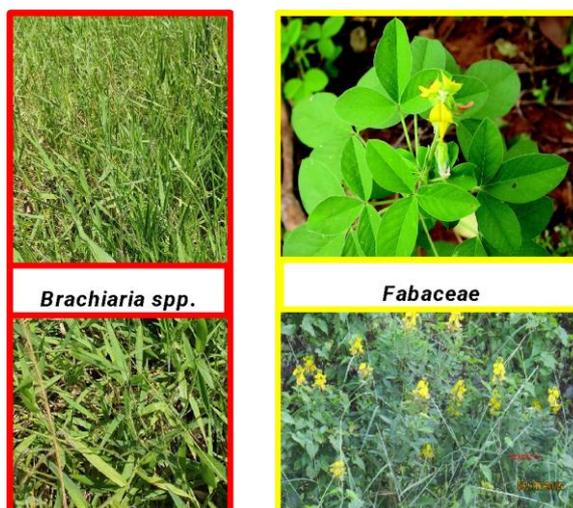


Figura 2 – Fotos obtidas por smartphone de plantas daninhas da família *Fabaceae*, encontradas no pasto formado pelo gênero *Brachiaria spp.*

2.2 Banco de dados

O banco de dados criado somou um total de 654 imagens que foram divididas em dois grupos (*Brachiaria* e *Fabaceae*), tanto para treinamento, quanto validação. Foi constituído de diferentes de imagens obtidas pela internet, smartphone e drone. Para o

treinamento da CNN foram utilizadas 07 imagens de *Fabaceae* e 07 de *Brachiaria*, e para validação, 03 imagens de *Fabaceae* e 03 de *Brachiaria*. Para que a quantidade de dados não fosse insuficiente, foi realizada a duplicação das imagens (*data augmentation*) de *Fabaceae* e *Brachiaria*, chegando a um total de 371 imagens para treinamento e 216 para validação.

2.3 Treinamento

O algoritmo da CNN foi desenvolvido utilizando a linguagem Python e suas bibliotecas Matplotlib, Keras, Tensorflow, Os e Numpy. As imagens de drone possuem resolução de 4864x3648 e as de smartphone 1908x4032, sendo ambas ajustadas para a entrada no código com dimensões de 250x250 e separadas em 75% para treinamento e 25% para validação. A arquitetura da CNN (Figura 03) possui 4 camadas de convolução Conv2D com as seguintes quantidades de neurônios: 32, 32, 64 e 128, MaxPooling 2D, Flatten e Dense. Foram geradas duas saídas: classe 0 (*Brachiaria Spp*) e classe 1 (*Fabaceae*).

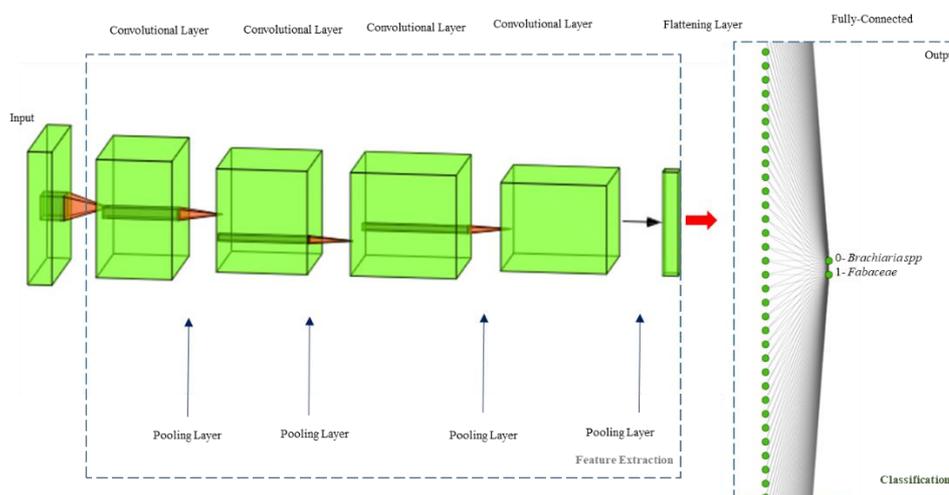


Figura 3 – Arquitetura da CNN

2.4 Classificação

Para a classificação das imagens contendo planta daninha foi utilizado um algoritmo desenvolvido na linguagem Python, utilizando suas bibliotecas Tensorflow, Numpy e Matplotlib. A partir delas foi desenvolvida uma função utilizada para exibir a taxa de acerto do algoritmo e as respectivas imagens classificadas.

Ao chamar a função de classificação `plot_dataset_predictions` e informar a variável que armazena o banco de dados de validação foi realizada a classificação das imagens que estão na variável `daset_validation` e em seguida foi plotada a imagem classificada exibindo a classificação real das imagens (labels) e a classificação pelo modelo treinado (predictions). A classificação da predictions foi realizada por uma linguagem binária onde 1 significa a classe *Fabaceae* e 0 a classe *Brachiaria*.

3. Resultados

O primeiro ortomosaico, produzido a partir de fotos obtidas em altitude de 50m, indicou a presença de árvores e arbustos (destacados em amarelo) e baixa incidência de plantas

daninhas (destacadas em vermelho), dentro da área de pastagem. O quarto ortomosaico, produzido com fotos obtidas em altitude superior à 50m, também possibilitou a identificação e localização das plantas daninhas e espécies arbóreas (Figuras 3).

A figura 4, devido a altitude menor de imageamento e colaboração das fotos georreferenciadas obtidas em campo com smartphone, permitiu diferenciar as plantas daninhas da família *Fabaceae*, espécie *Crotalaria micans* (Guizo-de-cobra). Dessa forma, dentro da área de pastagem, composta por plantas do gênero *Brachiaria spp.*, são separadas e localizadas as plantas daninhas que são extremamente perigosas e tóxicas para o gado.



Figura 3 – Ortomosaico obtido a partir de imageamento realizado a 50 m de altitude.

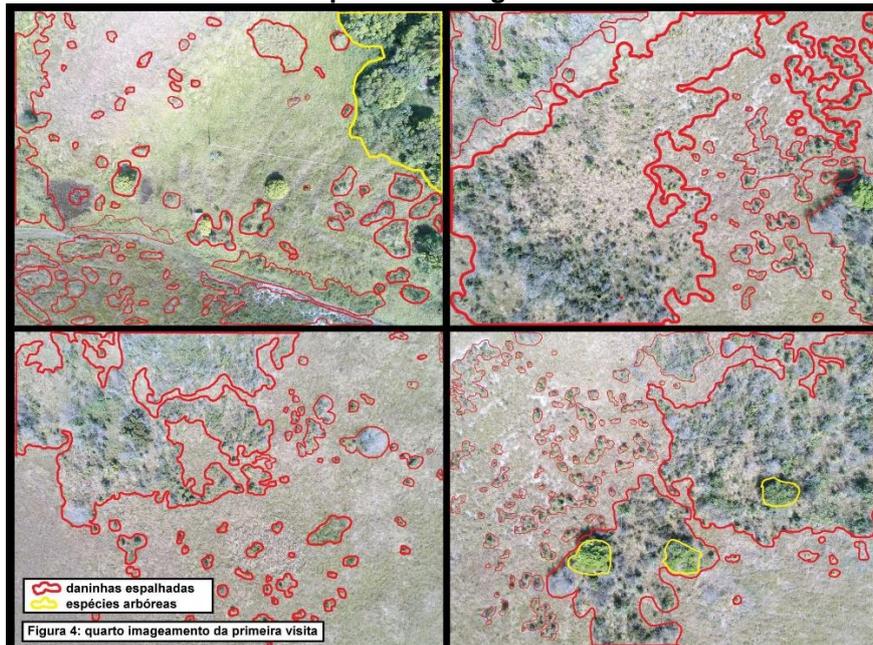


Figura 4 - Ortomosaico oriundo do segundo imageamento realizado com drone.

Utilizando dez épocas para o banco de dados de imagens da internet, a CNN obteve 91,89% de acurácia para treinamento e 85,02% para validação (Tabela 1). Com relação às perdas foram baixas tanto para treinamento (0,2) quanto validação (0,3).

Tabela 1 - Valores de acurácia e perda do treinamento e validação para as imagens de smartphone e da Web.

Imagens de smartphone e da Web

	Treinamento	Validação	Nº de Épocas
Acurácia (%)	91,89	85,02	10
Perda	0,2	0,3	10

Utilizando imagens da web observou-se um bom desempenho da CNN pelo fato do treinamento ter utilizado 57 imagens de *Fabaceae* e 54 *Brachiaria* (Tabela 2). Para validação foram utilizadas 20 imagens de *Fabaceae* e 20 de *Brachiaria* tiradas com o smartphone durante os trabalhos de campo, obtendo uma taxa de acerto de 80%.

Tabela 2 - Quantidade de Acertos nas imagens do smartphone com treinamento da web.

Método Utilizado	Quantidade de imagens	Acertos
Treinamento – Imagens da web	40	80%
Validação – Imagens do smartphone		

Para o treinamento do banco de dados das imagens de smartphone, a CNN utilizou dez épocas e obteve 97,30% de acurácia no treinamento e 80% na validação (Tabela 3). As perdas tiveram valores baixos para treinamento (0,1) e validação (0,4).

Tabela 3 - Valores de acurácia e perda do treinamento e validação para as imagens de smartphone.

Imagens de Smartphone

	Treinamento	Validação	Nº de Épocas
Acurácia (%)	97,30	80,00	10
Perda	0,1	0,4	10

Os dados apresentados na tabela 4 os resultados obtidos para imagens tiradas em campo pelo smartphone. Com relação ao banco de dados para treinamento, foi obtido um total de 30 imagens, sendo 15 para *Brachiaria* e 15 para *Fabaceae*. No entanto, devido a pouca quantidade de imagens foram utilizadas imagens duplicadas (*data augmentation*) para os bancos de dados de treino e de validação. Foram utilizadas as mesmas imagens

para treinamento e validação, gerando uma taxa de acerto de 100%. Na figura 5 observa-se ótimo desempenho do algoritmo de classificação para separar as imagens com *Fabaceae* das imagens com *Brachiaria*.

Tabela 4 - Quantidade de Acertos nas imagens de smartphone.

Método Utilizado	Quantidade de imagens	Acertos
Treinamento – Imagens da smartphone	30	100%
Validação – Imagens do smartphone		

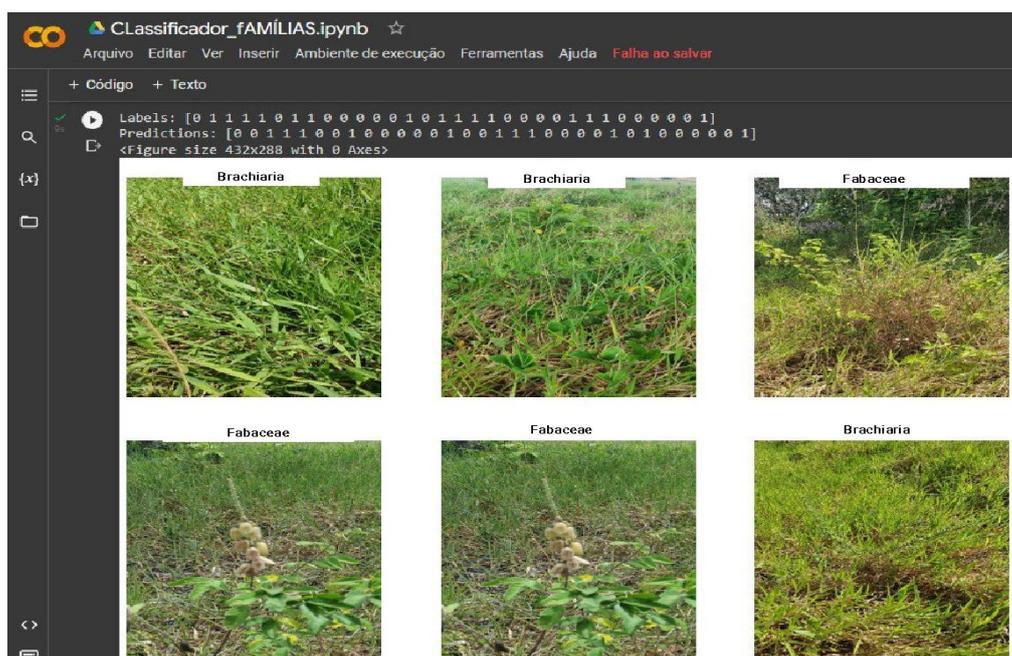


Figura 5 - Imagens de *Fabaceae* e *Brachiaria* obtidas apenas por smartphone.

Utilizando o banco de dados de imagens de drone, a CNN atingiu o valor de 100% de acurácia considerando 10 épocas para treinamento (Tabela 5). As perdas chegaram ao valor mínimo (0).

Tabela 5 - Valores de acurácia e perda do treinamento e validação para as imagens de Drone

	Imagens de Drone		
	Treinamento	Validação	Nº de Épocas
Acurácia (%)	100	100	10
Perda	0,0	0,0	10

As informações descritas na tabela 6 indicam a quantidade total de imagens (216) e os acertos (100%) obtidos pela CNN através do uso de imagens de drone. Como pode ser observado através da figura 6, o algoritmo de classificação teve um bom resultado na diferenciação entre a família *Fabaceae* e ao gênero *Brachiaria spp.*, apesar da pouca quantidade de dados.

Tabela 6 - Quantidade de Acertos na classificação das imagens de drone.

Método Utilizado	Quantidade de imagens	Acertos
Treinamento – Imagens do drone	216	100%
Validação – Imagens do drone		



Figura 6 - Imagens de *Fabaceae* e *Brachiaria* obtidas por drone.

3.1 Discussões

As CNNs são redes neurais muito sofisticadas, sendo sua capacidade equiparada ao reconhecimento feito pelo cérebro humano, até mesmo ultrapassando-o em acertos e eficiência (JATI; GEORGIU, 2019). Em um tempo muito curto e com uma quantidade muito pequena de amostras, o presente trabalho apresentou alto número de acertos quanto a diferenciação de pasto e planta daninha, sendo provavelmente um resultado improvável do ponto de vista da capacidade de reconhecimento cerebral humano.

A rede neural tem potencial para possibilitar que não somente um gênero específico de planta seja identificado, podendo ser expandida para uma grande variedade de vegetações de pastagem (ZHANG et al., 2018, TIAN, 2020). Já que as CNNs funcionam por um envelamento de pixels baseados em RGB e forma, através das

características de formato da folha, cor e tamanho é possível identificar características marcantes de diferentes tipos de pastagem, portanto, provavelmente teria sido possível o reconhecimento de outro gênero de pastagem além de *Brachiaria spp.*

Segundo Yang et al., (2022) o reconhecimento das plantas pode ser dificultado dependendo da classificação cotiledonar, fazendo com que uma CNN com reconhecimento para imagens de duas dicotiledôneas tenha sua acurácia reduzida, não chegando a um acerto de 90%, devido às semelhanças nos aspectos morfológicos. Nesta CNN que diferenciou *Brachiaria spp.* e *Fabaceae*, este problema não foi detectado, já que a primeira é uma monocotiledônea e a segunda uma dicotiledônea, indicando um grande potencial de aplicação em áreas de pastagem infestadas pela família *Fabaceae*.

O excesso de épocas utilizadas no treinamento de uma CNN também pode comprometer a precisão do algoritmo causando o *overfitting*, ou seja, apesar do modelo estar adequado ao banco de dados, ele passa a obter muitas variáveis, o que corrobora para a diminuição da acurácia (RIST et al., 2019). Neste trabalho utilizou-se inicialmente 60 épocas, onde notou-se uma drástica diminuição da acurácia, provavelmente devido ao *overfitting*. As épocas foram então reduzidas até alcançarem uma melhor assertividade, ficando definidas 30 e 5 épocas para as imagens de drone.

4. Conclusão

O algoritmo da CNN apresentou resultados interessantes para distinção de famílias de plantas daninhas, tendo seu melhor resultado para imagens da web onde apresentou o valor de 90,32% de acerto. Isto se deve a boa resolução e padronização das imagens além do fato das plantas daninhas da família *Fabaceae* serem isoladas e sem interferência da *Brachiaria*, diferentemente do que aconteceu com as imagens de smartphone e drone.

O valor de acerto para classificação de imagens obtidas a partir de Smartphone e drone alcançou 100%. No entanto, esse valor ocasionou um *overfitting*, já que, para a classificação foram utilizados os mesmos dados que foram utilizados no treinamento.

Para trabalhos futuros, recomenda-se a utilização de uma quantidade maior de dados de imagens de smartphone, sendo elas isentas de qualquer interferência de outra vegetação, para melhorar a diferenciação e, conseqüentemente, a classificação. Em relação aos imageamentos com drone recomenda-se uma altitude menor e em áreas com pouca interferência de outras plantas, para possibilitar uma melhor visualização das características morfológicas das plantas a serem diferenciadas.

A falta de dados para rede neural foi uma grande dificuldade causada, principalmente, pela manifestação climática extrema durante o período de desenvolvimento do projeto. Em 2022, o Estado de Pernambuco entrou em estado de alerta devido às fortes chuvas, as quais causaram deslizamento no entorno das rodovias de acesso e na área de estudo, impossibilitando os voos para imageamento com drone.

Referências

- Aitkenhead, M. J. et al. Weed and crop discrimination using image analysis and artificial intelligence methods. *Computers and electronics in Agriculture*, v. 39, n. 3, p. 157-171, 2003.
- Amaral, L. R. do et al. Aplicações de UAVs na Agricultura 4.0. *Revista Ciência Agrônômica*, v. 51, n. spe, 2020.

- Bharambe, R. Docker: empowering app development for developers. Disponível em: <<https://www.ambab.com/blog/docker-empowering-app-development-for-developers/>>. Acesso em: 29 jun. 2021.
- Da Rosa, M. C. (2019). Redes neurais convolutivas aplicadas à detecção de ervas daninhas. Universidade Federal do Rio Grande do Sul. Escola de Engenharia. Programa de Pós-Graduação em Engenharia Elétrica.
- Dias Filho, M. B. Degradação das pastagens: o que é como evitar. Brasília, DF: Embrapa, 2017. 19 p.
- Esposito, M. et al. Drone and sensor technology for sustainable weed management: A review. *Chemical and Biological Technologies in Agriculture*, v. 8, n. 1, p. 1-11, 2021.
- Jati, A., Georgiou, P. Neural predictive coding using convolutional neural networks toward unsupervised learning of speaker characteristics. *IEEE/ACM Trans. Audio, Speech, Lang. Process.*, v. 27, n. 10, p. 1577–1589, 2019.
- Liang, W-C.; Yang, Y-J.; Chao, C-M. Low-cost weed identification system using drones. In: 2019 Seventh International Symposium on Computing and Networking Workshops (CANDARW). IEEE, 2019. p. 260-263.
- OpenDroneMap Authors ODM – A command line toolkit to generate maps, point clouds, 3D models and DEMs from drone, balloon or kite images. OpenDroneMap/ODM GitHub Page 2020; <https://github.com/OpenDroneMap/ODM>. Acessado em 04 set. 2022.
- Petrich, L. et al. Detection of *Colchicum autumnale* in drone images, using a machine-learning approach. *Precision Agriculture*, v. 21, n. 6, p. 1291-1303, 2020.
- Rist, Y., Shendryk, I., Diakogiannis, F., Levick, S. Weed Mapping Using Very High Resolution Satellite Imagery and Fully Convolutional Neural Network. *IGARSS, IEEE International Geoscience and Remote Sensing Symposium*, p. 9784-9787, 2019.
- Teixeira, T., Jayme, S., Arnal, G., Sônia, B., João, T., Neto, C., Vieira, L., Kleber, K., & Sampaio De Souza, X. (n.d.). Visão computacional aplicada na agricultura. Alice.Cnptia.Embrapa.Br. Retrieved August 16, 2022, from <https://www.alice.cnptia.embrapa.br/bitstream/doc/1126261/1/LV-Agricultura-digital-2020-cap6.pdf>
- Tian, Y. Artificial Intelligence Image Recognition Method Based on Convolutional Neural Network Algorithm. *IEEE Access*, v. 8, p. 125731-125744, 2020.
- Yang, J., Wang, Y., Chen, Y., Yu, J. Detection of Weeds Growing in Alfalfa Using Convolutional Neural Networks. *Agronomy*. v. 12, n. 6, p. 1459, 2022.
- Zhang, W., Hansen, M., Volonakis, T., Smith, M., Smith. Broad-Leaf Weed Detection in Pasture. *IEEE 3rd International Conference on Image, Vision and Computing (ICIVC)*, p. 101-105, 2018.