

ENCOSIS 2019


ENCOSIS
ENCONTRO REGIONAL
DE COMPUTAÇÃO E
SISTEMAS DE INFORMAÇÃO



ANAIS

**VIII Encontro Regional de Computação
e Sistemas de Informação**

Artigos completos

Manaus, Amazonas, Brasil.

Reconhecimento de folíolos do guaranazeiro atacados pelo tripses por meio de imagens digitais

Richardson Allan F. de Souza¹, Marcos Filipe Alves Salame²

¹ Bolsista de Iniciação Científica FAPEAM

²Analista de Tecnologia da Informação

Embrapa Amazônia Ocidental Caixa Postal 319 – 69010-970 – Manaus – AM – Brasil

richardson.allan.souza@gmail.com, marcos.salame@embrapa.br

Abstract. *The thrips, Pseudophilothrips adisi, is the unique arthropod specie that makes economic losses to the Amazonas State's guarana crops. Currently, these damages are identified through the visual inspection of a expert or through laboratory analysis. This paper proposes an approach that uses Computer Vision and Supervised Machine Learning technics to the recognition of Guarana's young leaves attacked by the thrips from a digital image.*

Resumo. *O tripses, Pseudophilothrips adisi, é a única espécie de artrópode que causa danos econômicos aos cultivos de guaranazeiro no Estado do Amazonas. Atualmente, esses danos são identificados por meio da inspeção visual de um especialista ou através de análise realizada em laboratório. Este trabalho propõe uma abordagem que emprega técnicas de Visão Computacional e Aprendizado de Máquina Supervisionado no reconhecimento de folhas jovens do guaranazeiro atacadas pelo tripses a partir de uma imagem digital.*

1. Introdução

O tripses, *Pseudophilothrips adisi* (zur Strassen) é fitófago e se alimenta do conteúdo celular das estruturas jovens e tenras das plantas do guaranazeiro [Fontes and Tavares 2017]. Ao se alimentarem, formam numerosas e pequenas pontuações de onde sugam a seiva e causam alterações morfofisiológicas e de desenvolvimento, resultando, por fim, na redução significativa da produção de grãos de guaraná [Tavares et al. 2007]. Os danos econômicos provocados pelas altas populações dessa praga são representativos e requerem soluções para o seu controle [Tavares and Garcia 2009].

Dentre os problemas que podem ser tratados por técnicas de Aprendizado de Máquina (AM), podem ser citados: previsão e controle de pragas e epidemias, monitoramento em tempo real de animais e de safras, agricultura de alta precisão, previsão dos preços de *commodities* e melhoramento genético [Faceli et al. 2011].

Diante desse cenário, propõe-se o desenvolvimento de um modelo de classificação de Aprendizado de Máquina Supervisionado capaz de detectar folíolos do guaranazeiro atacados pelo tripses por meio de uma foto capturada pela câmera de celular. Para isso, uma base de dados com imagens de folíolos atacados (positivo) e não atacados (negativa) foi construída. Métodos de Visão Computacional (VC) foram aplicados para viabilizar o processo de treinamento usando as redes neurais artificiais (RNAs) e as máquinas de vetores de suporte (SVMs, do inglês *support vector machines*).

2. Trabalhos Relacionados

Na literatura existem vários trabalhos que buscam aplicar diversas técnicas de AM e VC na detecção de danos ou doenças que acometem vários tipos de cultivos. Porém, ainda não há nenhum estudo nesse sentido aplicado a cultura do guaranazeiro.

Dentre os trabalhos pertinentes, foram escolhidos os que passaram por uma fase de coleta de imagens e fizeram uso das técnicas de SVM e RNA para gerar um modelo de classificação.

Em [INAMASU et al. 2011] o objetivo é diferenciar uma praga das demais que estão presentes na região da folha. Para isso, o autor digitalizou amostras da folha para evitar problemas de iluminação e segmentação. Um classificador RNA foi implementado para fazer a segmentação da imagem por cor (RGB). A imagem segmentada passou por outra RNA afim de classificar a doença. A segmentação por cor usando RNA apresentou uma acurácia de 96,04%.

Já em [Santos 2015] pretende-se identificar bagas de café em uma imagem. Diante disso, imagens de cafeeiros foram tomadas em campo sob luz ambiente utilizando-se uma câmera digital SLR (CanonR EOS Rebel T3i). No processo de identificação foram usados detectores de regiões circulares como a Laplaciano da Gaussiana (LoG) e descritores para reconhecimento de objetos como o Histogramas de Gradientes Orientados (HOG) em conjunto com as técnicas de SVM e Gradient Boosting (GB). Chegando a 90% de precisão com SVM.

A ideia proposta neste trabalho possui como diferencial o uso da câmera fotográfica de celulares para capturar imagens para a preparação do conjunto de dados (do inglês *dataset*), com o intuito de viabilizar soluções mais acessíveis ao agricultor comum, além da geração de um modelo autônomo apto a realizar a classificação da imagem em uma cultura específica, o guaranazeiro, de forma automatizada.

3. Material e Métodos

3.1. Aquisição de imagens

A base de dados foi obtida de folhas do clone BRS Maués cultivados nas áreas do Banco Ativo de Germoplasma (BAG) da Embrapa Amazônia Ocidental, por uma câmera de celular (Motorola Moto G5) de 13 megapixel com as funções de HDR e Flash desativadas obtendo apenas a luz natural durante a coleta de imagens. Um papel cartão de cor branco e, posteriormente, outro de cor preta foram colocados a uma distância de 10 a 20 centímetro do folíolo, que ajudou na redução dos ruídos de fundo.

Folíolos com até 1,7 centímetros foram dispostos em placas de Petri com 15 indivíduos *P. adisi* adultos e monitorados durante 27 horas. Após esse período injúrias puderam ser observadas na parte adaxial (frontal) dos folíolos e registradas com a câmera do celular. Os folíolos também foram fotografados antes de incitar o ataque e junto a outros exemplos de imagens capturadas nas áreas do BAG.

Para manter um padrão de imagem, uma aplicação móvel foi desenvolvida utilizando o framework Ionic V3, o plugin de câmera nativo cordova-plugin-camera e uma biblioteca chamada angular-cropperjs v0.1.5. Essa aplicação, que pode ser vista na figura 1(b), permitiu destacar a área de interesse da imagem e gerar variações através da rotação e inversão da mesma com 1872 x 1872 pixels.

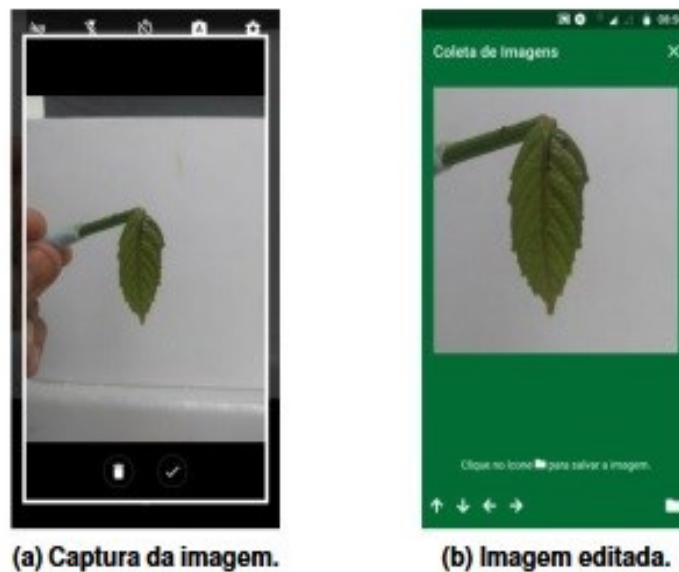


Figura 1. Aplicação para auxiliar na padronização da imagens

3.2. Extração de características

Todo o pré-processamento das imagens foi feito linguagem de programação Python juntamente com a biblioteca para VC OpenCV. A Figura 2(a), 2(b) e 2(c) ilustra a sequência até chegar a segmentação por limiarização. Essa limiarização foi obtida usando como parâmetro o THRESH_TRUNC com os limites 100 e 255.



Figura 2. Pré-processamento das imagens.

3.3. Avaliação dos modelos criados

Para fins de teste e simulação dos modelos gerados no processo de aprendizagem, um protótipo com a arquitetura Cliente/Servidor foi montado. Uma aplicação cliente foi criada com o Framework Ionic para obter fotos e enviá-las para o servidor de aplicação implementado com o Framework Flask responsável por processar a imagem e devolver o resultado da predição.

Por padrão, as imagens obtidas são codificadas em base64 enviadas a um servidor via requisição HTTP/JSON. No servidor a imagem é decodificada e submetida ao modelo de aprendizagem. Por fim, o resultado da predição é devolvido ao cliente.

4. Resultados

Como resultado temos, uma base de imagens com folíolos do guaranazeiro atacados pelo tripses, um protótipo Cliente/Servidor para realizar testes e simulações, e os primeiros modelos gerados.

Os primeiros treinamentos foram realizados com a técnica de Máquinas de Vetores de Suporte. Porém, devido a uma base de dados ainda pequena, os resultados apresentados ainda não foram satisfatórios, pois pretende-se alcançar uma acurácia maior que 90%.

5. Considerações Finais

Este trabalho apresentou a proposta de um modelo de classificação de Aprendizado de Máquina Supervisionado capaz de reconhecer folíolos atacados pelo tripses por meio de imagens digitais. Foi explicada a elaboração da base de dados e as técnicas de Visão computacional para extrair as características do ataque.

Para as próximas etapas, será aumentada a base de imagens, novos modelos com diferentes parâmetros serão gerados e outros métodos para extração de características serão avaliadas, além da realização de outros experimentos com a folha inteira, com apenas a parte central da folha sem a borda e em ambiente real de produção.

6. Agradecimentos

O autor agradece à Embrapa pela oportunidade de desenvolver o projeto, ao orientador Marcos Filipe Alves Salame, ao Dr. Adauto Maurício Tavares pelos ensinamentos compartilhados e disponibilidade em preparar exemplares do guaranazeiro que possibilitaram a aquisição de imagens, e a bolsista Julliane da Silva Fontes pelo suporte na coleta de exemplares e nos experimentos realizados.

Referências

- Faceli, K., Lorena, A. C., Gama, J., Carvalho, A. C. P. d. L., et al. (2011). Inteligência artificial: Uma abordagem de aprendizado de máquina.
- Fontes, J. d. S. and Tavares, A. (2017). Aspectos da biologia da linhagem sexuada do tripses-do-guaranazeiro (*pseudophilothrips adisi*, zur strassen)(thysanoptera: Phlaeothripidae). In *Embrapa Amazônia Ocidental-Artigo em anais de congresso (ALICE)*. In: JORNADA DE INICIAÇÃO CIENTÍFICA DA EMBRAPA AMAZÔNIA OCIDENTAL, 14.
- INAMASU, R., JORGE, L. d. C., and PAIVA, M. (2011). Aplicação de técnicas de processamentos de imagens para diferenciação do greening de outras pragas. *Embrapa Instrumentação-Tese/dissertação (ALICE)*.
- Santos, T. T. (2015). Detecção automática de bagas de café em imagens de campo. In *Embrapa Informática Agropecuária-Artigo em anais de congresso (ALICE)*. In: CONGRESSO BRASILEIRO DE AGROINFORMÁTICA, 10., 2015, Ponta Grossa.
- Tavares, A. and Garcia, M. (2009). Tripses do guaranazeiro: *Liothrips adisi zur strassen*, 1977 (thysanoptera: Phlaeothripidae, phlaeothripinae). *Embrapa Amazônia Ocidental-Documentos (INFOTECA-E)*.
- Tavares, A. M. T., Garcia, M. V. B., and Nascimento-Filho, F. (2007). *Tripses do guaranazeiro: estado atual e perspectivas*. Embrapa Amazônia Ocidental.