

Inteligência artificial aplicada na agricultura de precisão e digital

Artificial intelligence applied in precision and digital agriculture

Lucio André de Castro Jorge¹, Lucas Prado Osco², José Marcato Júnior³, Ana Paula Marques Ramos⁴, Wesley Nunes Gonçalves⁵, Eduardo Antonio Speranza⁶, Carlos Manoel Pedro Vaz⁷, Ricardo Yassushi Inamasu⁸

¹ Engenheiro Eletricista, Mestre, Doutor, Pesquisador, Embrapa Instrumentação, São Carlos (SP), Brasil, lucio.jorge@embrapa.br

² Engenheiro Ambiental, Mestre, Doutor, Professor, Faculdade de Engenharia e Arquitetura e Urbanismo da Universidade do Oeste Paulista, Presidente Prudente (SP), Brasil, lucasosco@unoeste.br

³ Engenheiro Cartógrafo, Mestre, Doutor, Faculdade de Engenharia, Arquitetura, Urbanismo e Geografia da Universidade Federal do Mato Grosso do Sul, Campo Grande (MS), Brasil, jose.marcato@ufms.br

⁴ Engenheiro Cartógrafo, Mestre, Doutor, Faculdade de Ciência e Tecnologia da Universidade Estadual Paulista de Presidente Prudente, Presidente Prudente (SP), Brasil, anamos@unoeste.br

⁵ Engenheiro de Computação, Faculdade de Ciência da Computação da Universidade Federal do Mato Grosso do Sul, Campo Grande (MS), Brasil, wesley.goncalves@ufms.br

⁶ Cientista da Computação, Mestre, Doutor, Pesquisador, Embrapa Agricultura Digital, Campinas (SP), Brasil, eduardo.speranza@embrapa.br

⁷ Físico, Mestre, Doutor, Pesquisador, Embrapa Instrumentação, São Carlos (SP), Brasil, carlos.vaz@embrapa.br

⁸ Engenheiro Mecânico, Mestre, Doutor, Pesquisador, Embrapa Instrumentação, São Carlos (SP), Brasil, ricardo.inamasu@embrapa.br

RESUMO

A integração da IA tem revolucionado a maneira como os dados agrícolas são coletados, analisados e interpretados, destacando-se particularmente o uso de imagens obtidas por veículos aéreos não tripulados (VANTS) e a análise avançada de séries temporais por meio da fusão de dados. O presente trabalho explora os avanços e as novas perspectivas trazidas pela aplicação de técnicas de inteligência artificial (IA), com um enfoque especial no *deep learning* (DL), dentro do contexto da agricultura de precisão e digital. As tecnologias de DL, incluindo redes neurais convolucionais (CNNs), estão no epicentro dessa transformação. Essas redes profundas permitem não apenas a detecção eficiente de objetos e o monitoramento detalhado das condições agrícolas utilizando dados RGB e multi e hiperespectrais, mas também viabilizam a otimização dos processos agrícolas. Aqui discute-se como essas tecnologias contribuem significativamente para a redução de custos e minimização dos impactos ambientais por meio de aplicações operacionais em tempo real. Além disso, apresenta-se uma revisão abrangente das técnicas de DL que estão sendo aplicadas na agricultura, destacando suas contribuições para o avanço da agricultura digital e de precisão. Também se discute como a adoção crescente de GPUs e clusters de processamento está impulsionando inovações significativas no setor, focando especialmente na implementação dessas tecnologias em VANTS, robôs e máquinas agrícolas. Essa análise detalhada não apenas ilustra o potencial transformador da IA na agricultura, mas também propõe caminhos para futuras pesquisas e desenvolvimentos tecnológicos que poderiam otimizar ainda mais a produção agrícola e promover práticas de cultivo mais sustentáveis e eficientes.

Palavras-chave: aprendizagem de máquina; sensoriamento remoto; aprendizagem profunda; VANT; agricultura de precisão.

ABSTRACT

The integration of AI has revolutionized the way agricultural data are collected, analyzed, and interpreted, with a notable emphasis on the use of images captured by Unmanned Aerial Vehicles (UAVs) and advanced time-series analysis through data fusion. This work explores the advancements and new perspectives brought about by the application of Artificial Intelligence (AI) techniques, with a special focus on Deep Learning (DL), within the context of precision and digital agriculture. DL technologies, including convolutional neural networks (CNNs), are at the epicenter of this transformation. These deep networks enable not only efficient object detection and detailed monitoring of agricultural conditions using RGB, multi-spectral, and hyper-spectral data but also facilitate the optimization of agricultural processes. Here, we discuss how these technologies significantly contribute to

<https://doi.org/10.4322/978-65-86819-38-0.1000082>

 Este é um capítulo publicado em acesso aberto (Open Access) sob a licença Creative Commons Attribution-NonCommercial-NoDerivatives, que permite uso, distribuição e reprodução em qualquer meio, sem restrições desde que sem fins comerciais, sem alterações e que o trabalho original seja corretamente citado.

cost reduction and the minimization of environmental impacts, through real-time operational applications. Moreover, a comprehensive review of DL techniques being applied in agriculture is presented, highlighting their contributions to the advancement of digital and precision agriculture. We also discuss how the growing adoption of GPUs and processing clusters is driving significant innovations in the sector, focusing especially on the implementation of these technologies in UAVs, robots, and agricultural machinery. This detailed analysis not only illustrates the transformative potential of AI in agriculture but also proposes pathways for future research and technological developments that could further optimize agricultural production and promote more sustainable and efficient farming practices.

Keywords: Machine learning; remote sensing; deep learning; UAV; precision agriculture.

1 INTRODUÇÃO

A inteligência artificial é uma área da computação e tem sido aplicada em diferentes áreas, destacando-se na agricultura de precisão e digital com o uso de reconhecimento de padrões e aprendizado de máquina (*machine learning* – ML, incluindo o aprendizado profundo, *deep learning* – DL). A principal importância da inteligência artificial na agricultura de precisão está na análise de grandes conjuntos de dados, aprendendo padrões que possibilitem, por exemplo, identificar a variabilidade no campo ou antecipar a produtividade de uma lavoura e criar alguns processos automatizados.

O uso de inteligência artificial (IA) pode ser capaz de reconhecer por um sistema computacional todos os padrões ensinados. É por essa razão que muitos dos problemas importantes de IA podem ser caracterizados, como classificações e agrupamentos de medições de temperatura, dados climáticos, valores espectrais, dentre outros. O reconhecimento de padrões por um sistema computacional é capaz de aprender e diferenciar os dados. Para o processamento desses dados, existem várias técnicas, tais como árvores de decisão, florestas aleatórias, k-vizinhos mais próximos, máquinas de vetores de suporte, redes neurais, dentre outras (Bishop, 2006). A aplicação de técnicas de IA pode indicar, por exemplo, que uma dada sequência de valores de temperatura está dentro da normalidade, que uma cultura está com certa praga, ou que o objeto que está em determinada posição em uma imagem é uma laranja.

O aprendizado de máquina é uma subárea da inteligência artificial, representando os algoritmos que aprendem com os padrões que lhes foram apresentados. Em geral, o aprendizado de máquina é dividido em: supervisionado, quando a partir de um conjunto previamente definido de dados rotulados deseja-se encontrar uma função que seja capaz de prever rótulos desconhecidos; e não supervisionado, em que se busca identificar grupos ou padrões a partir dos dados (Russel; Norvig, 2020). No aprendizado não supervisionado o conjunto de dados utilizado não possui ne-

nhum tipo de rótulo. O objetivo desse tipo de aprendizagem é detectar similaridades e anomalias entre os objetos analisados. O processo de agrupamento de objetos em classes similares é denominado clusterização, a qual pode ser utilizada para segmentação de dados, particionando grandes conjuntos de dados de acordo com a similaridade entre subconjuntos e algoritmos hierárquicos que não exigem a identificação de representantes iniciais e nem da quantidade de grupos desejada (Russel; Norvig, 2020).

O aprendizado supervisionado de máquina consiste em apresentar uma grande quantidade de dados previamente classificados e fazer com que se aprenda a partir desses dados. Os principais paradigmas de aprendizado, segundo Russel e Norvig (2020), são:

- Simbólico (árvores de decisão): – baseado em instâncias (k-NN ou k vizinhos mais próximos); – baseado em aprendizado estatístico (SVM – *Support Vector Machines*); – baseado em comitê (*random forest*); – conexionista (redes neurais artificiais – RNA); são modelos computacionais inspirados pelo cérebro humano, capazes de realizar o aprendizado de máquina, bem como o reconhecimento de padrões, que é um dos mais utilizados recentemente. Um exemplo de modelo conexionista é a técnica de *deep learning* (DL) ou aprendizado profundo.

A técnica de aprendizado profundo (*deep learning*), ou redes neurais profundas, é uma técnica de aprendizado de máquina na qual o modelo escolhido para o algoritmo de aprendizado é uma rede neural artificial com muitas camadas.

As redes neurais foram inspiradas pela forma como os neurônios funcionam em sistemas biológicos, nos quais operam de modo paralelo e descentralizado (Russel; Norvig, 2020). Tipicamente, uma rede neural pode conter muitas camadas, dispostas uma após a outra ou em paralelo. Cada uma dessas camadas é composta por um ou mais neurônios, interligados entre si de forma que o resultado dos neurônios que estão em uma camada alimenta a entrada dos neurônios que estão na camada posterior. Existem diferentes algoritmos de treinamento de redes neurais,

sendo mais frequentemente empregado o algoritmo chamado *backpropagation*. Existem muitas arquiteturas de redes neurais disponíveis, como as redes conectadas para frente (*feedforward*), as redes convolutivas, as redes recorrentes e as máquinas de Boltzmann restritas, entre muitas outras (Russel; Norvig, 2020).

A inteligência artificial na agricultura pode ser aplicada em diferentes tipos de dados, desde dados provenientes de sensores operando em campo, embarcados ou não em máquinas, sensores IoT (Internet das coisas), em robôs terrestres, veículos aéreos, dados suborbitais e orbitais, os quais tem cada vez mais se destacado para os sistemas de visão computacional e sistemas de fusão de sensores. Na Figura 1 podem ser observadas as diferentes escalas de sensores utilizados na agricultura digital e que cada vez mais têm sido integrados às fazendas.

Na última década, aplicações realizadas com algoritmos estatísticos e de *machine learning* (ML) foram usadas principalmente em tarefas de classificação/regressão. O aumento dos sistemas de sensoriamento remoto nas diferentes escalas, como apresentado na Figura 1, tem permitido uma ampla coleta de dados na superfície da Terra. Imagens aéreas tornaram-se uma abordagem comum para aquisição de dados com o advento dos veículos aéreos não tripulados (VANT). Estes também são conhecidos como aeronaves remotamente pilotadas (ARP), ou, como em um termo popular, drones (multirrotores, de asas fixas, híbridos etc.). Esses dispositivos têm crescido em disponibilidade no mercado por seu custo relativamente baixo

e alta capacidade operacional na captura de imagens de maneira rápida e fácil. A alta resolução espacial das imagens baseadas em VANTs e sua capacidade para múltiplas visitas permitiram a criação de grandes e detalhados conjuntos de dados a serem tratados. O mapeamento de superfície com plataformas VANTs apresenta algumas vantagens em relação ao orbital e outros métodos de aquisição de sensoriamento aéreo. A menor interferência atmosférica, a possibilidade de voar em altitudes mais baixas e, principalmente, o baixo custo operacional tornaram esse sistema de aquisição popular tanto em explorações comerciais quanto científicas. No entanto, a inspeção visual de vários objetos ainda pode ser uma operação demorada, tendenciosa e imprecisa.

Atualmente, o verdadeiro desafio nas abordagens de IA no sensoriamento remoto na agricultura e meio ambiente é obter informações automáticas, rápidas e precisas desses tipos de dados. Nos últimos anos, o advento das técnicas de *deep learning* (DL) tem oferecido métodos robustos e inteligentes para aprimorar o mapeamento da superfície terrestre. DL é um método de rede neural artificial (ANN) com múltiplas camadas ocultas e combinações mais profundas que é responsável por otimizar e retornar melhores padrões de aprendizado do que uma ANN comum. Há uma quantidade impressionante de material de revisão nas revistas científicas explicando técnicas baseadas em DL, sua evolução histórica, uso geral, bem como redes e funções (Osco et al., 2021a). À medida que o processamento e os exemplos rotulados (ou se-

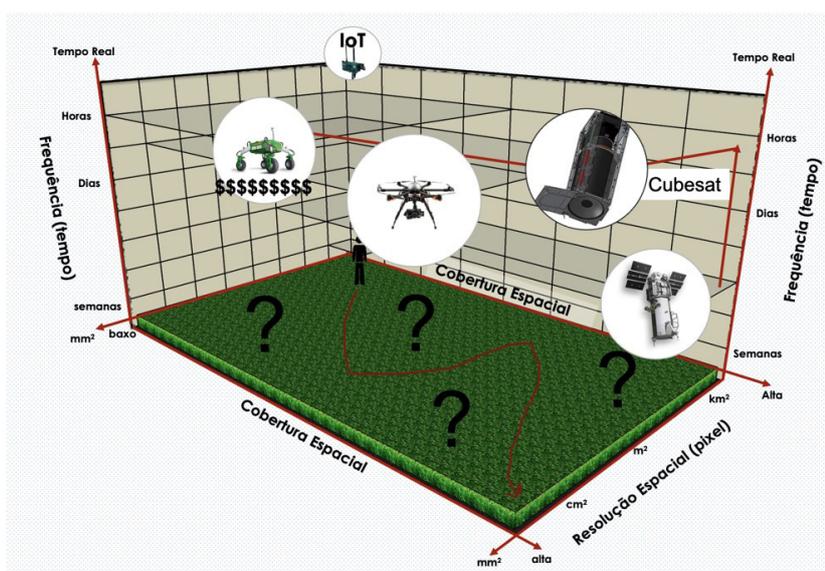


Figura 1. Diferentes escalas espaciais e temporais de fontes de dados utilizados pelos algoritmos de inteligência artificial aplicados na agricultura digital.

Fonte: Feito por Lúcio Jorge.

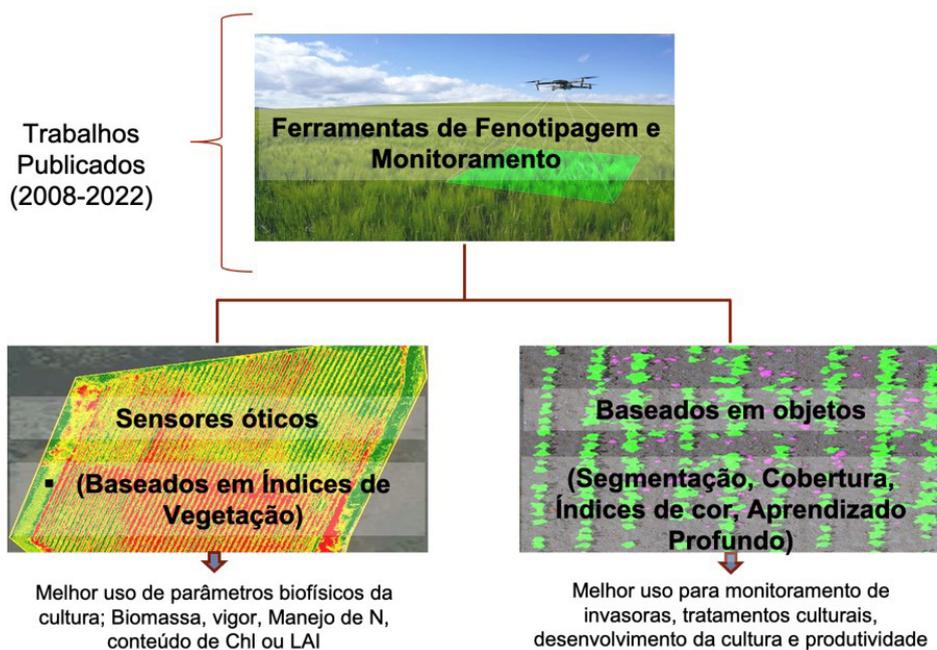


Figura 3. Principais aplicações da inteligência artificial no monitoramento agrícola e na fenotipagem (técnica de melhoramento genético de plantas).

Fonte: adaptado de Phelippe Vigneau.

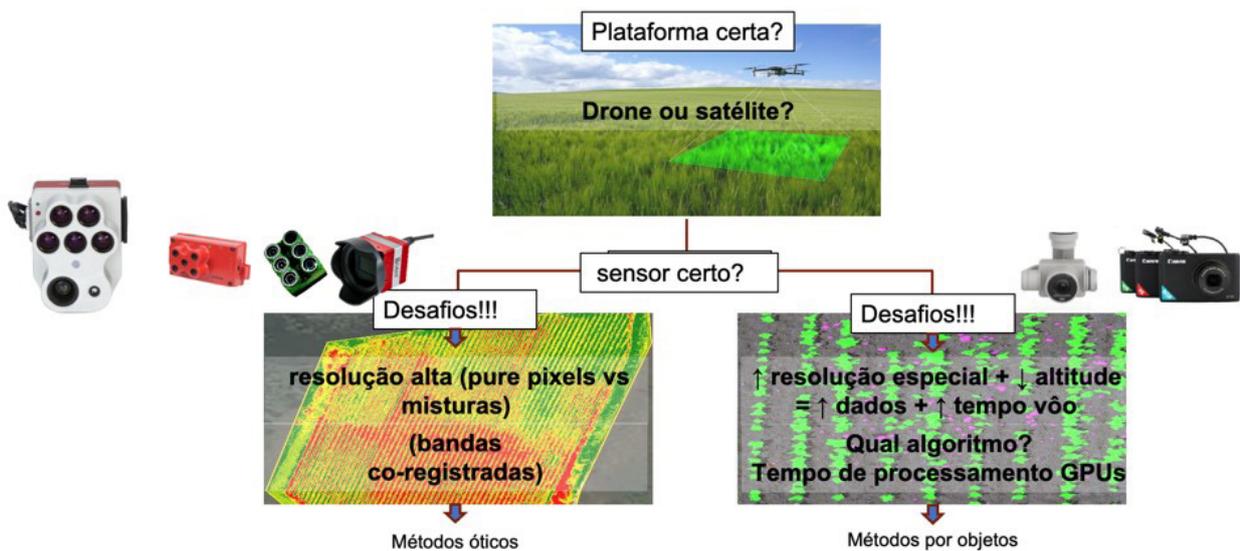


Figura 4. Dificuldades encontradas na obtenção dos dados para aplicação nos algoritmos de ML e DL.

Fonte: adaptado de Phelippe Vigneau.

2 APRENDIZADO PROFUNDO (DEEP LEARNING)

O interesse em algoritmos de DL vem crescendo desde meados de 2010, especificamente porque esses algoritmos alcançaram sucesso significativo em tarefas de processamento de imagens digitais (Ma et al., 2019; Khan et al., 2020).

As DNNs mais comuns (Osco et al., 2021a) são geralmente compostas por camadas densas, nas quais as funções de ativação calculam a soma ponderada

de entrada e *bias*, decidem se um neurônio pode ser ativado ou não. Essas funções constituem funções de decisão que auxiliam no aprendizado de padrões intrínsecos, ou seja, são um dos principais aspectos de como cada neurônio aprende a partir de sua interação com os outros neurônios. As funções de ativação comumente aplicadas podem ser lineares, sigmoidais, tangentes hiperbólicas, máximo, unidades lineares retificadas (ReLU) e variantes de ReLU, in-

cluindo ReLU com vazamento, unidade linear exponencial (ELU) e unidade linear retificada paramétrica (PReLU). Além da função de ativação, outra informação importante sobre o funcionamento de uma DNN está relacionada a suas camadas, como *dropout*, *batch-normalization*, *convolution*, *deconvolution*, *max-pooling*, *encode-decode*, *memory cells*, entre outras. As camadas de *dropout* são importantes para introduzir a regularização dentro da rede, pois ela escolhe aleatoriamente conexões e unidades com uma determinada probabilidade. Isso não apenas ajuda a reduzir o *overfitting*, removendo a presença de conexões coadaptadas, mas também melhora sua generalização e contribui para taxas de aprendizado otimizadas e mais rápidas. A camada de normalização do lote atua como um fator regulador e suaviza o fluxo do gradiente de perda, o que também melhora a generalização (Osco et al., 2021a).

A organização na qual essas e outras camadas são compostas bem como seus parâmetros definem a topologia da rede. Além da topologia, os métodos de otimização mais usados são Adam, algoritmo de Momentum, *Stochastic Gradient Descent* (SGD) e *Root Mean Squared Propagation* (RMSprop). Existem vários otimizadores e a escolha correta, de acordo com o modelo e seu objetivo, pode auxiliar na otimização das precisões. SGD é o método mais utilizado, nele os neurônios convergem e tendem em direção à função de custo ótimo. Momentum tenta resolver o problema de mínimo local adicionando um conceito temporal a ele. RMSprop, uma técnica de otimização baseada em gradiente, implementa uma média de decaimento exponencial dos gradientes, combinando o momento e outro algoritmo conhecido como *Adaptive Gradient Algorithm* (AdaGrad). Adam, por exemplo, é atualmente a opção mais usada, e sua popularidade se deve à sua capacidade de usar taxas de aprendizagem dinâmica e adaptativa (Osco et al., 2021a).

Os otimizadores combinados com a função de custo correta podem influenciar sua precisão. No contexto da otimização, a função definida para avaliar o modelo é conhecida como função de custo (também conhecida como função objetivo). Essa função representa a capacidade de o modelo representar os dados de treinamento em um único valor escalar. Com essa redução, o problema de aprendizado visa encontrar maneiras de ajustar os parâmetros do modelo para minimizar a função de custo. Isso permite que possíveis soluções sejam classificadas e depois comparadas entre as interações dos neurônios. As funções de custo são calculadas de acordo com probabilidades matemáticas e estão relacionadas à natureza do problema em si; ou seja, se a rede está lidando com um

problema de classificação ou regressão. Para resolver classificações, também conhecidas como probabilísticas, pode-se usar funções como entropia cruzada, Poisson, entre outras. Para problemas relacionados à regressão, as perdas com base no erro quadrático médio (MSE), erro absoluto médio (MAE), erro percentual médio absoluto (MAPE), erro logarítmico quadrado médio (MSLE) etc. são comumente implementadas.

Várias arquiteturas foram propostas nos últimos anos para melhorar e otimizar DNNs, implementando diferentes tipos de camadas, otimizadores, funções de custo, nível de profundidade etc. Novos métodos para melhorar a performance de cada DNN incluem métodos para aumento de dados, auto-supervisão e estratégias de aprendizado não supervisionado, entre outros (Khan et al., 2020).

3 REDES NEURAIS CONVOLUCIONAIS E RECORRENTES

Uma DNN pode ser formada por diferentes arquiteturas, e a complexidade do modelo está relacionada à forma como cada camada e método computacional adicional é implementado. Diferentes arquiteturas de DL são propostas regularmente como redes neurais convolucionais (CNN), redes neurais recorrentes (RNN), redes de crenças profundas (DBN) e, mais recentemente, redes adversárias generativas (GAN). No entanto, as DNNs mais comuns nas categorias de redes supervisionadas são geralmente classificadas como CNNs e RNNs (Osco et al., 2021a).

Para tarefas de processamento de imagens e reconhecimento de objetos, a maioria das pesquisas atuais está focada em arquiteturas de CNNs. As CNNs são bem conhecidas na visão computacional, mas nunca receberam tanta atenção quanto hoje.

As CNNs são um tipo de arquitetura que é composta principalmente por três estruturas hierárquicas distintas, como camadas de convolução, camadas de agrupamento e camadas totalmente conectadas e têm muitos parâmetros, como pesos, vieses, número de camadas e neurônios, tamanho do filtro, passos, função de ativação, taxa de aprendizado etc. (Osco et al., 2021a). Em cada camada, a imagem de entrada é envolvida com um conjunto de núcleos (ou seja, filtros) e vieses adicionados, gerando mapas de feição. A operação de convolução considera a vizinhança dos pixels de entrada, portanto, diferentes níveis de correlação podem ser explorados de acordo com o tamanho dos filtros. As CNNs foram originalmente projetadas para processar dados na forma de várias matrizes, e essa característica é particularmente adequada para lidar com imagens multibandas, uma vez que os pixels são organizados regularmente. Como resultado, es-

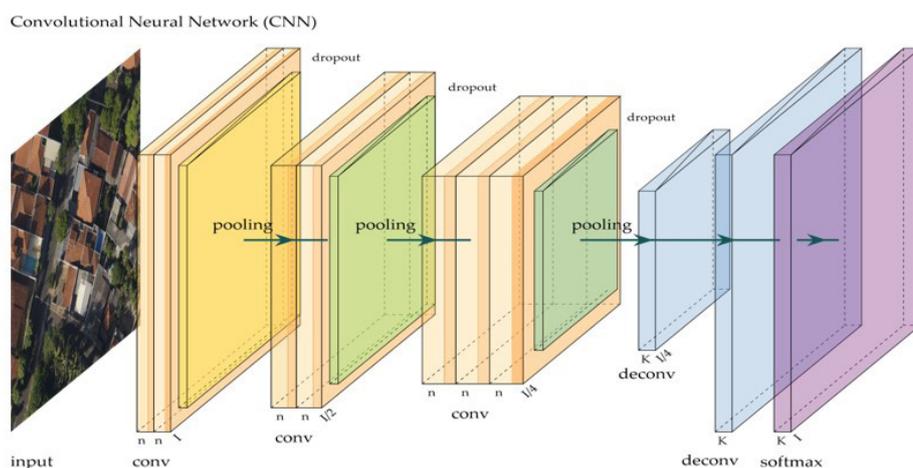


Figura 5. Uma CNN básica.
Fonte: Osco et al. (2021a).

sa arquitetura (Figura 5) está sendo considerada um dos modelos DNN mais populares hoje, e seu sucesso foi demonstrado em vários aplicativos de imagem baseados em VANTs (Osco et al., 2021a).

Como um tipo diferente de estrutura de rede de DL, as RNNs referem-se a outro modelo de aprendizagem supervisionada. Embora as RNNs tenham sido usadas por um tempo em outras tarefas de visão computacional, só mais tarde foi proposto para ser usado com imagens. O modelo RNN foi originalmente desenvolvido para lidar com a análise de sequências discretas. A ideia principal por trás da implementação de RNNs diz respeito à sua capacidade de melhorar sua aprendizagem em porções repetitivas de um determinado fenômeno ou objeto, muitas vezes associadas a uma coleção de séries temporais. Um tipo de RNN que está sendo implementado atualmente em várias tarefas é a memória de longo prazo (LSTM). As LSTMs são uma escolha interessante para previsões relacionadas a séries temporais, pois resolvem o problema do gradiente descendente produzido nas RNNs originais. Para isso, eles usam componentes aditivos adicionais, permitindo que os gradientes fluam através da rede de forma mais eficiente. Uma unidade LSTM é normalmente composta de uma célula, bem como por portas de entrada, saída e esquecimento. À medida que a célula “lembra” valores de intervalos de tempo arbitrários, essas três portas regulam o fluxo de informações dentro e fora da célula (Osco et al., 2021a).

Alguns exemplos com dados de sensoriamento remoto demonstrando o potencial em que as RNNs estão sendo usadas são descritos por Osco et al. (2021a). Outros tipos de redes neurais, além de CNNs e RNNs, estão sendo propostos para também lidar com um ti-

po de imagem de dados. As GANs estão entre os modelos de DL não supervisionados mais inovadores. As GANs são compostas por duas redes: generativas e discriminativas, que disputam entre si. A rede generativa é responsável por extrair características de uma determinada distribuição de dados de interesse, como imagens, e a rede discriminativa distingue entre verdade real.

Recentemente, abordagens no contexto do processamento de imagens como a classificação de imagens de sensoriamento remoto (Lin et al., 2017) e a solução de problemas de interpretação imagem a imagem adotaram GANs como modelos de DL, obtendo resultados bem-sucedidos.

Em suma, várias DNNs são constantemente desenvolvidas, em plataformas científicas e/ou de competição de imagens, para superar os métodos existentes. No entanto, a cada ano que passa, algumas dessas redes neurais são frequentemente mencionadas, lembradas ou até melhoradas por novas abordagens. Um resumo dos modelos conhecidos de DL encontrados nos últimos anos é apresentado por Osco et al. (2021a) e representado na Figura 6. Embora possa parecer que a maioria dos métodos de DL foram desenvolvidos de 2015 a 2017, é importante notar que algumas novas redes profundas usam a maioria dos métodos já desenvolvidos como espinhas dorsais, ou acompanhados de outros tipos de arquitetura, usados principalmente como parte de extração de recursos de uma estrutura muito mais complexa. Muitas vezes, essas abordagens podem ser agrupadas em tarefas de classificação, como classificação em termos da cena, detecção de objetos, segmentação semântica e de instância (em termos de pixel) e tarefas de regressão.

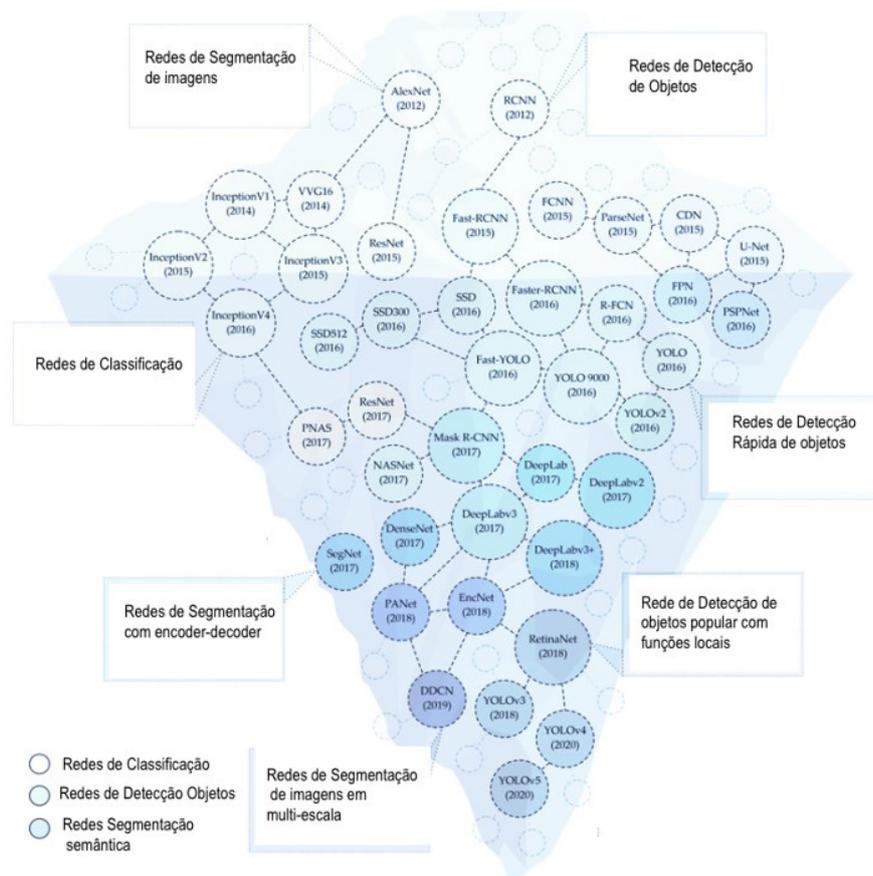


Figura 6. Uma série temporal de redes implementadas em DL indicando algumas arquiteturas populares na classificação de imagens, detecção de objetos e segmentação. **Fonte:** adaptada de Osco et al. (2021a).

A classificação em termos da cena envolve a atribuição de um rótulo de classe a cada imagem (ou patch), enquanto a tarefa de detecção de objetos visa desenhar caixas delimitadoras em torno de objetos em uma imagem (ou patch) e rotular cada um deles de acordo com o rótulo de classe. A detecção de pontos pode ser considerada uma tarefa mais desafiadora, uma vez que requer a localização dos objetos na imagem e, em seguida, executar sua classificação. Uma outra maneira de detectar objetos em uma imagem, em vez de desenhar caixas delimitadoras, é desenhar regiões ou estruturas ao redor do limite dos objetos, ou seja, distinguir a classe do objeto no nível de pixel. Essa tarefa é conhecida como segmentação semântica. No entanto, na segmentação semântica não é possível distinguir vários objetos da mesma categoria, pois cada pixel recebe um rótulo de classe. Para superar essa desvantagem, uma tarefa que combina segmentação semântica e detecção de objetos chamada segmentação foi proposta para detectar vários objetos em máscara de nível de pixel e rotulando cada máscara em um rótulo de classe (Osco et al., 2021a).

Para aplicações na agricultura de precisão, a estratégia de usar redes bem conhecidas é, em geral, adotada. Não apenas VGG-16 e ResNet-50, mas também outras redes, incluindo AlexNet e VGG-11 têm sido usadas.

4 DEEP LEARNING EM AGRICULTURA DE PRECISÃO E DIGITAL

Uma das principais arquiteturas baseadas em DL utilizadas em aplicações de imageamento na agricultura foi descrita por Ma et al. (2019) e por Osco et al. (2021a).

Várias práticas agrícolas e ambientais podem, potencialmente, se beneficiar do uso de redes profundas como CNNs e RNNs. Por exemplo, monitoramento e contagem de animais, detectando e classificando vegetação, como pastagens e áreas densamente florestadas, assim como monitorando áreas agricultáveis diferenciando culturas e manejos, como também reconhecendo sinais de fogo e fumaça, analisando o uso da terra, a cobertura da terra e as mudanças de terreno, que são frequentemente implementadas em mode-

los de planejamento e tomada de decisão ambientais, prevendo e medindo riscos ambientais (Osco et al., 2021a), entre outros.

Nos últimos anos, os métodos de inteligência artificial, especialmente aqueles baseados em *deep learning*, foram adaptados para processar imagens em áreas agrícolas a partir de diferentes resoluções espaço-espectrais com o objetivo de atender áreas de aplicação distintas (Castro et al., 2020; Ramos et al., 2022). Métodos baseados em aprendizado profundo são de última geração e bem conhecidos por sua capacidade de lidar com tarefas desafiadoras e variadas, envolvendo tarefas de reconhecimento em cena, detecção de objetos e segmentação semântica (Osco et al., 2021b). Osco et al. (2021b) propuseram um método para detectar simultaneamente plantas e linhas de cultura no campo agrícola usando conjuntos de dados de imagens VANT através de algoritmos de aprendizagem profunda, visando alimentar sistema para detecção e monitoramento de pragas e doenças por planta.

Uma das abordagens mais comuns relacionadas com as aplicações de detecção remota diz respeito ao uso do solo e cobertura do solo, podendo ajudar nas ferramentas de gestão da propriedade. O uso de imagens hiperespectrais (Park; Song, 2020) em uma combinação entre camadas convolucionais 2D e 3D foi desenvolvido para determinar a cobertura do solo e áreas de parcelas cultivadas.

O mapeamento e monitoramento florestal baseado em VANT também é uma abordagem que vem ganhando a atenção na silvicultura de precisão. As áreas florestais muitas vezes apresentam dificuldades para o monitoramento e a investigação precisos, uma vez que podem ser de difícil acesso e ser perigosas, até certo ponto. Nesse aspecto, imagens tiradas de sensores embarcados em VANT podem ser usadas para identificar uma única espécie-árvore em ambientes florestais e compor um inventário (Nezami et al., 2020). Detecção de árvore única e classificação de espécies por CNNs também foram realizadas por Ferreira et al. (2020) em três tipos de palmeiras consideradas importantes para população e comunidades nativas da floresta Amazônica, mapeando-as com esse tipo de abordagem. Outro exemplo (Hu et al., 2020) inclui a implementação de uma rede adversária generativa convolucional profunda (DCGAN) para discriminar árvores de pinus saudáveis em uma área de parque florestal densa. Outra investigação recente (Miyoshi et al., 2020) propôs um novo método DL para identificar espécies de árvore única em áreas altamente densas com imagens hiperespectrais a partir de VANT.

Um estudo recente (Zhang et al., 2020) propôs um método baseado na segmentação semântica e na classificação de cena das plantas em imagens baseadas em VANT. O método baseia-se em uma CNN que classifica plantas individuais aumentando a escala de imagem enquanto integra recursos aprendidos em pequenas escalas. Essa abordagem é uma importante aplicação de fusão de dados multiescala. Também relacionadas à identificação da vegetação, várias arquiteturas de CNNs foram investigadas por Osco et al. (2021a) para imagens de VANT.

As aplicações em agricultura de precisão foram muito beneficiadas pela integração entre imagens obtidas com VANTs e métodos DL. A maioria das questões relacionadas a essas abordagens envolve detecção de objetos e extração de recursos para contagem de plantas e detecção de linhas de plantação, reconhecimento de lacunas de plantação, segmentação de espécies de plantas e espécies invasoras como plantas daninhas, fenologia e detecção de fenótipos, entre muitos outros aspectos.

Essas aplicações oferecem inúmeras possibilidades para esse tipo de mapeamento, especialmente porque a maioria dessas tarefas é, ainda, conduzida manualmente, por inspeção visual humana. Como resultado, podem ajudar nas práticas de agricultura de precisão, devolvendo previsões com resultados rápidos, imparciais e precisos, fundamentando a tomada de decisões para o gerenciamento de sistemas agrícolas.

Independentemente disso, embora os métodos automáticos forneçam informações importantes nesse contexto, eles enfrentam grandes desafios. Alguns deles incluem semelhança entre a planta desejada e as plantas invasoras, plantas difíceis de detectar em ambientes de alta densidade (ou seja, apresentando pequeno espaçamento entre plantas e linhas), linhas de plantação que não seguem um caminho reto, segmentação de borda no mapeamento de copas com conflito entre sombra e iluminação e muitos outros.

Ainda assim, novas investigações visam alcançar uma capacidade mais generativa para essas redes ao lidar com tais problemas. Nesse sentido, abordagens que implementam métodos em mais de uma condição ou plantio estão sendo o foco principal de trabalhos recentes, com diferentes tipos de plantações, sensores, altitudes de voo, ângulos, divergências espaciais e espectrais, datas, estádios fenológicos etc.

Em Apolo-Apolo et al. (2020) foi apresentada a produtividade pela contagem de frutos com o método baseado em CNN. A contagem de frutos não é algo inteiramente novo em abordagens baseadas em DL, alguns trabalhos demonstraram a eficácia dos métodos de caixas envolventes. A detecção de característi-

cas pontuais, além de várias diferenças em casos de oclusão, tamanho da fruta e problemas de iluminação na imagem são tratados nos trabalhos. As redes profundas de hoje demonstram alto potencial na previsão de produtividade. Uma delas inclui a previsão de pastagem com apenas imagens RGB (Castro et al., 2020). Outro exemplo interessante em estimativas de produtividade de culturas é apresentado por Nevavuori et al. (2020), em cujo trabalho uma CNN-LSTM foi usada para prever o rendimento com uma abordagem espaço-multitemporal. Embora utilizadas com menor frequência do que as CNNs, arquiteturas LSTM começam a ser utilizadas nas abordagens de agricultura de precisão a partir de informações temporais dessas áreas.

Em Osco et al. (2021b), métodos de segmentação semântica foram aplicados em dados multiespectrais baseados em VANT para extrair áreas de dossel, possibilitando descobrir estrategicamente quais regiões espectrais eram mais apropriadas. Uma aplicação recente com dados baseados em VANT também foi proposta por Osco et al. (2020a), em cujo trabalho um modelo CNN é apresentado para contar e detectar simultaneamente plantas e linhas de plantio. Esse mo-

delo é baseado em uma extração de mapa de confiança e foi uma versão atualizada de pesquisas anteriores com contagem de árvores cítricas (Osco et al., 2020b).

Por fim, um campo ainda a ser explorado pela literatura é o de identificação e reconhecimento de pragas e doenças em plantas usando métodos baseados em DL. As abordagens mais recentes visavam identificar espécies invasoras. Dian Bah et al. (2018) avaliaram o desempenho de um método baseado em CNN para prever ervas daninhas nas linhas de plantio de diferentes culturas. A adaptação de domínio, na qual a rede extrai recursos de aprendizagem de novos dados não visualizados, é um dos modelos mais atuais (Li et al., 2020b). Quanto à detecção de doenças, um estudo (Kerkech et al., 2020) investigou o uso de segmentação de imagem para culturas de videira com imagens multiespectrais e foi capaz de separar sintomas visíveis (RGB), sintomas no NIR (infravermelho) e em uma interseção entre dados espectrais visíveis e infravermelhos. Outro exemplo interessante sobre a identificação de pragas com imagem de VANT foi apresentado por Tetila et al. (2020), que, considerando amostras de imagem de superpixel de várias espécies de pragas e usando filtros de ativação, reco-

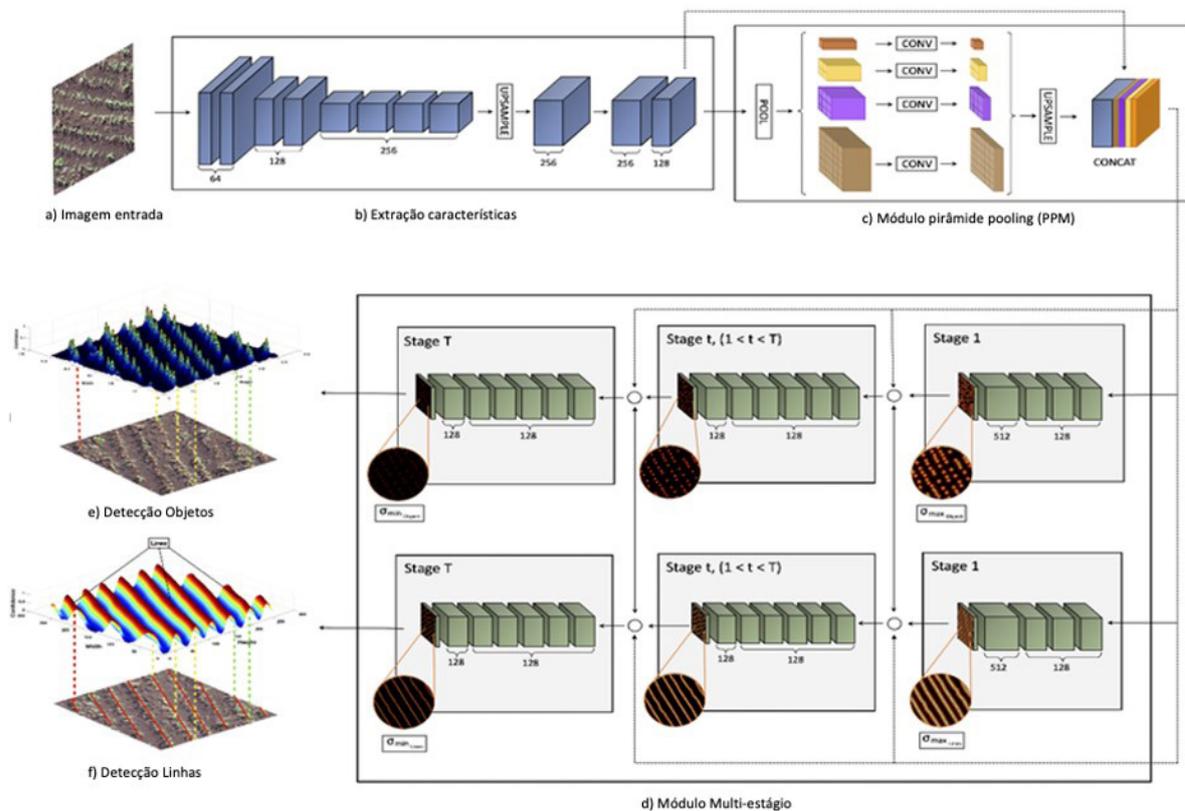
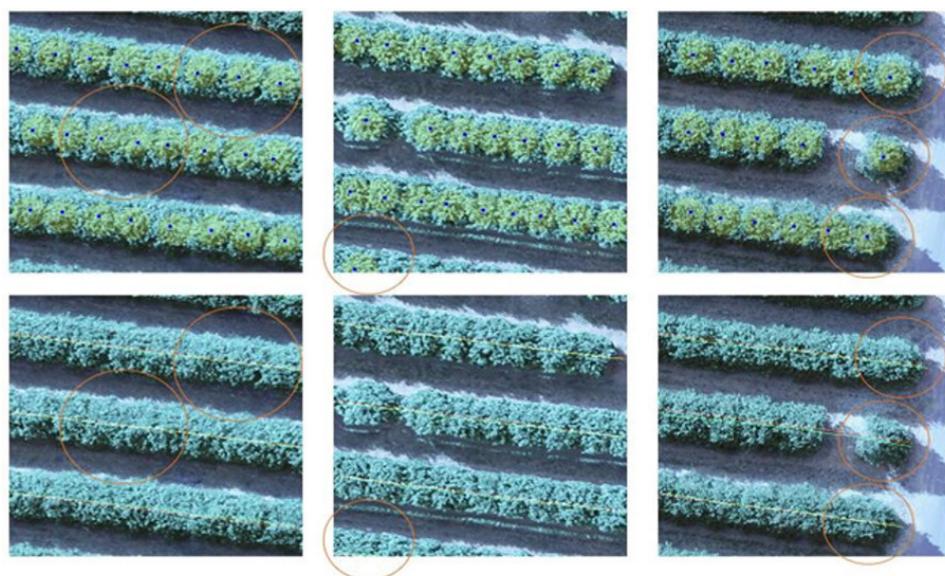


Figura 7. CNN proposta para detectar linhas de plantio e contar plantas: (a) imagem VANT de entrada; (b) o mapa de características obtido pela CNN; (c) o módulo de aprimoramento PPM com o mapa de características como uma entrada; (d) os dois ramos de detecção do MSM; (e) detecção de objetos (plantas); e (f) detecção de linhas (linhas de plantação).

Fonte: Osco et al. (2020a).



(a) Alta densidade

(b) Oclusão

(c) Planta única fim da linha

Figura 8. Exemplos de detecções de plantas e linhas de plantação no conjunto de dados de citros. As detecções de plantas e linhas de plantação são mostradas nas linhas superior e inferior da imagem, respectivamente. Os pontos azuis e os círculos amarelos representam uma previsão correta e as copas das árvores das plantas rotuladas. As linhas vermelha e verde representam as linhas de plantação anotadas e detectadas. Os círculos laranja destacam os desafios superados pela abordagem em cada cena.

Fonte: Osco et al. (2020a).



Figura 9. Contagem de plantas de citros com alta densidade.

Fonte: Osco et al. (2020a).

nheceram padrões visuais utilizando diferentes arquiteturas baseadas em DL.

Algumas aplicações podem ser visualizadas nas Figuras 7, 8 e 9. Na Figura 7 é apresentada a rede proposta por Osco et al. (2020a) para detectar linhas e plantas nas culturas agrícolas ao mesmo tempo. Um exemplo da detecção de linhas numa cultura de citros com alta densidade de plantas pode ser visto na Figura 8 e, na Figura 9, a detecção das plantas.

5 CONSIDERAÇÕES FINAIS

As técnicas de IA tem avançado muito, principalmente o uso de *deep learning*, em aplicações na agricultura de precisão e na agricultura digital com grande destaque nos últimos anos. A aplicação para a área de imagens e fusão de dados, principalmente em séries temporais, tem se tornado de grande importância para aplicações na agricultura de precisão. Por ser uma área relativamente nova, este capítulo faz uma revisão

geral de técnicas e as perspectivas de última geração do uso de DL na agricultura de precisão e digital, sendo destaque nos avanços principalmente valendo-se de imagens de drones ou VANTs. A maioria das técnicas é baseada em métodos de detecção de objetos e sensores na faixa do visível (RGB); no entanto, algumas aplicações, como na agricultura de precisão e relacionadas a florestas, se beneficiam de dados multi/hiperespectrais e aparecem como promessas futuras. Embora as CNNs sejam as arquiteturas mais adotadas, outros métodos baseados em CNN-LSTMs e GANs estão ganhando atenção em aplicações de sensoria-mento remoto e imagem na agricultura de precisão. As técnicas de DL estão em grande evolução e a cada dia aparecem novas propostas que se beneficiam do uso de GPUs e clusters de processamento e apresen-tam como grande tendência para processamento em tempo real usando sistemas embarcados em VANTs, robôs ou máquinas agrícolas.

REFERÊNCIAS

- APOLO-APOLO, O. E.; MART 'INEZ-GUANTER, J.; EGEEA, G.; RAJA, P.; P 'EREZ-RUIZ, M. Deep learning techniques for estimation of the yield and size of citrus fruits using a UAV. **European Journal of Agronomy**, v. 115, p. 126030, 2020. DOI: <http://doi.org/10.1016/j.eja.2020.126030>.
- BISHOP, C. M. **Pattern recognition and machine learning**. Singapore: Springer Science+Business Media, 2006.
- CASTRO, W.; JUNIOR, J. M.; POLIDORO, C.; OSCO, L. P.; GONÇALVES, W.; RODRIGUES, L.; SANTOS, M.; JANK, L.; BARRIOS, S.; VALLE, C.; SIMEÃO, R.; CARROMEU, C.; SILVEIRA, E.; JORGE, L. A. D. C.; MATSUBARA, E. Deep learning applied to phenotyping of biomass in forages with uav-based rgb imagery. **Sensors**, v. 20, n. 17, p. 1-18, 2020. DOI: <http://doi.org/10.3390/s20174802>.
- DIAN BAH, M.; HAFIANE, A.; CANALS, R. Deep learning with unsupervised data labeling for weed detection in line crops in UAV images. **Remote Sensing**, v. 10, n. 11, p. 1-22, 2018. DOI: <http://doi.org/10.3390/rs10111690>.
- FERREIRA, M. P.; ALMEIDA, D. R. A.; PAPA, D. D. A.; MINERVINO, J. B. S.; VERAS, H. F. P.; FORMIGHIERI, A.; SANTOS, C. A. N.; FERREIRA, M. A. D.; FIGUEIREDO, E. O.; FERREIRA, E. J. L. Individual tree detection and species classification of Amazonian palms using UAV images and deep learning. **Forest Ecology and Management**, v. 475, p. 118397, 2020. DOI: <http://doi.org/10.1016/j.foreco.2020.118397>.
- HU, G.; YIN, C.; WAN, M.; ZHANG, Y.; FANG, Y. Recognition of diseased Pinus trees in UAV images using deep learning and AdaBoost classifier. **Biosystems Engineering**, v. 194, p. 138-151, 2020. DOI: <http://doi.org/10.1016/j.biosystemseng.2020.03.021>.
- KERKECH, M.; HAFIANE, A.; CANALS, R. Vine disease detection in UAV multispectral images using optimized image registration and deep learning segmentation approach. **Computers and Electronics in Agriculture**, v. 174, p. 105446, 2020. DOI: <http://doi.org/10.1016/j.compag.2020.105446>.
- KHAN, A.; SOHAIL, A.; ZAHOORA, U.; QURESHI, A. S. 2020. A survey of the recent architectures of deep convolutional neural networks. **Artificial Intelligence Review**, v. 53, p. 5455-5516. DOI: <https://doi.org/10.1007/s10462-020-09825-6>.
- LI, Y.; CAO, Z.; LU, H.; XU, W. Unsupervised domain adaptation for in-field cotton boll status identification. **Computers and Electronics in Agriculture**, v. 178, p. 105745, 2020b. DOI: <http://doi.org/10.1016/j.compag.2020.105745>.
- LIN, D.; FU, K.; WANG, Y.; XU, G.; SUN, X. Marta gans: Unsupervised representation learning for remote sensing image classification. **IEEE Geoscience and Remote Sensing Letters**, v. 14, n. 11, p. 2092-2096, 2017. DOI: <http://doi.org/10.1109/LGRS.2017.2752750>.
- MA, L.; LIU, Y.; ZHANG, X.; YE, Y.; YIN, G. Deep learning in remote sensing applications: a meta-analysis and review. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 152, p. 166-177, 2019. DOI: <http://doi.org/10.1016/j.isprsjprs.2019.04.015>.
- MİYOSHI, G. T.; ARRUDA, M. D. S.; OSCO, L. P.; MARCATO JUNIOR, J.; GONÇALVES, D. N.; IMAI, N. N.; TOMMASELLI, A. M. G.; HONKAVAARA, E.; GONÇALVES, W. N. A novel deep learning method to identify single tree species in uavbased hyperspectral images. **Remote Sensing**, v. 12, n. 8, p. 1294, 2020. DOI: <http://doi.org/10.3390/rs12081294>.
- NEVAVUORI, P.; NARRA, N.; LINNA, P.; LIPPING, T. Crop yield prediction using multitemporal UAV data and spatio-temporal deep learning models. **Remote Sensing**, v. 12, n. 23, p. 1-18, 2020. DOI: <http://doi.org/10.3390/rs12234000>.
- NEZAMI, S.; KHORAMSHAHI, E.; NEVALAINEN, O.; POLONEN, I.; HONKAVAARA, E. Ree species classification of drone hyperspectral and rgb imagery with deep learning convolutional neural networks. **Remote Sensing**, v. 12, n. 7, p. 1070, 2020. DOI: <http://doi.org/10.3390/rs12071070>.
- OSCO, L. P.; ARRUDA, M. S.; GONÇALVES, D. N.; DIAS, A.; BATISTOTI, J.; SOUZA, M.; GOMES, F. D. G.; RAMOS, A. P. M.; JORGE, L. A. C.; LIESENBERG, V.; LI, J.; MA, L.; JUNIOR, J. M.; GONÇALVES, W. N. A CNN approach to simultaneously count plants and detect plantation-rows from UAV imagery. **arXiv**, v. 2012.15827v3, p. 1-27, 2020a. DOI: <https://doi.org/10.48550/arXiv.2012.15827>.
- OSCO, L. P.; ARRUDA, M. D. S.; MARCATO JUNIOR, J.; SILVA, N. B.; RAMOS, A. P. M.; MORYIA, E. A. S.; IMAI, N. N.; PEREIRA, D. R.; CRESTE, J. E.; MATSUBARA, E. T.; LI, J.; GONÇALVES, W. N. A convolutional neural network approach for counting and geolocating citrus-trees in UAV multispectral imagery. **ISPRS Journal of Photogrammetry**

- and Remote Sensing**, v. 160, p. 97-106, 2020b. DOI: <http://doi.org/10.1016/j.isprsjprs.2019.12.010>.
- OSCO, L. P.; MARCATO JUNIOR, J.; RAMOS, A. P. M.; JORGE, L. A. C.; SILVA, J. A.; MATSUBARA, E. T.; PISTORI, H.; GONCALVES, W. N.; LI, J. A review on deep learning in UAV remote sensing. **International Journal of Applied Earth Observation and Geoinformation**, v. 102, p. 102456, 2021a. DOI: <http://doi.org/10.1016/j.jag.2021.102456>.
- OSCO, L. P.; NOGUEIRA, K.; RAMOS, A. P. M.; PINHEIRO, M. M. F.; FURUYA, D. E. G.; GONÇALVES, W. N.; JORGE, L. A. C.; MARCATO JUNIOR, J.; SANTOS, J. A. Semantic segmentation of citrus-orchard using deep neural networks and multispectral uav-based imagery. **Precision Agriculture**, v. 22, n. 4, p. 1171-1188, 2021b. DOI: <http://doi.org/10.1007/s11119-020-09777-5>.
- PARK, S.; SONG, A. Discrepancy analysis for detecting candidate parcels requiring update of land category in cadastral map using hyperspectral uav images: a case study in jeonju, south korea. **Remote Sensing (Basel)**, v. 12, n. 3, p. 354, 2020. DOI: <http://doi.org/10.3390/rs12030354>.
- RAMOS, A. M. M.; GOMES, F. D. G.; PINHEIRO, M. M. F.; FURUYA, D. E. G.; GONÇALVEZ, W. N.; MARCATO JUNIOR, J.; MICHEREFF, M. F. F.; BLASSIOLI-MORAES, M. C.; BORGES, M.; LAUMANN, R. A.; LIESENBERG, V.; JORGE, L. A. C.; OSCO, L. P. Detecting the attack of the fall armyworm (*Spodoptera frugiperda*) in cotton plants with machine learning and spectral measurements. **Precision Agriculture**, v. 23, p. 470-491, 2022. DOI: <http://doi.org/10.1007/s11119-021-09845-4>.
- RUSSEL, S.; NORVIG, P. **Artificial intelligence: a modern approach**. 4th ed. New Jersey: Prentice Hall, 2020.
- TETILA, E. C.; MACHADO, B. B.; MENEZES, G. K.; OLIVEIRA, A. S.; ALVAREZ, M.; AMORIM, W. P.; BELETE, N. A. S.; SILVA, G. G.; PISTORI, H. Automatic recognition of soybean leaf diseases using UAV images and deep convolutional neural networks. **IEEE Geoscience and Remote Sensing Letters**, v. 17, n. 5, p. 903-907, 2020. DOI: <http://doi.org/10.1109/LGRS.2019.2932385>.
- ZHANG, C.; ATKINSON, P. M.; GEORGE, C.; WEN, Z.; DIAZGRANADOS, M.; GERARD, F. Identifying and mapping individual plants in a highly diverse high-elevation ecosystem using UAV imagery and deep learning. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 169, p. 280-291, 2020. DOI: <http://doi.org/10.1016/j.isprsjprs.2020.09.025>.