

Mapeamento sistemático de detecção e contagem de plantas em imagens agrícolas usando aprendizagem de máquina – proposta de modelagem para desenvolvimento de sistema

Carlos Daniel Pohlod¹

Kelly Lais Wiggers²

Regiane Orlovski³

Rodrigo Ferreira⁴

Thais Amanda Santos⁵

William Nahirnei Lopes⁶

RESUMO

A busca por produção de alimentos em grande escala continua sendo uma preocupação mundial. Nesse aspecto, realizada a detecção e contagem de plantas, estimar produção é uma área que está sendo explorada por técnicas de aprendizagem de máquina. Diante disso, este artigo tem como objetivo realizar um mapeamento bibliográfico das abordagens de aprendizagem de máquina aplicadas na estimativa de detecção e contagem de plantas. Com esse mapeamento, pretende-se avaliar se existem similaridades entre cultivos e técnicas escolhidas pelos autores e, dessa forma, propor uma modelagem para estudos futuros com imagens capturadas por VANTs. Para alcançar o objetivo proposto, foi aplicada uma *string* de busca em bases de dados e foram filtrados os resultados. Nesse mapeamento, 18 artigos foram relatados. Os resultados mostraram que o estado da arte indica que, modelos de Rede Neural Artificial (RNA), com destaque em Redes Neurais Convolucionais, estão sendo amplamente utilizados na contagem/estimativa de produção.

Termos para indexação: agricultura, estimativa de produção, redes neurais artificiais, VANT.

Systematic mapping of plant detection and counting in agricultural images using machine learning – modeling proposal for system development

ABSTRACT

The search for large-scale food production continues to be a global concern. In this regard, when detecting and counting plants, estimating production is an area that is explored by

Ideias centrais

- O acesso facilitado a RNAs despertam o interesse de pesquisas envolvendo diferentes tecnologias na agricultura.
- Ao incorporar técnicas com processamento digital de imagens, diferentes pesquisas objetivam tratar problemas da estimativa de produção.
- Há uma tendência de estudos envolvendo algoritmos de aprendizagem de máquina no setor agrícola, especialmente com redes neurais artificiais.

Recebido em
23/08/2021

Aprovado em
06/04/2022

Publicado em
27/07/2022



This article is published in Open Access under the Creative Commons Attribution licence, which allows use, distribution, and reproduction in any medium, without restrictions, as long as the original work is correctly cited.

¹ Estudante de graduação no curso de Ciência de Computação da Universidade Estadual do Centro-Oeste, Guarapuava, PR. E-mail: carlospohlod@gmail.com

² Graduada em Ciência da Computação, doutora em Informática, professora no Departamento de Ciência da Computação da Universidade Estadual do Centro-Oeste, Guarapuava, PR. E-mail: kellyl@unicentro.br

³ Graduada em Sistemas de Informação, doutoranda em Informática, professora no Departamento de Ciência da Computação da Universidade Estadual do Centro-Oeste, Guarapuava, PR. E-mail: rorlovski@unicentro.br

⁴ Engenheiro Agrônomo. Doutorando em Agronomia, pesquisador na Fundação Agrária de Pesquisa Agropecuária (Fapa), Guarapuava, PR. E-mail: rfagronomy@hotmail.com

⁵ Estudante de graduação no curso de Ciência de Computação da Universidade Estadual do Centro-Oeste, Guarapuava, PR. E-mail: thais.amandas18@gmail.com

⁶ Estudante de graduação no curso de Ciência de Computação da Universidade Estadual do Centro-Oeste, Guarapuava, PR. E-mail: william.nahirnei@hotmail.com

machine learning techniques. Given the above, this article aims to carry out a bibliographic mapping of machine learning approaches applied to plant detection and counting estimation. With this mapping, it was intended to evaluate if there are similarities between crops and techniques chosen by the authors and, in this way, to propose a model for future studies with images captured by UAVs. To achieve the proposed objective, a search string was applied to databases and the results were filtered. In this mapping, 18 papers were reported. The results showed that the state of the art indicates that Artificial Neural Network (ANN) models, mainly Convolutional Neural Networks (CNN), are being widely used in production counting/estimation.

Index terms: agriculture, production estimation, artificial neural networks, UAV.

INTRODUÇÃO

Frequentemente, as indústrias possuem dados extras armazenados sobre as operações em suas empresas e buscam a otimização dos seus processos, e na agricultura isso não é diferente. Com o advento da agricultura de precisão, muitos agricultores possuem informações extras disponíveis que foram coletadas por variados sensores, tais como temperatura do solo, componentes do solo, cobertura, e identificadores e monitores de crescimento (Sarwar et al., 2018). Entretanto, informações precisas e atuais sobre a plantação, números e localização de cada planta são mais desafiadoras em grandes áreas, pois é um trabalho demorado, intensivo e caro (Karami et al., 2020).

Assim, pesquisadores estão explorando abordagens alternativas baseadas em imagens. As geotecnologias surgem como uma ferramenta de destaque para fiscalização, análise de recursos e monitoramento do ambiente (Cândido et al., 2015). Os Veículos Aéreos Não Tripulados (VANTs), equipados de diversos sensores, tornaram-se alternativas para soluções rápidas e precisas (Ampatzidis & Partel, 2019), além de criarem um impacto significativo em diferentes aplicações baseadas em campo. Destacam-se estudos voltados para acompanhamento da plantação, sejam estimativas (Rahnemoonfar & Sheppard, 2017), detecção de ervas-daninhas (Milioto et al., 2017; Ampatzidis & Partel, 2019), detecção de tipo de plantação (Di Nisio et al., 2020; Feng et al., 2020) ou contagem de plantas (Karami et al., 2020). Esses são campos que, a longo prazo, auxiliam o melhor manejo das regiões exploradas. Em particular, a estimativa de contagem de plantas é um indicador importante para melhoramento de plantas para avaliar variedades e práticas de manejo. Além disso, a contagem de plantas indica a proporção de crescimento comparada com o número de sementes que foram plantadas, enquanto a localização fornece informações sobre a variabilidade associada em uma determinada área geográfica (Karami et al., 2020).

Diversas abordagens que utilizam aprendizagem de máquina têm sido investigadas para se trabalhar com o problema de contagens, sejam baseadas em modelos clássicos como K-nearest neighbor (KNN), Random Forest (RF) ou Support Vector Machine (SVM). Contudo, observa-se que as características das imagens podem desafiar o desempenho dos algoritmos, e então alternativas baseadas em aprendizagem profunda têm demonstrado um desempenho favorável em uma gama de aplicações, com potencial significativo para agricultura (Castro et al., 2018; Karami et al., 2020). Particularmente, o estado da arte indica que Redes Neurais Convolucionais (CNN) podem ser utilizadas com imagens de VANTs para realizar detecção de objetos de forma eficiente e precisa (Wang et al., 2018).

Diante desse exposto, este artigo tem como objetivo realizar um mapeamento bibliográfico das abordagens de aprendizagem de máquina aplicadas na estimativa de contagem de plantas. Com esse mapeamento, pretende-se avaliar se existem similaridades entre cultivos e técnicas escolhidas pelos autores e, dessa forma, propor uma modelagem para estudos futuros com imagens capturadas por VANTs.

FUNDAMENTAÇÃO TEÓRICA

Com a ampliação da mecanização agrícola, verifica-se cada vez mais a necessidade de analisar a variabilidade dentro do campo, visto que cada região pode ter propriedades diferentes. Quanto a

isso, o uso de geotecnologias propicia aos agricultores a oportunidade de verificar as necessidades em áreas determinadas da região agrícola, por mapeamento ou aplicação de fertilizantes, defensivos, água, entre outros.

Com relação a isso, o uso de ferramentas que auxiliem no armazenamento, processamento, gerenciamento e análise de dados é relevante. Com o avanço da tecnologia, a captura de imagens mediante VANTs vem crescendo e apresenta diversas vantagens técnicas e econômicas, visto que oferece facilidade na adaptação para cada projeto. As características das imagens capturadas estão diretamente relacionadas a diferentes parâmetros, como resolução, escalas e tipos de sensores (Cândido et al., 2015). As imagens capturadas pelos VANTs por meio de sensoriamento remoto (SR) devem ser vistas como documentos, sobre um plano 2D, que representam as feições naturais e artificiais da superfície terrestre (Menezes & Almeida, 2012).

O SR possibilita o registro de informações das regiões em diferentes níveis do espectro eletromagnético por meio de instrumentos a distância do objeto ou área de interesse. Após, as informações coletadas podem ser analisadas por meio visual ou mesmo via processamento digital de imagens (Jensen et al., 2009). Contudo, cada objeto apresenta um comportamento espectral que corresponde a um conjunto dos valores da reflectância ao longo do espectro eletromagnético, também chamado de assinatura espectral do objeto (Moraes, 2002). Assim, o fluxo de energia eletromagnética atinge um objeto e sofre interações com o material do qual o objeto é composto. Ele é parcialmente refletido, absorvido e então transmitido pelo objeto.

Essa assinatura espectral define as feições de cada objeto e é relacionada de acordo com o seu tipo, seja vegetação, rochas, solos, nuvens ou água. Isso torna o SR apto para ser analisado em diferentes áreas da pesquisa voltadas para a agricultura.

Para extrair as informações espectrais das imagens capturadas por SR e VANTs, as etapas disponíveis para processamento digital de imagens se tornam essenciais. Essas etapas serão explicitadas na sequência.

PROCESSAMENTO DIGITAL DE IMAGENS

O Processamento Digital de Imagens (PDI) é uma área em constante crescimento e de caráter interdisciplinar. O PDI consiste em técnicas expressas de forma algorítmica para capturar, representar e transformar imagens com o auxílio de um computador, e, como resultado, possibilitam a compreensão das relações entre o comportamento espectral dos objetos e suas propriedades. Isso facilita na percepção de informações das imagens bem como na interpretação (Marques Filho & Vieira Neto, 1999; Gonzalez & Woods, 2009). No entanto, destacam-se as etapas de processamento representadas na Figura 1. Destacam-se algumas dessas etapas:

- Aquisição de imagens: é o primeiro processo e envolve a escolha do sensor, lentes, iluminação da cena, horário de captura, velocidade de aquisição, entre outros.
- Pré-processamento: envolve as técnicas subsequentes, tais como verificação de ruídos, realce, redimensionamento da imagem.
- Segmentação: divide a imagem em suas partes ou objetos constituintes.
- Extração de características: também chamada de representação/descrição que parte do resultado da etapa de segmentação. A representação de cada objeto será baseada em suas características, e os dados devem ser convertidos de uma forma adequada para processamento computacional.

- Reconhecimento e interpretação: atribui um rótulo a cada objeto com base nas suas características.
- Base de conhecimento: o conhecimento do domínio é codificado em forma de banco de dados e controla a interação entre todos os módulos.

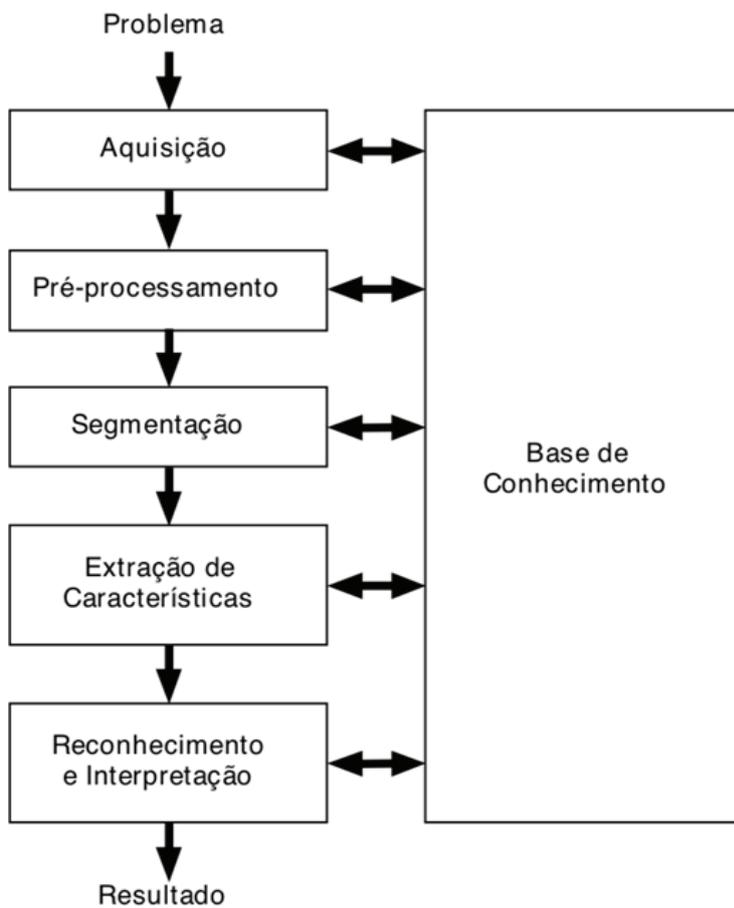


Figura 1. Passos fundamentais no processamento digital de imagens.

Fonte: Marques Filho & Vieira Neto (1999).

APRENDIZAGEM DE MÁQUINA

Em muitos trabalhos realizados com base em imagens aéreas, a fotointerpretação foi realizada por algum profissional experiente e, conforme a complexidade das feições dos objetos, pode demandar tempo e expertise desse fotointérprete. Os elementos de interpretação da imagem envolvem localização, tonalidade e cor, tamanho, forma, textura, padrão, entre outros (Gonzalez & Woods, 2009). Com o intuito de otimizar o tempo de processamento de dados e ampliar o reconhecimento de objetos na superfície terrestre de imagens digitais, técnicas de aprendizagem de máquina desempenham um papel importante na pesquisa de SR.

A Aprendizagem de Máquina (AM) é um conceito associado à Inteligência Artificial e tem se destacado em diversas abordagens que envolvem visão computacional, entre elas a classificação de imagens. Nessa técnica, cada pixel ou região da imagem é associada a uma classe que descreve algum tipo de cultivo, cobertura e uso da terra, tipos de vegetação, tipos de solos, reconhecimento de área urbana, entre outros. Além disso, pode envolver duas diferentes abordagens de classificação, sendo supervisionada e não supervisionada. Na abordagem supervisionada, é necessário que o usuário colete amostras para treinar e ensinar o classificador com exemplos de cada feição de interesse na cena. Já na abordagem não supervisionada, não são utilizados dados de formação, ou seja, é um processo independente do usuário. Assim, os algoritmos vão buscar por informações similares na imagem e agrupá-las em classes (Tan et al., 2009).

Cada região da imagem associada a uma classe é chamada de padrão. Esse padrão é um vetor de características que descreve um objeto. O objeto pode ser um pixel sozinho ou um conjunto de pixels adjacentes, formando uma entidade geográfica que será associada a uma classe. A etapa de reconhecimento dos padrões por máquina envolve técnicas de atribuição de padrões às suas respectivas classes, de forma automática, e com a menor intervenção humana possível (Gonzalez & Woods, 2009).

Tem-se alguns destaques com Randon Forest, Neupane et al. (2019), que realizaram a contagem de pés de banana, e Bonet et al. (2020), que usaram SVM com o intuito de realizar a contagem de palmeiras de extração de óleo vegetal.

Contudo, autores têm mostrado vantagens do uso de aprendizagem profunda sobre a extração de características manuais para a classificação/detecção de imagens, em que se citam Ho et al. (2019), para estimar o rendimento das plantações de melancias. As arquiteturas de redes neurais convolucionais (CNN) têm sido implementadas para diferentes problemas de reconhecimento de imagens, incluindo classificação. Csillik et al. (2018) detectaram frutas cítricas e outras árvores de cultivo com base em imagens de VANTs e detecção de objetos, em que Kalantar et al. (2020) aplicaram a técnica em imagens de plantações de melão. Com foco em imagens aéreas, essas CNNs têm apresentado destaque como extratoras de características, em que se citam Xu et al. (2020) para realizar a contagem rápida e precisa-se das espigas do trigo, e citam-se Wang et al. (2018) com foco na área urbana, podendo-se trabalhar com diferentes informações espaciais, escalas, cores ou texturas. Elas representam uma nova perspectiva para aprendizagem de máquina.

Na classificação de imagens, vale citar algumas arquiteturas que se destacaram, como: Rede Neural Artificial – Malinao & Hernandez (2018) –; e CNN – Csillik et al. (2018) e Selim et al. (2019). Na detecção de objetos, destacam-se as arquiteturas Fast CNN – Wang et al. (2018) –; R CNN – Sarwar et al. (2018) –; e CNN – Ampatzidis & Partel (2019).

PROTOCOLOS DE AVALIAÇÃO DE DESEMPENHO

A classificação de áreas capturadas por VANTs necessita de avaliação dos resultados, baseando-se nos experimentos realizados. Assim, devem ser definidas regiões não utilizadas no treinamento e validação para compor essa etapa de análise estatística.

Para cada objeto classificado da imagem, pode-se avaliar a precisa localização dele, considerando a métrica *Intersection over Union* (IoU). Para isso, é avaliada a sobreposição entre o objeto classificado (dada sua localização na imagem) e a localização definida no rótulo e *ground truth*. A sobreposição considera a posição da imagem rotulada $(x1, y1)$ e sua área $q1$. As posições do objeto candidato $(x1, y1)$ são também consideradas, bem como sua área $o1$, como descrito na equação 1 (Nowozin, 2014).

$$U_{iou}(x, y) = \frac{q1 \cap o1}{q1 \cup o1} \quad (1)$$

A Figura 2 apresenta exemplos das diferentes avaliações de desempenho utilizando-se IoU. Pode ser determinado um limiar para considerar que um objeto foi encontrado, como, por exemplo, $\text{IoU} \geq 0,6$.

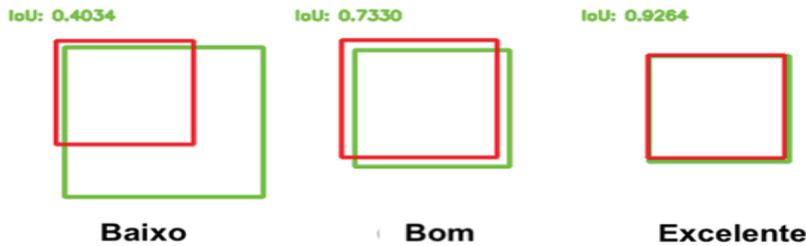


Figura 2. Exemplos de cálculo da IoU. Baixo desempenho com $\text{IoU} = 0,4034$. Bom desempenho com $\text{IoU} = 0,7330$. Excelente desempenho com $\text{IoU} = 0,9264$.

Fonte: adaptado de Cowton et al. (2019).

No intuito de avaliar estatisticamente os experimentos realizados, podem ser utilizados Precisão (PR) e Recall para cada conjunto de objetos de cada classe. Essas métricas são frequentemente utilizadas para avaliar o desempenho de classificação e detecção de objetos – Xu et al. (2020) utilizaram para avaliar o desempenho de classificação da CNN, Sarwar et al. (2018) aplicaram para o desempenho em R-CNN, Kestur et al. (2018) avaliaram em máquina de aprendizado extremo (ELM).

A PR avalia, de todos os objetos classificados, quantos efetivamente foram classificados corretamente. Já o Recall avalia se todos os objetos que deveriam ter sido classificados foram efetivamente classificados, ou seja, a frequência de classificações. Então a métrica mean Average Precision (mAP) é calculada. A AP é a área abaixo da curva de precisão e recall para cada objeto a ser identificado na imagem, que correspondem às equações 2 e 3, respectivamente (Powers, 2011):

$$\text{precisão} = \frac{\text{verdadeirosPositivos}(TP)}{\text{verdadeirosPositivos}(TP) + \text{falsoPositivos}(FP)} \quad (2)$$

$$\text{recall} = \frac{\text{verdadeirosPositivos}(TP)}{\text{verdadeirosPositivos}(TP) + \text{falsoNegativo}(FN)} \quad (3)$$

METODOLOGIA DE PESQUISA

Dermeval et al. (2020) descrevem que o levantamento do estado da arte é atividade obrigatória na realização de qualquer pesquisa científica de qualidade. Assim como em outros métodos de pesquisa, a questão de pesquisa de mapeamento sistemático da literatura é norteadora de toda a condução da pesquisa. Todas as atividades posteriores da revisão derivam da questão de pesquisa, logo, defini-la de forma fidedigna ao tópico que se quer investigar é fundamental para o sucesso da execução de uma revisão da literatura. Pode-se dizer que a questão de pesquisa é a atividade mais importante da etapa de planejamento de um mapeamento. Para tanto, a Figura 3 apresenta os processos metodológicos que foram executados neste artigo.

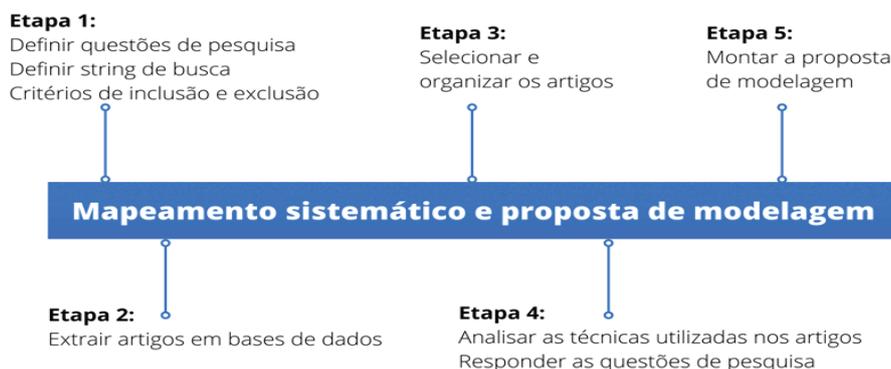


Figura 3. Passos para execução da metodologia de pesquisa.

Nesse aspecto, na etapa 1 se fez necessário definir as questões de pesquisa com intuito de serem respondidas no decorrer do trabalho:

- Q1. Quais são as ferramentas utilizadas para trabalhar com imagens de VANTs?
- Q2. Qual a técnica de extração de características utilizada?
- Q3. Qual a técnica de aprendizagem de máquina aplicada?
- Q4. Como foi realizado o particionamento da imagem de VANTs?
- Q5. Quais foram as análises estatísticas aplicadas para validação dos resultados?
- Q6. O método gerou um sistema (web/mobile)?
- Q7. O método gerou um banco de dados? Como foi armazenado?

Após a definição das questões, a primeira tarefa que deve ser feita para iniciar a busca dos estudos é a estruturação da questão de pesquisa em palavras-chave logicamente organizadas, ou seja, em uma *string* de busca (Dermeval et al., 2020).

Com o intuito de responder às questões supracitadas, a *string* de busca genérica com as respectivas palavras-chave, que foi adaptada para cada base de dados, seguiu a seguinte estrutura:

$((\text{“machine learning” OR “object detection” OR “deep learning” OR “neural network” }) \text{ AND } (\text{“unmanned aerial vehicle” OR “UAV”}) \text{ AND } (\text{“agriculture”}))$

Para finalizar a etapa 1, foram definidos os critérios de inclusão e exclusão, os quais darão suporte para a seleção dos artigos a serem explorados. Esses critérios estão apresentados na Tabela 1.

Tabela 1. Critérios de inclusão e exclusão para o mapeamento bibliográfico.

Critérios de inclusão
CI 1 - Um estudo é incluído se: abordar um método, técnica, abordagem ou estratégia para imagens de VANTs
CI 2 - Escrito em inglês com texto completo acessível online
Critérios de exclusão
CE 1 - Artigos não relacionados ao objetivo da pesquisa
CE 2 - Artigos duplicados
CE 3 - O artigo não está em inglês
CE 4 - O texto completo está inacessível online
CE 5 - Livros e literatura cinzenta
CE 6 - Resumos de tutoriais ou resumos de artigos, prefácios, entrevistas, resenhas, pôsteres, painéis de discussão

Na etapa 2, como o intuito do artigo é elaborar um mapeamento bibliográfico das abordagens de aprendizagem de máquina aplicadas na estimativa de detecção e contagem de plantas, buscando modelar uma estrutura de ferramenta para futuro desenvolvimento, foram selecionadas as bases: *ACM Digital Library*, *IEEE Xplore*, *Scopus* e *Springer Link*. Após a aplicação da *string*, obtiveram-se 45 artigos na *ACM Digital Library*, 89 artigos na *IEEE Xplore*, 269 artigos na *Scopus*, e 309 artigos na *Springer Link*. Como pode-se observar na Figura 4, 43,4% dos artigos foram publicados na base Springer, enquanto 37,8% foram publicados na Scopus.

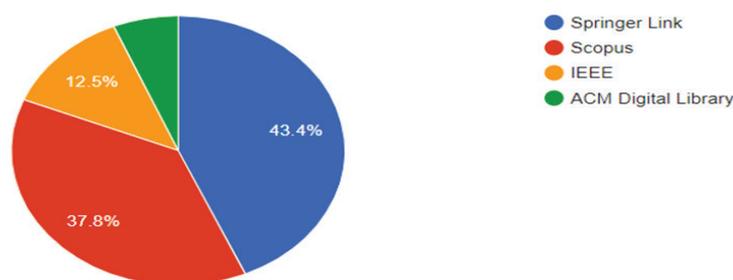


Figura 4. Percentual de artigos em cada base encontrados para o mapeamento.

Na etapa 3 é realizada a seleção dos artigos, considerando o processo de leitura dos títulos e resumo e atendendo aos critérios de inclusão. Nessa etapa, os trabalhos que passaram para a leitura completa resultaram em 17 artigos da Springer, 65 artigos da Scopus, 8 artigos da ACM. Vale ressaltar que nenhum artigo da IEEE atendeu aos critérios de inclusão. Nesse aspecto, temos a Tabela 2, abaixo, que ilustra os artigos selecionados e os artigos aceitos.

Tabela 2. Número total de artigos encontrados e aceitos para o mapeamento.

Base	Quantidade de artigos	Artigos aceitos
<i>ACM Digital Library</i>	45	8
IEEE Xplore	89	0
Scopus	269	65
Springer Link	309	17

Após a leitura completa dos trabalhos, verificou-se que apenas 18 trabalhos respondiam às questões de pesquisa. Assim, conforme cada questão de pesquisa, foram avaliadas as técnicas e abordagens utilizadas pelos usuários conforme a etapa 4 da pesquisa. Essa descrição está inclusa na seção de Resultados e Discussão. Assim, fez-se a análise dos dados, e sobre quais as similaridades entre técnicas dos autores, incluindo os resultados. Por fim, considerando as principais técnicas utilizadas pelos autores, e que se destacaram recentemente, na etapa 5 ocorre a proposta de modelagem, bem como a descrição de um sistema dedicado à detecção e contagem de plantas em imagens aéreas capturadas por VANT.

RESULTADOS E DISCUSSÃO

Conforme análise do mapeamento, foi observado um crescente interesse na aplicação de técnicas de aprendizagem de máquina para detecção de objetos em ambientes agrícolas a partir de 2017. Os trabalhos aceitos que respondiam às questões de pesquisa corresponderam a 7 artigos publicados em 2018, 3 artigos em 2019 e 8 artigos em 2020.

Para discussão dos resultados, foram separadas as questões de pesquisa Q2, Q3, Q4 e Q5 para avaliar as metodologias aplicadas pelos autores e buscar similaridades entre os métodos. As demais questões envolviam assuntos particulares de cada pesquisa e foram utilizadas para verificar a disponibilização de bases públicas, o uso de ferramentas para manipulação de imagens de VANTs e se foi desenvolvido algum produto.

- *Q1. Quais são as ferramentas utilizadas para trabalhar com imagens de VANTs?*

Várias abordagens foram encontradas utilizando-se técnicas de aprendizagem de máquina. Entre elas destacam-se: k-means, RNA, Árvore de Decisão e SVM.

Selim et al. (2019) realizaram contagem de plantação de laranjeiras, e para isso usaram o método de análise de imagem baseado em objeto, com uma precisão de 82,86%. Malinao & Hernandez (2018) realizaram um estudo com a finalidade de provar que o uso de VANTs combinado com RNA pode contribuir substancialmente para a indústria agrícola na classificação eficiente da fruta-pão. Para alcançar o objetivo do trabalho com a Rede Neural, a precisão foi de 72,66%.

Ashapure et al. (2020) aplicaram RNA com o intuito de estimar o rendimento da produção de algodão e alcançaram resultados satisfatórios, com precisão de 93%.

Kestur et al. (2018) realizaram a detecção e contagem de copa de árvores mediante o uso de máquina de aprendizado extremo (ELM) e algoritmo k-means como abordagem não supervisionada em imagens de VANTs. Nos experimentos realizados, tiveram uma precisão de 98%.

Varela et al. (2018) utilizaram a Árvore de Decisão para realizar o acompanhamento de crescimento da planta para detecção e contagem de milho. As imagens foram convertidas em excesso de verde (ExG), usando-se índice de vegetação e detecção de linhas e delineamento de contornos, tendo-se obtido uma precisão de 92%.

No mapeamento observaram-se alguns artigos que abordavam tecnologia realizada em relação à aprendizagem profunda, principalmente com modelo de CNN. Valente et al. (2020) utilizaram imagens aéreas a fim de realizar contagens de espinafre, e para isso usou-se o framework AlexNet com uma CNN que atingiu uma precisão de 95%. Xu et al. (2020) também utilizaram CNN para realizar a contagem rápida e precisa da espiga do trigo, e o agrupamento K-means foi usado para a segmentação automática de imagens de espigas de trigo. Como resultado do trabalho, obteve-se precisão de 98,47%.

Kalantar et al. (2020) aplicaram RetinaNet e CNN profunda em plantações de melão, tendo identificado os frutos em fotos de VANTs. Depois disso, foi estimado o peso de cada fruta, tendo sido obtida uma precisão de 92%. Já Barbedo et al. (2020) usaram CNN e correção de cor para contagem de gado, e 71% foram contados corretamente.

Ampatzidis & Partel (2019) utilizaram CNN para detecção de árvores, com o intuito de avaliar as características fenotípicas em culturas cítricas, com uma precisão de 98%. Enquanto isso, Csillik et al. (2018) detectaram frutas cítricas e outras árvores de cultivo com base em imagens de UAV, usando-se uma CNN, seguido por um refinamento de classificação usando-se superpixels derivados de um algoritmo *Simple Linear Iterative Clustering* (SLIC), tendo-se alcançado precisão geral de 96,24%.

Bonet et al. (2020) realizaram a contagem de palmeiras de extração de óleo vegetal mediante CNN VGG-16 como extrator de características e SVM para classificação, tendo obtido uma acurácia de 99% e precisão de 99,8%; enquanto Zhang et al. (2020) realizaram estimativa de contagem de colza (oleaginosa da China) por meio de CNN com uma precisão de 99,26%.

Também destaca-se que muitos autores utilizaram métodos de CNN que podem ser utilizados para detecção de objetos, já realizando o particionamento, extração de características e classificação. Sarwar et al. (2018) usaram imagens no espaço de cor RGB além de R-CNN com o intuito de detecção e contagem de ovelhas, tendo obtido resultados próximos a 100%. Wang et al. (2018) utilizaram Fast CNN, versão melhorada da R-CNN, para detecção de objetos em áreas urbanas, com um resultado de 86,52%.

Ho et al. (2019) aplicaram o Faster R-CNN, que é um modelo melhorado do Fast R-CNN, para estimar o rendimento das plantações de melancias. Os autores obtiveram uma precisão de 99%. Já Neupane et al. (2019) usaram a Faster-R CNN, para realizar a contagem de pés de banana, tendo obtido bons resultados, com 99% de acerto.

Destaca-se o trabalho de Oh et al. (2020), que aplicaram o método YOLO com o intuito de avaliar a estimativa de produção de plantas de algodão e contagem de pés. Eles realizaram vários experimentos, tendo o melhor resultado sido 88,16%.

- *Q2. Qual a técnica de extração de características utilizada?*

Dos autores selecionados, 12 deles utilizaram técnicas para extração de características mediante modelos de CNN, sendo eles: Csillik et al. (2018), Sarwar et al. (2018), Wang et al. (2018), Ampatzidis & Partel (2019), Ho et al. (2019), Neupane et al. (2019), Bonet et al. (2020), Kalantar et al. (2020), Oh et al. (2020), Valente et al. (2020), Xu et al. (2020), e Zhang et al. (2020).

Sarwar et al. (2018) compararam os resultados com características extraídas do modelo de rede R-CNN com um modelo baseado em extração manual de características, que analisa o limite de brilho na imagem em tons de cinza.

Além disso, Valente et al. (2020) utilizaram os métodos de extração de pixels verdes pela fórmula de *Excess Green Index* (ExG). Zhang et al. (2020) usaram ExGExR, um índice de vegetação de cor cuja identificação de capacidade de pixel verde foi utilizada para rotular os pixels verdes restantes como ervas daninhas.

Outros tipos de características foram considerados por Malinao & Hernandez (2018), que aplicaram o método de Simple Shape Descriptor para extrair as características. Já Ashapure et al. (2020) aplicaram atributos temporais e índices de vegetação como técnicas para compor os vetores de características das imagens.

Barbedo et al. (2020) usaram espaço de cor, segmentação e binário, para extração de características para formar o detector de objetos. Kestur et al. (2018) também fizeram a extração de características por meio de vetores binários.

Com relação a dados geométricos e vetoriais (Varela et al., 2018), descritores geométricos foram construídos a partir de contornos, com o intuito de extrair as características. Selim et al. (2019) extraíram as características de forma manual com auxílio de dados vetoriais, que foram comparadas com pontos de amostra retirados do solo por GPS.

- *Q3. Qual a técnica de aprendizagem de máquina aplicada?*

Destacaram-se as técnicas de CNN por Barbedo et al. (2020), Valente et al. (2020), Zhang et al. (2020), e Csillik et al. (2018) como técnica de aprendizagem de máquina.

Além disso, versões variadas de CNN para detecção foram abordadas. RetinaNet foi utilizada por Kalantar et al. (2020), Faster R-CNN por Ho et al. (2019) e Neupane et al. (2019), R-CNN foi utilizada por Malinao & Hernandez (2018) e Sarwar et al. (2018), e Fast CNN com método Feature Pyramid Network (FPN) por Wang et al. (2018). Além disso, Ampatzidis & Partel (2019) e Oh et al. (2020) utilizaram YOLO na detecção dos objetos.

Bonet et al. (2020) usaram uma rede CNN VGG-16 e também SVM para classificação. Xu et al. (2020) aplicaram o algoritmo de agrupamento K-means, e Ashapure et al. (2020) aplicaram RBF neural network (regressão).

Kestur et al. (2018) aplicaram máquina de aprendizado extremo (ELM) e k-means. Varela et al. (2018), para alcançar o objetivo do trabalho, utilizaram a Árvore de Decisão.

Contudo, Selim et al. (2019) não especificam qual técnica, apenas que é uma técnica de detecção de objetos.

- *Q4. Como foi realizado o particionamento da imagem de VANTs?*

A etapa de particionamento é variada entre os autores de acordo com a arquitetura de rede ou modelo de aprendizado utilizado para treinamento e detecção de objetos. Assim, observaram-se diferentes tamanhos de janelas que incluem as informações sobre os objetos a serem detectados.

Segundo Valente et al. (2020), com o objetivo de treinar o AlexNet, as imagens de entrada tinham um tamanho de 227×227 pixels. Ho et al. (2019) também redimensionaram as imagens adequadamente para classificação no AlexNet. Já Ampatzidis & Partel (2019) e Oh et al. (2020) realizaram o particionamento da imagem de VANTs por meio do YOLO. Já em Bonet et al. (2020), as imagens foram particionadas em imagens de 224×224 pixels, que são pré-requisitos para a rede CNN VGG-16. Csillik et al. (2018) aplicaram CNN em eCognition, tendo gerado 4.000 amostras de treinamento de 40×40 pixels.

Selim et al. (2019) utilizaram o caso mais ideal para ter um ortomosaico em que 227×227 pixels correspondem a uma área de planta.

Em Xu et al. (2020), para acelerar o processamento da imagem, a imagem original foi reduzida em 1400×1400 pixels do centro e dimensionada para 700×700 pixels.

Kalantar et al. (2020) utilizaram, para anotar a caixa delimitadora de cada fruta manualmente, a ferramenta “labelImg (version 1.8.1)”. Sarwar et al. (2018) também anotaram imagens de 250×250 pixels, tendo selecionado patches que contêm ou não objeto.

Malinao & Hernandez (2018) realizaram um trabalho com 7.597 folhas, que foram preparadas manualmente para análise morfológica. Barbedo et al. (2020) também definiram manualmente a divisão em quadrantes de até 50.000 pixels.

Com relação ao uso de sistemas disponíveis para particionamento, Ashapure et al. (2020) utilizaram o processamento no Agisoft, com tamanho de imagem de 1280×1024 pixels. Wang et al. (2018) usaram *Stanford Drone Dataset (SDD)* para particionar os objetos. Zhang et al. (2020) interpretaram e anotaram manualmente as folhas de colza ao longo das oito parcelas de amostra para cada dado de observação, tendo usado ArcMap 10.3.

Com base na imagem ortomosaica, Neupane et al. (2019) definiram a área de treinamento, e esta foi dividida em blocos de 600×600 pixels, em uma forma de grade sem preenchimento ou sobreposição.

Entretanto, em Kestur et al. (2018), as imagens não foram particionadas, pois foi realizada a contagem de pixels. Para a pesquisa de Varela et al. (2018), não houve particionamento das imagens VANTs; trabalharam com contornos da planta.

- *Q5. Quais foram as análises estatísticas aplicadas para validação dos resultados?*

Entre as técnicas estatísticas aplicadas nos estudos, observou-se que técnicas comuns, como a precisão (PR) e recall (RC), foram utilizadas por Csillik et al. (2018), Kestur et al. (2018), Sarwar et al. (2018), Ampatzidis & Partel (2019), Ho et al. (2019), Neupane et al. (2019), Selim et al. (2019), Barbedo et al. (2020), Bonet et al. (2020), Kalantar et al. (2020), Valente et al. (2020), Xu et al. (2020), e Zhang et al. (2020). Já o cálculo do F1-score foi utilizado por Csillik et al. (2018), Barbedo et al. (2020) e Xu et al. (2020).

Também foram observadas as aplicações de acurácia (ACC) por Varela et al. (2018) e Bonet et al. (2020), RMSE e coeficiente de determinação R² por Ashapure et al. (2020) e Oh et al. (2020), e Cumulative Distribution Functions (CDF) por Wang et al. (2018).

Com relação às questões de pesquisa “*Q6. O método gerou um sistema (web/mobile)?*” e “*Q7. O método gerou um banco de dados? Como foi armazenado?*”, nenhum dos trabalhos mapeados neste artigo teve como foco o armazenamento e geração de um sistema. O intuito dessas questões de pesquisa dava-se ao fato que este artigo é o primeiro nas fases de projeto de pesquisa, que tem como intuito modelar, testar as técnicas de aprendizagem de máquina e gerar um sistema com o intuito de auxiliar na agricultura.

A Tabela 3 apresenta uma visão geral dos artigos aceitos para estudo das técnicas escolhidas pelos autores. Nessa tabela foram selecionados os métodos utilizados nas questões Q2, Q3, Q4 e Q5, os quais possibilitam observar quais as técnicas recentemente mais utilizadas pelos autores, possibilitando a melhor escolha no desenvolvimento de novas abordagens.

MODELAGEM

Além da contribuição do mapeamento, buscou-se também apresentar uma modelagem com base nos trabalhos que foram relatados em resultados. Dos 18 artigos citados em resultados, todos os trabalhos usaram ferramentas prontas para aplicar técnicas de aprendizagem de máquina, porém, todos seguiam etapas definidas pelas ferramentas que consistiam, dependendo da técnica, no particionamento da imagem, extração das características, treinamento e validação da técnica.

Nesse aspecto, o desenvolvimento de uma ferramenta consistiria nas seguintes fases:

- No caso de se manter imagem, o usuário pode visualizar, carregar, redimensionar ou excluir a imagem captada por VANTs

Tabela 3. Artigos selecionados que envolvem detecção e contagem de plantas com aprendizagem de máquina.

Autor	Objetivo	Q2. Partições	Q3. Características	Q4. Técnica de AM	Q5. Análise estatística	Precisão (%)
Valente et al. (2020)	Contagem de pés de espinafre	227 × 227	CNN	CNN AlexNet	ACC e Erro	95
Selim et al. (2019)	Contagem de pés de laranja	227 × 227	Dados vetoriais	Baseada em objeto	PR	82,86
Xu et al. (2020)	Contagem de espigas de trigo	700 × 700	CNN e K-means	CNN	PR, RC, F1	98,47
Kalantar et al. (2020)	Contagem de melão	Elipse nas imagens	CNN e PCA	CNN Resnet50	PR, RC	92
Ho et al. (2019)	Contagem de melancia	1.000 × 1.000	Pixels e CNN	Faster R-CNN	PR	99
Malinao & Hernandez (2018)	Contagem de fruta-pão	Manual	Morfológicas	RNA	PR	72,66
Wang et al. (2018)	Contagem de objetos urbanos	FPN	FPN	Fast CNN	CDF	86,52
Ashapure et al. (2020)	Contagem de algodão	1.280 × 1.024	Índices de vegetação	RNA	RMSE e R2	93
Oh et al. (2020)	Contagem de algodão	416 × 416	CNN	YOLO como CNN	RMSE e R2	88,16
Barbedo et al. (2020)	Contagem de gado	Até 50.000 pixels	Cor e binário	NasNet Large CNN	PR e F1	71
Neupane et al. (2019)	Contagem de pés de banana	600 × 600	CNN	Faster R-CNN	PR, RC, ACC	99
Ampatzidis & Partel (2019)	Detecção de árvores	850 × 600	CNN	YOLO como CNN	PR, RC, F1	98
Sarwar et al. (2018)	Contagem de ovelhas	250 × 250	CNN e binário	R-CNN	PR e RC	100
Kestur et al. (2018)	Contagem de coroas de árvores	Contagem de pixels	Vetores binários	ELM	PR e RC	98
Varela et al. (2018)	Contagem de milho	Contornos da planta	Geométricas	Árvore de decisão	PR e RC	92
Bonet et al. (2020)	Contagem de palmeiras	224 × 224	CNN	Rede VGG-16	PR e ACC	99,8
Zhang et al. (2020)	Contagem de plantas de colza	Amostras por pixels	ExGExR	CNN	RMSE, PR, RC, F1	99,26
Csillik et al. (2018)	Contagem de cultivo	40 × 40	CNN	CNN	PR, RC, F1	96,24

- Nas etapas seguintes da pesquisa, pretende-se reunir os tipos de plantas que serão contadas, ou seja, o usuário precisa selecionar o tipo de cultura.
- Da mesma maneira, neste artigo foram elencadas as técnicas presentes na literatura sobre aprendizagem de máquina para contagem e estimativa de produção, aplicada em determinados tipos de culturas, que já foram relatadas.
- Após o usuário selecionar a cultura, habilitará a(s) técnica(s) que foram implementadas para aquela cultura, como o pré-processamento, o processamento e a validação. Ainda, o usuário pode selecionar os valores de sobreposição; por fim, todos os arquivos podem ser exportados.

- Outra necessidade será armazenar tanto os algoritmos de aprendizagem de máquina, quanto as imagens, e os valores de sobreposição.

A modelagem proposta pode ser observada na Figura 5, incluindo os atores que são o usuário e o banco de dados, bem como os casos de uso, com objetivo de descrever como será cada funcionalidade do sistema.

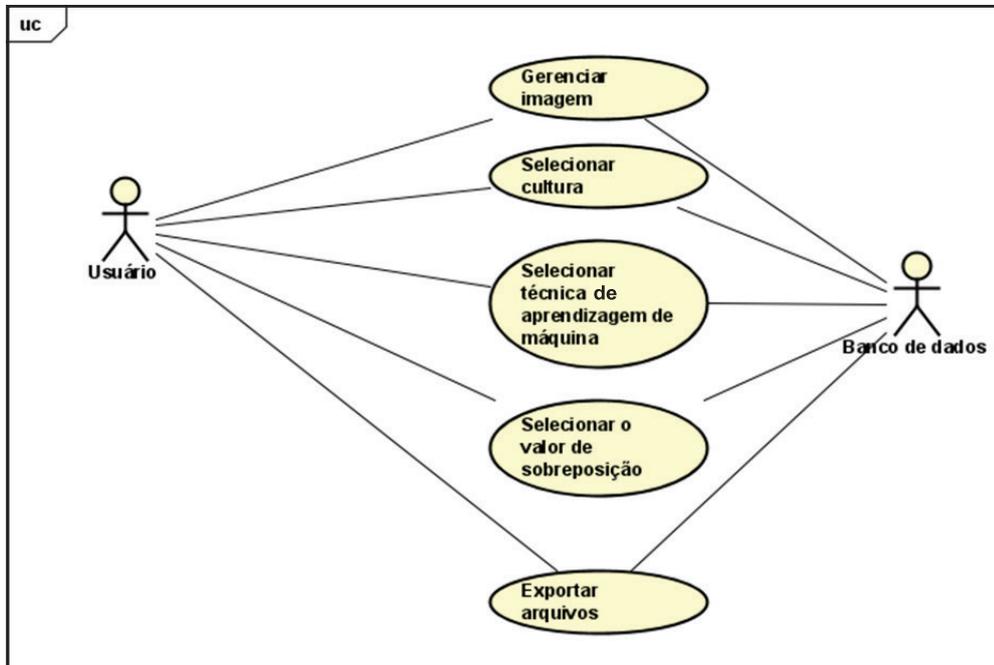


Figura 5. Proposta de modelagem para desenvolvimento da ferramenta.

CONSIDERAÇÕES FINAIS

Nesse artigo foi apresentado um mapeamento bibliográfico das abordagens de aprendizagem de máquina aplicadas na estimativa de contagem de plantas. Foram selecionados artigos de 4 bases de dados, e 18 artigos que respondiam às questões de pesquisa foram relatados.

Foi possível observar que há bastante divergência entre técnicas que estão sendo testadas e aplicadas na contagem/estimativa de culturas. Contudo, destacou-se grande interesse por parte dos pesquisadores por redes neurais convolucionais nas etapas de particionamento e extração de características.

Com esse mapeamento foi possível realizar uma modelagem para ser suporte do desenvolvimento de uma ferramenta que seja capaz de avaliar imagens capturadas por VANT e detectar objetos, considerando a variabilidade dos cultivos analisados.

Como trabalhos futuros pretende-se implementar as técnicas analisadas na modelagem e criar um protótipo de sistema para contagem automatizada de objetos de imagens agrícolas.

AGRADECIMENTO

À Fundação Agrária de Pesquisa Agropecuária (Fapa) pela disponibilização dos materiais e conteúdos para permitir a condução da pesquisa.

REFERÊNCIAS

- AMPATZIDIS, Y.; PARTEL, V. UAV-based high throughput phenotyping in citrus utilizing multispectral imaging and artificial intelligence. **Remote Sensing**, v.11, art.410, 2019. DOI: <https://doi.org/10.3390/rs11040410>.
- ASHAPURE, A.; JUNG, J.; CHANG, A.; OH, S.; YEOM, J.; MAEDA, M.; MAEDA, A.; DUBE, N.; LANDIVAR, J.; HAGUE, S.; SMITH, W. Developing a machine learning based cotton yield estimation framework using multi-temporal UAS data. **ISPRS Journal of Photogrammetry and Remote Sensing**, v.169, p.180-194, 2020. DOI: <https://doi.org/10.1016/j.isprsjprs.2020.09.015>.
- BARBEDO, J.G.A.; KOENIGKAN, L.V.; SANTOS, P.M.; RIBEIRO, A.R.B. Counting cattle in UAV images: dealing with clustered animals and animal/background contrast changes. **Sensors**, v.20, p.1-14, 2020. DOI: <https://doi.org/10.3390/s20072126>.
- BONET, I.; CARAFFINI, F.; PEÑA, A.; PUERTA, A.; GONGORA, M. Oil palm detection via deep transfer learning. In: IEEE CONGRESS ON EVOLUTIONARY COMPUTATION (CEC), 2020. **Proceedings**. [Piscataway]: IEEE, 2020. DOI: <https://doi.org/10.1109/CEC48606.2020.9185838>.
- CÂNDIDO, A.K.A.A.; SILVA, N.M. da; PARANHOS FILHO, A.C. Imagens de alta resolução espacial de Veículos Aéreos Não Tripulados (VANT) no planejamento do uso e ocupação do solo. **Anuário do Instituto de Geociência**, v.38, p.147-156, 2015. DOI: https://doi.org/10.11137/2015_1_147_156.
- CASTRO, A.I. de; TORRES-SÁNCHEZ, J.; PEÑA, J.M.; JIMÉNEZ-BRENES, F.M.; CSILLIK, O.; LÓPEZ-GRANADOS, F. An automatic random forest-OBIA algorithm for early weed mapping between and within crop rows using UAV imagery. **Remote Sensing**, v.10, art.285, 2018. DOI: <https://doi.org/10.3390/rs10020285>.
- COWTON, J.; KYRIAZAKIS, I.; BACARDIT, J. Automated individual pig localisation, tracking and behaviour metric extraction using deep learning. **IEEE Access**, v.7, p.108049-108060, 2019. DOI: <https://doi.org/10.1109/ACCESS.2019.2933060>.
- CSILLIK, O.; CHERBINI, J.; JOHNSON, R.; LYONS, A.; KELLY, M. Identification of citrus trees from unmanned aerial vehicle imagery using convolutional neural networks. **Drones**, v.2, 39, 2018. DOI: <https://doi.org/10.3390/drones2040039>.
- DERMEVAL, D.; COELHO, J.A.P. de M.; BITTENCOURT, I.I. Mapeamento Sistemático e Revisão Sistemática da Literatura em Informática na Educação. In: JAQUES, P.A.; SIQUEIRA, S.; BITTENCOURT, I.; PIMENTEL, M. (Org.). **Metodologia de Pesquisa Científica em Informática na Educação: abordagem quantitativa**. Porto Alegre: SBC, 2020. (Série Metodologia de Pesquisa em Informática na Educação, v.2). Disponível em: <<https://metodologia.ceie-br.org/livro-2>>. Acesso em: 15 jul. 2021.
- DI NISIO, A.; ADAMO, F.; ACCIANI, G.; ATTIVISSIMO, F. Fast detection of olive trees affected by Xylella Fastidiosa from UAVs using multispectral imaging. **Sensors**, v.20, art.4915, 2020. DOI: <https://doi.org/10.3390/s20174915>.
- FENG, Q.; YANG, J.; LIU, Y.; OU, C.; ZHU, D.; NIU, B.; LIU, J.; LI, B. Multi-temporal unmanned aerial vehicle remote sensing for vegetable mapping using an attention-based recurrent convolutional neural network. **Remote Sensing**, v.12, art.1668, 2020. DOI: <https://doi.org/10.3390/rs12101668>.
- GONZALEZ, R.C.; WOODS, R.E. **Processamento digital de imagens**. [S.l.]: Pearson, 2009.
- HO, M.; LIN, Y.-C.; HSU, H.-C.; SUN, T.-Y. An efficient recognition method for watermelon using faster R-CNN with post-processing. In: INTERNATIONAL CONFERENCE ON INNOVATION, COMMUNICATION AND ENGINEERING, 8., 2019, Zhengzhou. **Proceedings**. [S.l.]: IEEE, 2019. p.86-89. Editors: Shoou-Jinn Chang, Sheng-Joue Young, Artde Donald Kin-Tak Lam, Liang-Wen Ji, Hao-Ying Lu, Stephen D. Prior. DOI: <https://doi.org/10.1109/ICICE49024.2019.9117374>.
- JENSEN, J.R. **Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres**. São José dos Campos: Parêntese, 2009.
- KALANTAR, A.; EDAN, Y.; GUR, A.; KLAPP, I. A deep learning system for single and overall weight estimation of melons using unmanned aerial vehicle images. **Computers and Electronics in Agriculture**, v.178, art.105748, 2020. DOI: <https://doi.org/10.1016/j.compag.2020.105748>.

- KARAMI, A.; CRAWFORD, M.; DELP, E.J. Automatic plant counting and location based on a few-shot learning technique. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v.13, p.5872-5886, 2020. DOI: <https://doi.org/10.1109/JSTARS.2020.3025790>.
- KESTUR, R.; ANGURAL, A.; BASHIR, B.; OMKAR, S.N.; ANAND, G.; MEENAVATHI, M.B. Tree crown detection, delineation and counting in UAV remote sensed images: a neural network based spectral-spatial method. **Journal of the Indian Society of Remote Sensing**, v.46, p.991-1004, 2018. DOI: <https://doi.org/10.1007/s12524-018-0756-4>.
- MALINAO, R.M.L.; HERNANDEZ, A.A. Classifying breadfruit tree using artificial neural networks. In: INTERNATIONAL CONFERENCE ON APPLIED COMPUTING AND INFORMATION TECHNOLOGY, 6., 2018, Kunming. **Proceedings**. New York: ACM, 2018. p.27-31. ACIT 2018. DOI: <https://doi.org/10.1145/3265007.3265014>.
- MARQUES FILHO, O.; VIEIRA NETO, H. **Processamento digital de imagens**. Rio de Janeiro: Brasport, 1999.
- MENEZES, P.R.; ALMEIDA, T. de. (Org.). **Introdução ao processamento de imagens de sensoriamento remoto**. Brasília: CNPq, 2012.
- MILIOTO, A.; LOTTES, P.; STACHNISS, C. Real-time blob-wise sugar beets vs weeds classification for monitoring fields using convolutional neural networks. **ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v.IV-2/W3, 2017. p.41-48. DOI: <https://doi.org/10.5194/isprs-annals-IV-2-W3-41-2017>.
- MORAES, E.C. de. Capítulo 1: **fundamentos de sensoriamento remoto**. São José dos Campos: INPE, 2002. INPE-8984-PUD/62.
- NEUPANE, B.; HORANONT, T.; HUNG, N.D. Deep learning based banana plant detection and counting using high-resolution red-green-blue (RGB) images collected from unmanned aerial vehicle (UAV). **PLoS ONE**, v.14, e0223906, 2019. DOI: <https://doi.org/10.1371/journal.pone.0223906>.
- NOWOZIN, S. Optimal decisions from probabilistic models: the intersection-over-union case. In: IEEE CONFERENCE COMPUTER VISION AND PATTERN RECOGNITION, 2014, Columbus. **Proceedings**. Danvers: IEEE Computer Society, 2014. CVPR 2014. DOI: <https://doi.org/10.1109/CVPR.2014.77>.
- OH, S.; CHANG, A.; ASHAPURE, A.; JUNG, J.; DUBE, N.; MAEDA, M.; GONZALEZ, D.; LANDIVAR, J. Plant counting of cotton from UAS imagery using deep learning-based object detection framework. **Remote Sensing**, v.12, art.2981, 2020. DOI: <https://doi.org/10.1109/CVPR.2014.77>.
- POWERS, D.M.W. Evaluation: from precision, recall and f-measure to ROC, informedness, markedness & correlation. **Journal of Machine Learning Technologies**, v.2, p.37-63, 2011.
- RAHNEMOONFAR, M.; SHEPPARD, C. Real-time yield estimation based on Deep Learning. **Proceedings of SPIE**, v.10218, art.1021809, 2017. DOI: <https://doi.org/10.1117/12.2263097>.
- SARWAR, F.S.; GRIFFIN, A.; PERIASAMY, P.; PORTAS, K.; LAW, J. Detecting and counting sheep with a Convolutional Neural Network. In: IEEE INTERNATIONAL CONFERENCE ON ADVANCED VIDEO AND SIGNAL BASED SURVEILLANCE, 15., 2018, Auckland. **Proceedings**. [S.l.]: IEEE, 2018. AVSS 2018. DOI: <https://doi.org/10.1109/AVSS.2018.8639306>.
- SELIM, S.; SONMEZ, N.K.; COSLU, M.; ONUR, I. Semi-automatic tree detection from images of unmanned aerial vehicle using object-based image analysis method. **Journal of the Indian Society of Remote Sensing**, v.47, p.193-200, 2019. DOI: <https://doi.org/10.1007/s12524-018-0900-1>.
- TAN, P.-N.; STEINBACH, M.; KUMAR, V. **Introdução ao Data Mining: mineração de dados**. Rio de Janeiro: Ciência Moderna, 2009.
- VALENTE, J.; SARI, B.; KOOISTRA, L.; KRAMER, H.; MÜCHER, S. Automated crop plant counting from very high-resolution aerial imagery. **Precision Agriculture**, v.21, p.1366-1384, 2020. DOI: <https://doi.org/10.1007/s11119-020-09725-3>.
- VARELA, S.; DHODDA, P.R.; HSU, W.H.; PRASAD, P.V.V.; ASSEFA, Y.; PERALTA, N.R.; GRIFFIN, T.; SHARDA, A.;

FERGUSON, A.; CIAMPITTI, I.A. Early-season stand count determination in corn via integration of imagery from Unmanned Aerial Systems (UAS) and supervised learning techniques. **Remote Sensing**, v.10, art.343, 2018. DOI: <https://doi.org/10.3390/rs10020343>.

WANG, X.; CHENG, P.; LIU, X.; UZOCHUKWU, B. Fast and accurate, convolutional neural network based approach for object detection from UAV. In: ANNUAL CONFERENCE OF THE IEEE INDUSTRIAL ELECTRONICS SOCIETY, 44., 2018, Washington. **Proceedings**. [S.l.]: IEEE, 2018. IECON 2018. DOI: <https://doi.org/10.1109/IECON.2018.8592805><https://doi.org/10.48550/arXiv.1808.05756>.

XU, X.; LI, H.; YIN, F.; XI, L.; QIAO, H.; MA, Z.; SHEN, S.; JIANG, B.; MA, X. Wheat ear counting using K-means clustering segmentation and convolutional neural network. **Plant Methods**, v.16, art.106, 2020. DOI: <https://doi.org/10.1186/s13007-020-00648-8>.

ZHANG, J.; ZHAO, B.; YANG, C.; SHI, Y.; LIAO, Q.; ZHOU, G.; WANG, C.; XIE, T.; JIANG, Z.; ZHANG, D.; YANG, W.; HUANG, C.; XIE, J. Rapeseed stand count estimation at leaf development stages with UAV imagery and convolutional neural networks. **Frontiers in Plant Science**, v.11, art.617, 2020. DOI: <https://doi.org/10.3389/fpls.2020.00617>.
