



Visão Computacional aplicada na identificação de doenças na fruticultura: uma Revisão Sistemática da Literatura

Heloise Acco Tives¹, Andreia Marini¹, André Roberto Ortoncelli²

¹Instituto Federal do Paraná (IFPR) – Palmas - PR - Brasil

²Universidade Tecnológica Federal do Paraná (UTFPR)
Dois Vizinhos - PR - Brasil

{heloise.acco, andreia.marini}@ifpr.eu.br, ortoncelli@utfpr.edu.br

Abstract. *Models based on computer vision have been effectively employed for the detection and classification of plant diseases. However, the existence of studies and their results are very scattered. This study presents the results of a Systematic Literature Review (SLR) that primarily focused on the application of computer vision to support the identification of pests/diseases in fruit farming. The main contributions of this work lie in describing the most commonly used techniques and tools, along with the indication of the crops and plant structures that serve as the basis for the analyses.*

Resumo. *Modelos baseados em visão computacional tem sido empregados para detectar e classificar doenças de plantas de forma eficaz. Entretanto, a existência de trabalhos e seus resultados estão muito dispersos. Esse estudo apresenta os resultados de uma Revisão Sistemática de Literatura que teve como foco a identificação de como a visão computacional tem sido aplicada para apoiar na identificação de pragas/doenças na fruticultura. As principais contribuições do trabalho estão na descrição das técnicas e ferramentas mais utilizadas, com o apontamento das culturas e estruturas das plantas que servem de base para as análises.*

1. Introdução

Estimativas confiáveis, precisas e exatas da severidade das doenças de uma planta são importantes entre outros fatores para prever a perda de rendimento, monitorar e evitar prolongamento de epidemias. Tradicionalmente, doenças de plantas são diagnosticadas por meio de avaliações visual dos sintomas feitas por especialistas humanos, avaliação microscópica de características morfológicas e aplicação de técnicas de diagnóstico molecular, sorológico e microbiológico. Esses métodos são considerados confiáveis, no entanto, também podem ser demorados, trabalhosos, caros e com grande dependência de especialistas humanos que nem sempre estão disponíveis [Oraño et al. 2019].

Outro fator a ser levado em consideração, é que a resposta dos avaliadores humanos não é sempre a mesma e depende de vários fatores [Bock et al. 2010]. Com isso, abordagens automatizadas de diagnóstico de pragas e doenças de plantas tem despertado grande interesse em pesquisas, oportunizando também condições mais rápidas de controle e manejo para evitar o incremento da severidade dos danos e impacto e/ou perdas nas colheitas [Oraño et al. 2019].

Os modelos baseados em visão computacional (VC) tem se tornado cada vez mais utilizados para detectar e classificar doenças de plantas de forma eficaz [Senthilkumar and Kamarasan 2020], mas notou-se que esses resultados estão muito dispersos. Com isso torna-se importante a realização de uma Revisão Sistemática de Literatura (RSL), para entendimento das atuais aplicações de visão computacional voltadas para a identificação de pragas e doenças na fruticultura. Nesse contexto, as principais contribuições deste trabalho ocorrem através da identificação das principais metodologias e tecnologias utilizadas para aplicação de VC na fruticultura, apontamento das estruturas de plantas mais estudadas, indicação da fase do ciclo produtivo onde ocorrem as análises, descrição do apoio ferramental necessário para aplicação dessas técnicas e metodologias, como também a sintetização das culturas que estão utilizando essas técnicas.

Este artigo está organizado da seguinte maneira: na seção 2 é descrita a base referencial que guiou a criação do protocolo da RSL. Na seção 3 é detalhada a metodologia utilizada para alcançar os objetivos propostos. A seção 4 apresenta os resultados obtidos com a condução da RSL. As considerações finais e os trabalhos futuros são descritos na seção 5.

2. Referencial Teórico

A fruticultura é o setor dedicado ao cultivo de plantações com frutos comestíveis. Todos os dias, vários tipos de frutas são vendidos em toneladas. O reconhecimento de doenças em frutas está rapidamente se tornando um tópico importante no campo da visão computacional. A presença de doenças de plantas não só reduz a produção de frutas, mas também pode causar perdas econômicas significativas [Hassam et al. 2022a].

A visão computacional e o aprendizado de máquina, se apresentam como os principais ramos da Inteligência Artificial (IA), progredindo em diferentes domínios de aplicações. Atualmente, esforços são direcionados para atender vários desafios que envolvem os diferentes setores agrícolas. Alguns desses domínios são: reconhecimento de frutas e vegetais, classificação de qualidade de frutas e vegetais, diagnóstico de doenças [Habib et al. 2022].

A aplicação de *Deep Learning* (DL) tem cada vez mais sido utilizada nesses cenários, sendo definido como um conjunto de métodos que permitem que modelos compostos por várias camadas aprendam representações dos dados em diferentes níveis de abstração [Lecun et al. 2015]. Esses algoritmos demonstraram ser capazes de superar os métodos tradicionais, em diferentes domínios de aplicações. As Redes Neurais Convolucionais (CNN), que são um dos principais métodos de *Deep Learning* dispostos na literatura, apoiam na classificação de imagens e têm a capacidade de produzir um diagnóstico conclusivo em vários casos [Pratapagiri et al. 2021].

3. Metodologia

Este trabalho utiliza a Revisão Sistemática de Literatura para sua execução, através das fases de Planejamento, Condução e Publicação de Resultados [Kitchenham 2004].

A questão de pesquisa principal investigada nesta revisão é: **“Como a visão computacional tem sido aplicada para apoiar na identificação de pragas/doenças na fruticultura?”**. Além desta questão de pesquisa, foram definidas Sub-questões de pesquisa, para responder questionamentos específicos, sendo: 1) Quais as técnicas e tecnologias são aplicadas?, 2) Em quais estruturas das plantas há análise?, 3) Em qual fase do ciclo produtivo a visão computacional é utilizada?, 4) Qual o apoio ferramental necessário? e 5) Em quais culturas há aplicação?. As Sub-questões de pesquisa permitiram categorizar e diagnosticar os conhecimentos atuais sobre a aplicação de técnicas de visão computacional para apoiar a identificação de pragas/doenças na fruticultura.

Como parte do protocolo de pesquisa definido na fase de planejamento, foi definida a estratégia de pesquisa como sendo a busca automática [Silva et al. 2015]. Foi realizada a busca três fontes de dados que são: Biblioteca Digital ACM, Biblioteca Digital IEEE Xplore e DBLP-Computer Science Bibliography.

A partir da estruturação realizada, a seguinte *string* foi definida para realização das buscas automáticas: (“COMPUTER VISION”) AND (“FRUIT”OR “ORCHARD”OR “PLANTATION”) AND (“PRAGUE”OR “ILLNESS”OR “PLAGUE”OR “COMMITMENT”OR “PROBLEM”OR “PATHOLOGY”OR “FUNGUS”OR “DISEASE”OR “DEFECT”OR “INSECT”OR “INFESTATION”OR “ATTACK”). Foi necessário adaptar a string para cada fonte conforme condições de concatenação disponibilizada.

Ainda durante a delimitação do protocolo, foram definidos os seguintes critérios de exclusão dos estudos primários: publicação em língua diferente de Português ou Inglês; trabalho com mais de 10 anos de publicação; pesquisas não relacionadas a VC aplicada identificação de pragas ou doenças na Fruticultura; trabalhos que não são estudos primários.

A fase de condução da RSL foi desenvolvida por duas pesquisadoras, com a seleção dos estudos primários em duas etapas. Na primeira etapa houve a leitura do título e resumo de todos os trabalhos. Na segunda etapa houve a leitura das demais seções dos artigos de forma a permitir a inclusão ou exclusão definitiva do trabalho da RSL.

4. Resultados

A condução da primeira etapa do protocolo de pesquisa nas três fontes resultou na seleção 81 trabalhos dos 339 identificados na execução da string de busca, ou seja, aproximadamente 24% dos trabalhos. A condução da segunda etapa do protocolo de pesquisa nas três fontes resultou na seleção final 34 trabalhos, dos quais 22 foram utilizados para responder as questões de pesquisa, já que 12 artigos não passaram pela segunda etapa de condução devido impossibilidade de acesso ao trabalho completo.

Os trabalhos analisados durante a RSL, utilizam diversos classificadores e algoritmos de aprendizagem de máquina diversos, como: SVM (*support vector machines*), RSVM (*Regression-type Support Vector Machines*), KNN (*k-nearest neighbors* e *Decision Tree*), RTree (*Regression Tree*), ESVM (*Enhanced SVM*), BPNN (*Back Propagation Neural Network*), FFNN (*Feed Forward Back Propagation*), LDA (*Linear Discriminat*

Analysis), NB (*Naive Bayes*), RF (*Random Forest*), RLinear (*Linear Regression*), GPR (*Gaussian Process Regression*) e MGSR (*Multiple Gene Symbolic Regression*).

Sobre as doenças, elas são o principal fator que diminui a produção vegetal. Estas doenças podem ocorrer em qualquer parte das plantas, incluindo caule, flores, frutos, folhas, entre outras [Chouhan et al. 2019]. A RSL realizada resultou na identificação de trabalhos que aplicam visão computacional em folhas, frutos ou ambos. Sobre a análise de flores, alguns trabalhos foram identificados, mas foram excluídos da pesquisa por não investigarem doenças e pragas na fruticultura.

A importância de compreender a fase do ciclo produtivo para identificação de doenças com apoio de visão computacional se dá pelo fato da possibilidade de execução de ações que desacelerem as doenças e minimizem os impactos negativos na produção. A fase do ciclo produtivo onde as pesquisas analisadas foram aplicadas envolve as frutas ainda na planta, em diferentes níveis de amadurecimento ou frutas já colhidas, sendo que alguns trabalhos não especificam exatamente a fase do ciclo produtivo no qual as pesquisas são aplicadas. Nos trabalhos pesquisados a maior incidência de pesquisas ocorre com os frutos ainda no pé, etapa onde é possível realizar o diagnóstico adequado da doença com a mensuração de sua gravidade para evitar ou pelo menos minimizar grandes prejuízos ecológicos e econômicos [Behera et al. 2018].

Utilizar um conjunto de dados confiável para aplicação de visão computacional é importante para aumentar a confiabilidade dos resultados obtidos. Em algumas pesquisas os conjuntos de dados são montados diretamente no campo de aplicação, utilizando câmeras fotográficas, câmeras de celulares, robôs com câmeras e até mesmo veículos aéreos não tripulados (VANTs), também conhecido como drones, equipados com câmeras. Quando não é possível criar um conjunto de dados, fontes online podem ser utilizadas para aplicação das pesquisas.

Sobre a construção do conjunto de dados, sabe-se que poderá não ser balanceada no que diz respeito a quantidade de amostras de plantas saudáveis e amostras de plantas doentes. Nesses casos, os pesquisadores tendem a usar métodos de aumento de dados produzindo imagens sintéticas que simulem as condições do mundo real. Entretanto, nem sempre essas estratégias são eficientes ou suficientes. Em geral, como em qualquer outro domínio que envolva aprendizado de máquina, a organização do conjunto de dados e confiabilidade a ele atribuída são elementos importantes durante a análise dos resultados reportados. Por esses fatores a escolha e organização das bases de imagens é tão relevante para os resultados das pesquisas.

Uma dificuldade descrita é quanto à aquisição das imagens. Por exemplo, a coleta de uma imagem hiperespectral requer instrumentos e especialistas relativamente caros para a coleta de dados. Além disso, a anotação/rotulação é uma etapa obrigatória para a criação de um novo conjunto de dados. Esse tipo de tarefa é demorada e também envolve especialistas para que possa existir garantia das anotações efetuadas [Ouhami et al. 2021].

Durante a realização da RSL identificou-se a aplicação de técnicas de visão computacional para várias culturas relacionadas a fruticultura, principalmente estudos que envolvem Frutas Cítricas, como laranja, limão e lima, mas também foram identificados estudos com banana, cereja, goiaba, jaca, maçã, manga, pêssigo, romã e tomate.

A planilha completa com os dados extraídos durante a realização da RSL está

disponível na pasta do Google Drive que pode ser acessada através desse link.

4.1. QP - Como a visão computacional tem sido aplicada para apoiar na identificação de pragas/doenças de fruticultura?

A aplicação de visão computacional para apoiar na identificação de pragas e doenças, foi analisada rigorosamente nos artigos selecionados para esta RSL. Durante a execução da pesquisa alguns trabalhos tiveram destaque pela forma de descrição das suas metodologias, conforme lista detalhada a seguir.

1. [Soini et al. 2019], desenvolveu um algoritmo para permitir aos produtores instalarem câmeras em seus veículos para monitorar pomares de forma automatizada, combinando um processo de visão computacional de extração de sub-imagens de uma imagem principal e um processo de aprendizado profundo que classifica as imagens com base no algoritmo inicial. As etapas envolvidas foram 1) Dimensionamento e remoção de ruído para consistência. 2) Filtragem por cor e resultados de limpeza. 3) Segmentação e contorno para permitir o uso no algoritmo de aprendizado profundo. 4) Sobreposição de Máscaras e Contorno das imagens. 5) Extração de segmentos como sub-imagens para especificar imagens das frutas para identificar como infectadas ou não infectadas por doenças. 6) Treinamento do modelo inicial do algoritmo de aprendizado profundo para categorização. A validação do modelo de forma cruzada ocorreu 10 vezes. O treinamento ocorreu com 100 mil imagens de mil categorias 7) Execução da avaliação final para cálculo da precisão e confiança do processo.
2. [Prabhu et al. 2021] apresentou uma análise comparativa de três classificadores. A metodologia combinou quatro etapas principais: 1) Pré-processamento. 2) Identificação do defeito ou doença usando algoritmo de agrupamento. 3) Seleção de recursos, a partir da identificação e extração de padrão ou características as imagem. 4) Treinamento e classificação das imagens, com a validação e registro do desempenho de cada algoritmo.
3. [Behera et al. 2018], através de duas etapas classificou de frutos doentes e mediu a gravidade das doença, com a realização dos seguintes passos: 1) segmentação das imagens para separar o fundo, o primeiro plano e a parte defeituosa, sendo que a parte defeituosa é a região de interesse (ROI) para análise. 2) a partir do ROI, os recursos de textura extraídos foram treinados para classificação. 3) a identificação automática da doença, ocorreu pela execução de um algoritmo de agrupamento que também calcula a gravidade da doença e estima a taxa de falha.
4. [Senthilkumar and Kamarasan 2019] executou o reconhecimento de manchas de lesão em frutas e folhas em plantas e classificou as doenças através das seguintes etapas: 1) os pontos a serem analisados foram extraídos usando uma abordagem de segmentação ponderada otimizada que ocorreu em uma imagem real aprimorada. 2) a cor, textura e características geométricas foram segmentadas. 3) os recursos ideais foram escolhidos desenvolvendo uma hibridação com p método de seleção de recursos que compreende uma pontuação de PCA, entropia e vetor de covariância baseado em assimetria. 4) as características escolhidas foram classificadas.
5. [Kumar et al. 2021] a classificação da doença infecta as folhas foi feita em um conjunto de dados capturado em tempo real. Essas imagens foram cortadas em tamanho padrão e, em seguida, o histograma foi equalizado para aumentar o contraste. Etapas envolvidas: 1) Coleta de folha infectadas e saudáveis em tempo real e, em seguida, coletadas imagens

de folhas de outras plantas de PlantVillage. 2) pré-processamento de todas as imagens no conjunto de dados, que inclui o corte da imagem e o aprimoramento do contraste usando a técnica de equalização do histograma. 3) rotulação das imagens. 4) divisão do conjunto de dados em conjunto de dados de treinamento e validação, dependendo dos rótulos atribuídos. 5) treinamento dos dados de treinamento e validação do modelo. 6) uso das imagens em tempo real para teste do algoritmo. 7) Desenvolvimento da Interface Gráfica do Usuário amigável para produtores.

6. [Hassam et al. 2022b] proposta de um novo framework baseado no aprendizado profundo e no algoritmo de otimização, contribuindo com o aumento de dados com base em quatro operações de aprimoramento de contraste, remoção de sombra, ajuste de intensidade de pixel, melhoria de brilho e melhoria de contraste local. A metodologia utilizada para o reconhecimento de doenças em frutas consiste nas etapas de: 1) pré-processamento. 2) detecção da região de interesse (ROI). 3) extração de características. 4) seleção de características. e 5) reconhecimento.

Com a condução da Revisão Sistemática de Literatura e a busca focada em obter elementos para responder as questões de pesquisa, foi possível perceber que as fases e técnicas atualmente existentes em Visão Computacional estão consolidadas e sendo aplicadas cada vez mais por pesquisadores em todo o mundo. De maneira geral, na fruticultura é observado o desafio da escassez de dados e para evolução das pesquisas existem duas opções, ou a coleta de imagens em pomares e plantações ou conseguem obtenção de imagens em bancos de dados disponibilizados de forma online, mas nem sempre de forma gratuita.

Entretanto, em ambos os métodos podem ser identificadas desvantagens, como por exemplo, o fato da aquisição de imagens poder implicar em múltiplas visitas ao mesmo pomar ou a diferentes pomares em etapas de cultivo específicas, ou ainda ser necessário realizar coleta de frutos e folhas para que possam ser levadas a locais equipados para aquisição de imagens, o que tende a ser custoso em tanto em termos de tempo, como também financeiramente. Já as imagens coletadas na internet em geral são livres de contextos, não sendo possível garantir a qualidade desejada. Ambos os métodos também requerem anotações manuais, o que é demorado e é suscetível a erros. Por isso, foi percebida, em diferentes trabalhos, a utilização de métodos de aumento de dados produzindo imagens sintéticas que simulam condições do mundo real. Entretanto, nem sempre essas estratégias são eficientes ou suficientes.

5. Considerações Finais

As abordagens para detecção de doenças de plantas usadas atualmente são, em sua maioria, manuais e requerem trabalho humano para realizar diagnósticos. Existem vários estudos que desenvolvem técnicas para resolver esse problema. Empresas agrícolas e agricultores individuais podem ser apoiados por informações atualizadas de pomares por meio de sistemas capazes de fornecer informações sobre doenças em estágios iniciais, quando ainda não existem tantos sinais de infecção presentes.

O diagnóstico correto e precoce de doenças e pragas em pomares depende da escolha adequada de técnica de Visão Computacional, do tipo, da quantidade e da qualidade dos dados disponíveis. Resultados promissores e que já estão sendo aplicados em poma-

res foram identificados na organização desta RSL, demonstrando a importância da Visão Computacional na detecção precoce de doenças na fruticultura.

Ao finalizar a análise dos trabalhos para RSL, percebeu-se que a maioria das aplicações de VC para identificação de pragas e doenças segue um conjunto de etapas similares, compostas por: como captura de imagem, pré-processamento de imagem, com a remoção de ruídos, segmentação, seleção de características e por fim a classificação. Sendo que práticas de segmentação tem sido cada vez mais utilizadas para proporcionar o aumento dos dados.

Como trabalhos futuros tem-se a aplicação das técnicas identificadas como mais utilizadas em bases de dados produzidas, como também em bases de dados disponibilizadas na internet. Com a realização dos experimentos propostos, pretende-se comparar os resultados obtidos com os resultados dos estudos incluídos nesta RSL.

Referências

- Behera, S. K., Jena, L., Rath, A. K., and Sethy, P. K. (2018). Disease classification and grading of orange using machine learning and fuzzy logic. In *2018 International Conference on Communication and Signal Processing (ICCSP)*, pages 0678–0682. IEEE.
- Bock, C., Poole, G., Parker, P., and Gottwald, T. (2010). Plant disease severity estimated visually, by digital photography and image analysis, and by hyperspectral imaging. *Critical reviews in plant sciences*, 29(2):59–107.
- Chouhan, S. S., Kaul, A., and Singh, U. P. (2019). A deep learning approach for the classification of diseased plant leaf images. In *2019 International Conference on Communication and Electronics Systems (ICCES)*, pages 1168–1172. IEEE.
- Habib, M. T., Raza, D. M., Islam, M. M., Victor, D. B., and Arif, M. A. I. (2022). Applications of computer vision and machine learning in agriculture: A state-of-the-art glimpse. In *2022 International Conference on Innovative Trends in Information Technology (ICITIT)*, pages 1–5.
- Hassam, M., Khan, M. A., Armghan, A., Althubiti, S. A., Alhaisoni, M., Alqahtani, A., Kadry, S., and Kim, Y. (2022a). A single stream modified mobilenet v2 and whale controlled entropy based optimization framework for citrus fruit diseases recognition. *IEEE Access*, 10:91828–91839.
- Hassam, M., Khan, M. A., Armghan, A., Althubiti, S. A., Alhaisoni, M., Alqahtani, A., Kadry, S., and Kim, Y. (2022b). A single stream modified mobilenet v2 and whale controlled entropy based optimization framework for citrus fruit diseases recognition. *Ieee Access*, 10:91828–91839.
- Kitchenham, B. (2004). Procedures for performing systematic reviews. *Keele, UK, Keele University*, 33(2004):1–26.
- Kumar, P., Ashtekar, S., Jayakrishna, S., Bharath, K., Vanathi, P., and Kumar, M. R. (2021). Classification of mango leaves infected by fungal disease anthracnose using deep learning. In *2021 5th International Conference on Computing Methodologies and Communication (ICCMC)*, pages 1723–1729. IEEE.
- Lecun, Y., Bengio, Y., and Hinton, G. (2015). Deep learning. *Nature*, 521(7553):436–444. Funding Information: Acknowledgements The authors would like to thank the

Natural Sciences and Engineering Research Council of Canada, the Canadian Institute For Advanced Research (CIFAR), the National Science Foundation and Office of Naval Research for support. Y.L. and Y.B. are CIFAR fellows. Publisher Copyright: © 2015 Macmillan Publishers Limited. All rights reserved.

- Oraño, J. F. V., Maravillas, E. A., and Aliac, C. J. G. (2019). Jackfruit fruit damage classification using convolutional neural network. In *2019 IEEE 11th International Conference on Humanoid, Nanotechnology, Information Technology, Communication and Control, Environment, and Management (HNICEM)*, pages 1–6. IEEE.
- Ouhami, M., Hafiane, A., Es-Saady, Y., El Hajji, M., and Canals, R. (2021). Computer vision, iot and data fusion for crop disease detection using machine learning: A survey and ongoing research. *Remote Sensing*, 13(13).
- Prabhu, A., Likhitha, S., et al. (2021). Identification of citrus fruit defect using computer vision system. In *2021 Second International Conference on Electronics and Sustainable Communication Systems (ICESC)*, pages 1264–1270. IEEE.
- Pratapagiri, S., Gangula, R., G, R., Srinivasulu, B., Sowjanya, B., and Thirupathi, L. (2021). Early detection of plant leaf disease using convolutional neural networks. In *2021 3rd International Conference on Electronics Representation and Algorithm (ICERA)*, pages 77–82.
- Senthilkumar, C. and Kamarasan, M. (2019). Optimal segmentation with back-propagation neural network (bpgnn) based citrus leaf disease diagnosis. In *2019 International Conference on Smart Systems and Inventive Technology (ICSSIT)*, pages 78–82. IEEE.
- Senthilkumar, C. and Kamarasan, M. (2020). An optimal weighted segmentation with hough transform based feature extraction and classification model for citrus disease. In *2020 International Conference on Inventive Computation Technologies (ICICT)*, pages 215–220. IEEE.
- Silva, F. S., Soares, F. S. F., Peres, A. L., de Azevedo, I. M., Vasconcelos, A. P. L., Kamei, F. K., and de Lemos Meira, S. R. (2015). Using cmmi together with agile software development: A systematic review. *Information and Software Technology*, 58:20–43.
- Soini, C. T., Fellah, S., and Abid, M. R. (2019). Citrus greening infection detection (cigid) by computer vision and deep learning. In *Proceedings of the 2019 3rd international conference on information system and data mining*, pages 21–26.