

# Drones e Inteligência Artificial para o monitoramento de gado

## *Drones and Artificial Intelligence for cattle monitoring*

Jayme Garcia Arnal Barbedo<sup>1</sup>

<sup>1</sup> Pesquisador, Embrapa Agricultura Digital, Campin=as (SP), Brasil, [jayme.barbedo@embrapa.br](mailto:jayme.barbedo@embrapa.br).

### RESUMO

Veículos Aéreos Não Tripulados (VANTs), também conhecidos como Sistemas Aéreos Não Tripulados (SANTs) ou simplesmente drones, vêm sendo usados há décadas. Porém, só recentemente os padrões de segurança e operação alcançaram um nível que permita seu uso em uma classe mais ampla de aplicações. Ao mesmo tempo, tecnologias de imageamento digital vêm evoluindo continuamente, de modo que agora é possível capturar imagens de alta qualidade com uma boa relação custo-benefício. A área de inteligência artificial também experimentou uma revolução com o desenvolvimento de uma classe de modelos, chamada de aprendizado profundo, capaz de extrair a informação contida nas imagens a fim de resolver uma variedade de problemas de classificação. Como resultado, o interesse pelo uso de drones para monitoramento, rastreamento e detecção de diferentes tipos de objetos cresceu rapidamente ao longo da última década. Essa tendência se manifestou de maneira particularmente intensa na agricultura, sendo que o monitoramento animal se encontra entre as aplicações que mais podem se beneficiar desse tipo de tecnologia.

A operação de VANTs vem se tornando cada vez mais simples, especialmente no caso de aeronaves de asa rotativa (“cópteros”), e a maioria dos drones consegue realizar as missões de maneira autônoma. Porém, há muitos aspectos que, se ignorados, podem levar a resultados subótimos, tanto em termos de operação quanto de coleta e processamento de dados. Este capítulo tem como objetivo fornecer informações básicas sobre a operação dos drones, bem como descrever o processo de treinamento e uso de modelos de inteligência artificial aplicados a problemas de monitoramento de animais.

**Palavras-chave:** drone; VANT; imagens digitais; inteligência artificial; aprendizado profundo.

### ABSTRACT

Unmanned Aerial Vehicles (UAV), also known as Unmanned Aerial Systems (UAS) or simply drones, have been used for decades. However, only recently the safety and operation standards have reached a point that allows them to be used in a wider range of applications. At the same time, technologies for digital imaging are constantly evolving, so now it is possible to capture high quality images with a good cost-benefit ratio. The artificial intelligence field has also experienced a revolution with the development of a class of models, called deep learning, capable of extracting information from images in order to solve a variety of classification problems. As a result, the interest for drones for monitoring, tracking and detecting different types of objects has grown sharply over the last decade. This trend has manifested itself particularly intense in agriculture, with animal monitoring being among the applications that could benefit most from this type of technology.

Operating UAVs is becoming increasingly simple, especially in the case of rotary-wing aircraft (“copters”), and most drones can carry out flight missions autonomously. However, there are many aspects that, if ignored, can lead to suboptimal results, both in terms of operation and data collection and processing. This chapter aims at providing basic information on the operation of drones, as well as describing the training process and using artificial intelligence models applied to animal monitoring problems.

**Keywords:** drone; UAV; digital images; artificial intelligence; deep learning.

<https://doi.org/10.4322/978-65-86819-38-0.1000057>

 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.

## 1 INTRODUÇÃO

O monitoramento de gado é parte essencial da gestão das propriedades. Porém, esta tarefa não é trivial, especialmente em grandes propriedades adotando pecuária extensiva, algo comum em países como o Brasil. Nesse contexto, levantamentos aéreos surgem como uma opção viável. Imagens de satélite ainda não oferecem resolução espacial suficiente para identificação de animais individuais e a cobertura de nuvens ainda é um problema. O uso de aeronaves tripuladas, apesar de tecnicamente viável, possui várias desvantagens, como custo de operação, altos níveis de ruído capazes de perturbar os animais, possibilidade da ocorrência de acidentes fatais, além de que nem sempre é possível instalar os sensores de maneira apropriada. Dadas as limitações associadas a satélites e aeronaves tripuladas, o uso de drones aparece como uma opção mais vantajosa para o monitoramento de animais (Zhang; Kovacs, 2012).

Este capítulo está dividido em nove partes, além da introdução: 1) diferentes tipos de drones e suas características; 2) sensores que podem ser embarcados em drones; 3) legislação e regulamentos aplicados ao uso de drones; 4) operação prática dos drones; 5) técnicas de inteligência artificial; 6) captura e preparação das imagens; 7) treinamento dos modelos de inteligência artificial; 8) seleção dos modelos de inteligência artificial, e 9) considerações finais.

## 2 TIPOS DE DRONES

O tamanho dos drones pode variar de alguns poucos gramas, como o AV Nano Hummingbird, até centenas de quilogramas, como o NASA Ikhana, e a carga que eles são capazes de carregar normalmente é proporcional a seu peso. Para aplicações agrícolas, tamanhos intermediários normalmente oferecem o melhor custo-benefício, mas, em última análise, a melhor opção dependerá dos sensores necessários para a aplicação pretendida e do orçamento disponível (Barbedo; Koenigkan, 2018). Apesar de sua menor autonomia, drones elétricos são normalmente preferidos por serem mais práticos, silenciosos e estáveis que aeronaves usando combustíveis fósseis (Linchant et al., 2015).

Drones de asa rotativa (Figura 1) são pequenas aeronaves do tipo helicóptero contendo entre quatro e oito conjuntos de lâminas rotativas, arranjadas ao redor do centro da aeronave ou em dois braços opostos (Anderson; Gaston, 2013). Este tipo de drone tem como vantagens a capacidade de pairar sobre alvos fixos, conseguem ficar no ar mesmo quando um dos rotores perde potência, são pouco sujeitos a vibração, são mais fáceis de operar e tendem a ser mais bar-

tos que aeronaves de asa fixa. Por outro lado, são relativamente lentos, o limite de carga normalmente é baixo, cobrem áreas relativamente pequenas em cada voo (Anderson; Gaston, 2013) e são instáveis com ventos acima de 25 km/h (Miller et al., 2017).

Drones de asa fixa (Figura 2) são aeronaves do tipo avião. Este tipo de VANT normalmente é lançado manualmente e pousa de barriga, de modo a minimizar os componentes necessários para lançamento e resgate (Linchant et al., 2015). Em comparação com drones de asa rotativa, tendem a ser mais rápidos, usam menos energia, operam melhor sob condições de vento forte, podem cobrir áreas maiores por voo e, normalmente, são capazes de carregar pesos maiores (Miller et al., 2017). Por outro lado, drones de asa fixa tendem a ser mais caros, são mais difíceis de operar e menos manobráveis, e as imagens tendem a exibir efeitos de borrão um pouco mais intensos, devido tanto ao movimento da aeronave quanto às vibrações associadas à sua operação.

Drones de asa rotativa e asa fixa são os mais utilizados, porém há alguns sistemas alternativos que se adaptam bem a algumas aplicações específicas. Duas dessas aeronaves alternativas podem ser apropriadas



Figura 1. Drone de asa rotativa. Fonte: unsplash.com. Autor: Aditya Chinchure.



Figura 2. Drone de asa fixa. Fonte: sensefly.com.

para uso no monitoramento de animais. Sistemas híbridos possuem características tanto de aeronaves de asa rotativa quanto de asa fixa. O quadricóptero híbrido, por exemplo, usa múltiplos rotores para decolar e pousar verticalmente, porém possui também asas fixas para poder voar distâncias mais longas (Vergouw et al., 2016). Drones do tipo dirigível (balão) podem ficar no ar por várias horas e podem levar até algumas centenas de quilogramas de carga, porém ainda há alguns desafios técnicos relacionados à sua operação prática que precisam ser superados. Outras opções menos comuns incluem drones equipados com motores a jato e ornitópteros.

### 3 SENSORES EMBARCADOS EM DRONES

A maioria dos drones vem equipada de fábrica com uma câmera RGB (red-green-blue) convencional (Figura 3). Porém, em princípio, qualquer tipo de sensor pode ser instalado, desde que os limites de carga sejam observados e a operação normal do drone não seja prejudicada. Vários sensores vêm sendo usados na prática, incluindo câmeras RGB, multiespectrais, hiperespectrais e termográficas, as quais são brevemente descritas a seguir. Uma descrição mais completa desses sensores pode ser encontrada em Barbedo e Koenigkan (2018).

Câmeras RGB capturam imagens usando três componentes do espectro visível (vermelho, verde e azul). Esses sensores tendem a ser baratos em comparação com outros tipos de câmeras, e as imagens produzidas fornecem uma boa aproximação da maneira como seres humanos perceberiam a cena com seus olhos.

Câmeras multiespectrais capturam imagens em comprimentos de onda específicos (entre quatro e dez bandas), cujas bandas normalmente estão localizadas na região do espectro visível e do infravermelho



Figura 3. Exemplo de imagem RGB.  
Fonte: Luciano Vieira Koenigkan.

lho próximo, embora bandas termográficas também sejam capturadas em alguns casos. Alguns atributos dos objetos de interesse podem ser mais proeminentes em certos comprimentos de onda, fato este que pode ser explorado para melhorar o processo de detecção. Além disso, diferentes bandas podem ser combinadas de modo a revelar informações relevantes, como, por exemplo, os índices de vegetação. Sensores multiespectrais podem ser usados para identificar e contar animais, uma vez que diferentes espécies podem ter diferentes assinaturas espectrais (Terletzky et al., 2012). Estes sensores tendem a ter resolução espacial menor que sensores RGB.

Como no caso de sensores multiespectrais, câmeras hiperespectrais capturam imagens em comprimentos de onda específicos, mas, neste caso, com uma resolução espectral muito mais alta, proporcionada por centenas de bandas. Este tipo de sensor ainda é caro e a resolução espectral fornecida não é necessária para detecção e contagem de animais. Porém, câmeras hiperespectrais podem ser úteis na detecção de atributos mais sutis, como raça e presença de doenças.

Câmeras termográficas detectam diferenças de temperatura usando a banda infravermelha de comprimento de onda longo (Figura 4). Estas podem ser utilizadas para detectar gado (Longmore et al., 2017) e animais selvagens (Miller et al., 2017; Wiczuk et al., 2017), levando em conta o fato de que animais tendem a ter temperaturas corporais mais altas que seu entorno. Câmeras termográficas têm a vantagem de poderem ser utilizadas à noite (Linchant et al., 2015), porém possuem resolução espacial menor que outros tipos de sensores (Chabot; Bird, 2015).

### 4 LEGISLAÇÃO E REGULAMENTOS NO USO DE DRONES

As operações com drones são governadas por regulamentos que podem diferir entre diferentes países e que frequentemente mudam à medida que a tecnologia evolui e novos usos são vislumbrados. Nesse contexto, manter-se atualizado pode ser um desafio. As informações a seguir estavam atualizadas no momento em que este capítulo foi publicado, mas é sempre aconselhável buscar as informações oficiais mais recentes sobre o assunto.

Regras estritas ainda estão presentes em muitos países e devem sempre ser levadas em consideração antes de qualquer voo. As motivações por trás dessas restrições incluem garantir a segurança das pessoas e evitar o uso inadequado dos drones (Watts et al., 2012). À medida que a tecnologia evolui e o uso dos drones é mais bem entendido, as regras tendem a alcançar um melhor equilíbrio entre segurança e viabi-

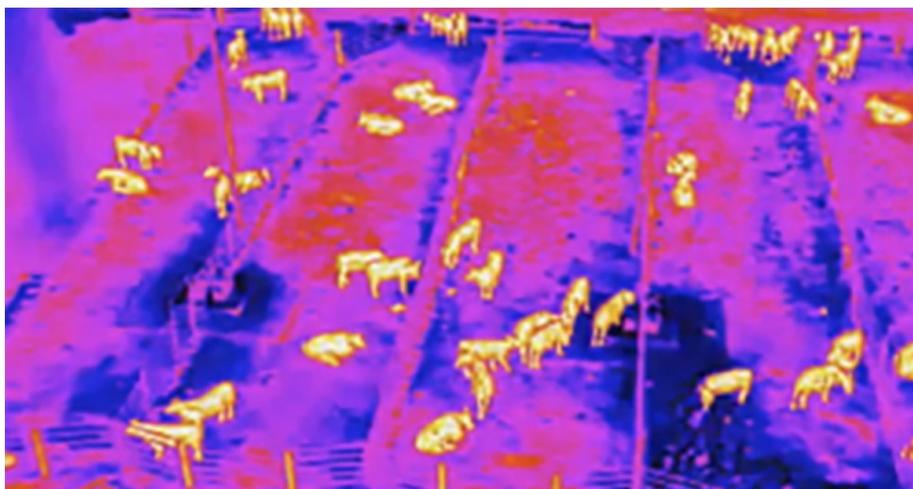


Figura 4. Exemplo de imagem termográfica. Fonte: Texas A&M AgriLife.

lização do uso prático. Um resumo das principais regras vigentes no Brasil, em 2022, é apresentado abaixo.

O uso de drones no Brasil é regulado pela Agência Nacional de Aviação Civil (ANAC). As principais regras vigentes são as seguintes (Agência Nacional de Aviação Civil, 2022): uma licença de pilotagem é necessária para operar aeronaves acima de 25 kg; os drones precisam manter uma distância de ao menos 30 m (horizontalmente) de qualquer pessoa, a menos que haja autorização em contrário; uma autorização especial é necessária para voos acima de 120 m de altitude ou em casos em que a aeronave sairá da linha de visão dos operadores em algum momento; voos completamente autônomos em que não haja possibilidade de intervenção imediata dos operadores são completamente vedados. Mais detalhes podem ser encontrados no *website* da ANAC.

Dentre as regras mencionadas, a necessidade de se manter permanente contato visual com o drone é provavelmente a que tem maior impacto no monitoramento de animais. Considerando-se que muitas propriedades são extensas, levantamentos amplos podem se tornar inviáveis por esta restrição. Apesar de exceções a esta regra poderem ser autorizadas, o processo pode ser complexo e demorado. É interessante notar que essa é uma situação que ocorre na maioria dos países (Chrétien et al., 2016; Colefax et al., 2017; Watts et al., 2012).

## 5 OPERAÇÃO DOS DRONES

Cada modelo de drone tem associado ao menos um *software* ou aplicativo para ajudar com o planejamento de rota e navegação da aeronave. Apesar de essas ferramentas serem projetadas para serem simples e intuitivas, há uma curva de aprendizado que requer

tempo e dedicação para ser completada, especialmente no caso de aeronaves maiores e mais complexas. É importante dedicar tempo suficiente para aprender a utilizar essas ferramentas e a operar o drone de maneira apropriada a fim de evitar problemas. A gestão dos dados também é importante, mas a maior parte dos passos é automatizada e não requer muita atenção.

Ferramentas dedicadas ao planejamento dos voos permitem que os usuários configurem diversos parâmetros. Primeiro, é necessário localizar no mapa os pontos-âncora a serem usados pelo drone durante o voo. A ordem na qual os pontos devem ser percorridos também deve ser configurada, de modo a caracterizar adequadamente a rota a ser seguida pelo drone. A altitude de voo em relação ao solo deve também ser definida. A altitude deve ser definida de acordo com as necessidades de cada aplicação específica, desde que observados os limites legais e levando-se em consideração obstáculos capazes de causar acidentes. É importante notar que, em geral, o drone mantém sua altitude em relação ao ponto de origem, de modo que, em terrenos acidentados, a altitude em relação ao solo pode variar consideravelmente, a menos que correções sejam aplicadas. A velocidade da aeronave deve ser configurada levando-se em consideração as características do sensor utilizado e a altitude adotada, a fim de evitar imagens excessivamente borradas.

Diferentes aplicações podem ter diferentes requerimentos em relação à iluminação. Por exemplo, se sombras devem ser evitadas, os voos devem ser realizados próximos ao meio dia ou em dias nublados. Além disso, se as características ou comportamentos dos objetos a serem imageados mudam durante o dia, este fato deve ser levado em consideração no momento de escolher o horário mais apropriado para os voos. Outras aplicações podem requerer que os voos sejam

realizados em diferentes momentos do dia, a fim de caracterizar adequadamente a área e os objetos a serem analisados. Voos noturnos também são uma opção, especialmente com câmeras termográficas, mas em alguns locais esse tipo de voo pode necessitar de autorização específica.

A maioria dos drones vem equipada com câmeras que podem capturar vídeos ou imagens em intervalos que podem ser definidos pelo usuário. Porém, se outras câmeras vão ser utilizadas, mecanismos dedicados para a captura das imagens podem ser necessários. É sempre recomendável que se realizem alguns voos de teste curtos para determinar se o sistema está operando de maneira adequada, especialmente quanto uma determinada configuração está sendo utilizada pela primeira vez.

Um fator muito importante a ser considerado no planejamento das missões de imageamento é a duração das baterias e o tempo de recarga. As baterias de um drone típico permitem voos que podem variar de alguns poucos minutos até uma hora. Os tempos de recarga geralmente são mais longos; então, se múltiplos voos estão previstos, é aconselhável que se levem algumas baterias carregadas de reserva a fim de evitar longas esperas entre os voos. O número ideal de baterias depende do drone, do número de voos e da área a ser coberta.

Após a missão ser planejada e os pontos-âncora serem preenchidos na aplicação de navegação, a maior parte da operação do drone é realizada de maneira autônoma. Porém, há alguns aspectos que requerem atenção. Primeiro, é importante considerar as diferenças na operação de drones de asa rotativa e asa fixa, especialmente em relação à decolagem e ao pouso. Drones de asa rotativa decolam e pousam sem a necessidade de intervenção humana, a menos que o ambiente e as condições climáticas estejam muito desfavoráveis à operação autônoma. Em qualquer caso, é sempre recomendável seguir todo o voo visualmente a fim de que se possa intervir rapidamente no caso de ocorrer algum problema. Isso é especialmente importante durante o pouso, porque as condições podem mudar rapidamente tanto no solo quanto no ar.

Drones de asa fixa são tipicamente lançados manualmente e pousam sobre suas barrigas. O procedimento de lançamento requer prática e as condições de vento podem ter forte interferência sobre o processo. O pouso deve ser sempre realizado em local sem obstruções e em superfície relativamente macia, a fim de evitar dano à aeronave e aos sensores.

Drones modernos vêm equipados com um conjunto de sensores anticolisão capaz de evitar a maioria dos acidentes. Mesmo com essas salvaguardas, acidentes

podem acontecer. Fatores de risco capazes de aumentar a ocorrência de acidentes podem ser identificados e mitigados antes dos voos. Áreas com árvores altas, por exemplo, devem ser analisadas com cuidado a fim de garantir que o drone voe confortavelmente acima das copas mais altas. Além disso, a altitude de voo é determinada em relação ao ponto de decolagem; então, se o voo começa em um local que é significativamente mais baixo que outras áreas a serem cobertas, a altitude inicial pode não ser suficiente para evitar obstáculos localizados em partes mais altas, de modo que correções devem ser aplicadas.

## 6 TÉCNICAS DE INTELIGÊNCIA ARTIFICIAL

Técnicas de aprendizado de máquina e inteligência artificial (IA) vêm sendo utilizadas há décadas. Essas técnicas têm sido empregadas em todas as áreas de conhecimento, com diferentes graus de sucesso. Dentre estas, redes neurais provavelmente experimentaram as maiores expectativas e também as maiores decepções. Na primeira metade da década de 1990, redes neurais eram vistas como potenciais soluções para quase todos os problemas relacionados a dados. Essas expectativas se mostraram irrealistas e, apesar de redes neurais continuarem a serem aplicadas a diferentes problemas, muitos começaram a duvidar do potencial deste tipo de técnica. Porém, o desenvolvimento de uma nova família de redes neurais contendo um grande número de camadas dedicadas a tarefas específicas mudou essa visão de maneira radical. O surgimento das técnicas de aprendizado profundo nos primeiros anos da década de 2010 trouxe as redes neurais de volta aos holofotes, mas, neste caso, a maior parte da promessa inicial foi alcançada, especialmente quando dados de boa qualidade estavam disponíveis. Este tipo de técnica tem sido particularmente bem sucedido na análise e classificação de imagens, fato este que pode ser em parte atribuído à impressionante evolução experimentada por câmeras e computadores. Considerando-se que muitos dos problemas encontrados na agricultura e pecuária são inerentemente visuais, as técnicas de aprendizado profundo se popularizaram rapidamente.

Inteligência artificial e aprendizado profundo, em particular, vêm sendo aplicados com cada vez mais frequência para lidar com as condições não estruturadas e dinâmicas encontradas nos campos agrícolas. Métodos de detecção e classificação baseados em aprendizado profundo normalmente empregam Redes Neurais Convolucionais (CNNs no termo em inglês) (Krizhevsky et al., 2012; Szegedy et al., 2015; Chollet, 2017; Zoph et al., 2018). No contexto de drones para

monitoramento de gado, embora técnicas de classificação sejam utilizadas (Barbedo et al., 2019), modelos de detecção, como o YOLOv3 (Redmon; Farhadi, 2018) e o Mask R-CNN (He et al., 2017), são frequentemente preferidos, uma vez que estes têm a capacidade de indicar exatamente onde o animal está localizado (Mahmud et al., 2021). Além disso, a exata delimitação dos animais pode ser alcançada através de modelos de segmentação semântica, como o Deeplab v3 (Chen et al., 2017), o SegNet (Badrinarayanan et al., 2016) e a U-Net (Ronneberger et al., 2015). Todos esses modelos têm implementações e versões pré-treinadas em diferentes plataformas, e a documentação associada é detalhada e acessível (Barbedo, 2022).

Uma consequência associada à disponibilidade de técnicas de inteligência artificial é que o número de artigos científicos empregando arquiteturas de aprendizado profundo vem aumentando continuamente. Porém, muitos desses trabalhos sofrem dos mesmos problemas, os quais frequentemente levam a resultados pouco confiáveis. Erros metodológicos sérios são comuns, indicando que mesmo os revisores dos artigos têm conhecimento limitado sobre o assunto. O objetivo desta seção é fornecer uma análise dos principais aspectos a serem considerados no fluxo normalmente adotado para treinar modelos profundos, com especial atenção dedicada aos muitos obstáculos que podem tornar os modelos gerados inadequados para uso prático.

## 7 CAPTURA E PREPARAÇÃO DAS IMAGENS

Por mais que as técnicas de inteligência artificial tenham evoluído nos últimos anos, modelos de boa qualidade só são viáveis se os dados usados no seu treinamento representam adequadamente o problema a ser resolvido. Nesse contexto, um dos principais desafios na construção de conjuntos de imagens para treinamento de modelos de IA é garantir que toda variabilidade associada ao problema a ser resolvido esteja adequadamente representada. Dentre os fatores que podem contribuir para o aumento da variabilidade – devendo portanto ser levados em consideração –, alguns se destacam:

- O fundo da imagem, composto por todos os pixels que não pertençam aos objetos de interesse, pode variar significativamente de acordo com a coloração do pasto, a presença de solo exposto e a presença de árvores, pedras, etc. A menos que se saiba que os locais onde o modelo gerado será aplicado possuem certas características relativamente homogêneas entre si, é importante que pelo menos

a maioria dessas variações esteja presente no conjunto de imagens capturado;

- Condições de iluminação: como discutido anteriormente, convém que se determinem certos protocolos em relação ao horário de captura das imagens e às condições climáticas, a fim de existirem condições de iluminação ideais para resolver o problema. Contudo, mesmo com tais protocolos, variações de iluminação relacionadas ao ângulo de insolação, estação do ano e outros fatores ainda ocorrerão e deverão estar representadas na base de imagens;
- Variações intraclasse: no monitoramento de animais, as características visuais da pelagem são essenciais para a detecção e o reconhecimento dos indivíduos. Variações nos padrões visuais são comuns e acentuados entre diferentes raças, mas mesmo animais de uma mesma raça podem ter pelagens com características distintas. Assim, é importante que o conjunto de dados a ser utilizado no treinamento dos modelos reflita essas possíveis variações;
- Configuração dos sensores e câmeras: os modelos devem, sempre que possível, ser treinados com imagens capturadas usando todos os sensores e configurações que podem potencialmente ser encontrados durante o uso prático. Caso o modelo venha a ser utilizado sob a mesma configuração, este fator deixa de ter relevância.

Uma parte fundamental do desenvolvimento e treinamento dos modelos de IA é a anotação dos dados de referência, na qual os objetos de interesse são manualmente identificados e as classes corretas são atribuídas (por exemplo, “animal” e “não-animal”). O processo de anotação normalmente requer considerável esforço e tempo. É importante considerar que o processo de anotação é inerentemente subjetivo, o que significa que é sujeito a fenômenos cognitivos e psicológicos que podem levar a vieses, ilusões de ótica e erro (Bock et al. 2020). Apesar de existirem ferramentas para auxiliar o processo de anotação (Verma et al., 2020), estas mitigam apenas parte do problema. A solução mais apropriada, em ambos os casos, é utilizar diversas pessoas no processo para uma anotação mais confiável, reduzindo inconsistências e melhorando a qualidade e confiabilidade tanto do conjunto de dados quanto dos modelos treinados.

## 8 TREINAMENTO DOS MODELOS DE INTELIGÊNCIA ARTIFICIAL

Modelos de aprendizado profundo podem ser implementados usando diferentes linguagens de programação, sendo Python a linguagem mais utilizada. Há muitos tutoriais disponíveis *online* com instruções

claras sobre como treinar e usar os modelos de aprendizado profundo.

Experimentos envolvendo aprendizado de máquina e aprendizado profundo, em particular, precisam ser planejados cuidadosamente a fim de gerar o melhor modelo possível. Dentre os aspectos que precisam ser considerados, alguns são particularmente importantes:

- **Arquiteturas:** à medida que a inteligência artificial evolui, novas arquiteturas surgem e novas estruturas são incorporadas aos modelos. Além das arquiteturas padrão, é possível combinar diferentes elementos de modo a gerar novas arquiteturas especificamente devotadas ao problema sendo tratado. A decisão sobre qual estratégia adotar depende de alguns fatores. Arquiteturas customizadas têm o potencial de levar a resultados melhores, mas a busca pela estrutura ideal pode demandar um processo experimental longo e complexo, sem qualquer garantia de que o desempenho do modelo adotado será melhor que aquele obtido usando arquiteturas padrão. O aprendizado de máquina automatizado oferecido por ferramentas, como AutoSklearn e Pycaret, pode ajudar na seleção dos melhores modelos. Se arquiteturas existentes são empregadas, é importante considerar que, em geral, há um compromisso entre desempenho e complexidade e tamanho da rede. A seleção da arquitetura mais apropriada deve se basear numa análise cuidadosa desses fatores;
- **Transferência de aprendizado:** a fim de evitar desperdício de tempo e recursos computacionais, a maioria das arquiteturas padrão tem disponíveis versões pré-treinadas usando conjuntos de dados, como o ImageNet (Deng et al., 2009). A transferência de aprendizado normalmente funciona bem, sendo efetiva em acelerar a convergência da rede. Apesar de haver casos em que o treinamento “do zero” é uma melhor opção, a maior parte dos estudos indica que a transferência de aprendizado é frequentemente a melhor opção;
- **Parâmetros a serem otimizados:** redes neurais profundas têm diversos parâmetros que podem ser otimizados, tais como tamanho do minibatch, taxa de aprendizado e tamanho de entrada, entre outros. Como o treinamento deste tipo de rede é em geral demorado, normalmente não é viável testar todas as combinações de parâmetros. A melhor estratégia é testar alguns parâmetros selecionados separadamente até que os valores mais apropriados sejam encontrados;
- **Balanco de classes:** se o número de amostras varia demais entre as classes, o treinamento pode favorecer as mais numerosas, causando vieses severos.

É boa prática igualar o número de amostras entre as diferentes classes, seja limitando o número de amostras das classes mais numerosas, seja pela aplicação de aumento às amostras das classes menores;

- **Aumento de dados:** esta técnica é frequentemente utilizada para aumentar artificialmente o tamanho do conjunto de dados e a variabilidade dos dados usados para treinamento. Aumento pode também ser utilizada para balancear as classes. As operações de aumento mais comuns incluem rotação, inversão e deslocamento de imagens, equalização de histograma, melhoria de contraste e equalização adaptativa (Barbedo, 2018). Aumento pode ser uma ferramenta útil, especialmente se o conjunto de imagens é relativamente pequeno, porém não deve ser aplicada indiscriminadamente. Em primeiro lugar, aumento deve ser aplicada somente ao conjunto de treinamento. É possível aplicar aumento ao conjunto de teste após a divisão em subconjuntos, mas normalmente isso é desnecessário. Se a aumento é aplicada antes da separação nos conjuntos de treinamento e teste, a subsequente divisão em subconjuntos pode fazer com que imagens similares, apenas com pequenas variações, estejam presentes em ambos os conjuntos, causando forte viés nos resultados obtidos. Além disso, se um número excessivo de operações de aumento é aplicado, o conjunto de treinamento pode se tornar excessivamente redundante, o que pode levar a efeitos inesperados na maneira como a rede é treinada. Infelizmente, muitos artigos revisados por pares publicados cometem este erro, fato este frequentemente utilizado como justificativa para perpetuação do problema (Sladojevic et al., 2016; Liu et al., 2018; Zhang et al., 2018; Jiang et al., 2019);
- **Procedimento de treinamento/teste:** as proporções mais utilizadas para os conjuntos de treinamento e teste são 70%/30% e 80%/20%. Alguns estudos adotam também um subconjunto de validação, normalmente contendo 10% de todas as amostras, a fim de testar a acurácia do modelo à medida que o treinamento progride. Essas proporções estão bem estabelecidas e, em geral, não precisam ser alteradas. O número ideal de épocas a ser adotado para treinamento depende da velocidade de convergência, a qual é fortemente dependente das características dos dados e do número de classes. Uma vez que a acurácia começa a estabilizar, o treinamento deve ser interrompido a fim de evitar desperdício de tempo e o fenômeno de “overfitting”, o qual pode causar perda de generalidade. Outros aspectos do processo de treinamento, como taxa de apren-

dizado, tipo de otimizador, tamanho do *minibatch*, etc., normalmente são determinados caso a caso. Uma boa referência para esses valores são os códigos disponíveis *online* dedicados a aplicações similares, de modo que poucas pessoas dedicam tempo significativo otimizando esses valores;

- Validação cruzada: esta estratégia é de fundamental importância na produção de resultados confiáveis. Especialmente em casos em que o conjunto de dados não possui muita variação, se uma única partição de dados é utilizada, as distribuições dos conjuntos de treinamento e teste podem ter fortes vieses, inadvertidamente favorecendo ou penalizando os modelos sendo comparados. Em outras palavras, viés causado por distribuições de dados desfavoráveis pode levar a resultados fortemente enviesados e irrealistas. A maneira mais efetiva de evitar essa situação é pela aplicação de validação cruzada com ao menos cinco repetições (5-fold);
- Conjuntos de dados independentes: “covariate shift” é o fenômeno no qual diferenças nas distribuições dos dados usados para treinamento e teste do modelo resultam em baixa acurácia (Barbedo, 2022). Em muitos casos, apesar de os conjuntos de treinamento, teste e validação serem distintos, normalmente as amostras vêm do mesmo conjunto de dados, naturalmente possuindo certa correlação entre eles. De fato, é comum que haja uma drástica redução de acurácia quando modelos treinados são aplicados a conjuntos de imagens independentes (Ferentinos, 2018; Mohanty et al., 2016). Há algumas maneiras de mitigar este problema, especialmente através de técnicas de adaptação de domínio, mas, para resultados mais realistas, é sempre recomendável empregar conjuntos de dados separados para avaliar os modelos.

## 9 SELEÇÃO DOS MODELOS DE INTELIGÊNCIA ARTIFICIAL

Normalmente, várias arquiteturas distintas são testadas para seleção do melhor modelo. Dentre os fatores que devem ser considerados para orientar a seleção final, três são particularmente importantes: acurácia, complexidade do modelo e capacidade de generalização.

Há muitas possíveis medidas para avaliar a acurácia do modelo, dependendo do tipo de problema a ser resolvido, tais como precisão e revocação, no caso de problemas de classificação, e Interseção sobre União (IoU), no caso de problemas de segmentação. Acurácia é o critério mais óbvio para escolha do modelo, mas pode não ser suficiente para apontar a melhor opção.

A complexidade do modelo também pode ser importante em certos contextos. O processo de treinamento de redes neurais profundas é quase sempre computacionalmente intenso, às vezes demandando dias ou mesmo semanas, para ser completado. Por outro lado, a maior parte dos modelos treinados pode ser executada em equipamentos com poder computacional limitado, mas aplicações em tempo real podem às vezes exigir modelos mais leves para serem viáveis.

Em algumas circunstâncias, os modelos podem alcançar acurácias muito elevadas durante seu desenvolvimento, mas falhar sob condições reais, indicando pouco poder de generalização. Como os dados a serem utilizados quase sempre possuem lacunas na sua representatividade, é importante que a arquitetura adotada tenha boa capacidade de generalização para lidar com os casos omitidos. Este fator não é fácil de avaliar, mas é de fundamental importância para avaliar o potencial do modelo. Este fato novamente destaca a importância de se utilizarem conjuntos de dados independentes para avaliar os modelos, como discutido anteriormente.

## 10 USO PRÁTICO DOS MODELOS E TECNOLOGIAS

No contexto da pesquisa acadêmica, o trabalho frequentemente termina quando o modelo é treinado e avaliado, e os resultados são publicados. Porém, se o modelo será usado em aplicações práticas, há alguns outros desafios e passos que precisam ser considerados.

Como discutido anteriormente, é importante conhecer a capacidade de generalização do modelo, isto é, quão preparado o modelo está para lidar com imagens provenientes de diferentes sensores, regiões e estações do ano. Em geral, é difícil construir conjuntos de dados que cubram toda a gama de variações. Como resultado, na prática, haverá situações para as quais o modelo não foi treinado apropriadamente. Na prática, isso significa que resultados confiáveis só são esperados em situações similares àquelas encontradas no conjunto de treinamento original. Esta é quase certamente a principal razão para a ausência de tecnologias baseadas em drones e imagens suficientemente confiáveis para o monitoramento de animais. A solução mais óbvia seria adicionar mais variabilidade ao conjunto de dados, mas isso leva tempo e nem sempre é viável. Isto posto, dependendo das características do problema e do modelo adotado, pode haver certa robustez a situações não presentes no conjunto de treinamento. Determinar a gama de situações para a qual o modelo pode ser aplicado não é simples e normalmente requer pesquisas adicionais. Uma maneira de se alcançar esse objetivo é convencer alguns

parceiros – de preferência, pecuaristas – a testarem a tecnologia e reportar problemas quando estes ocorrerem. Esta estratégia não somente permite um delineamento mais fino da tecnologia, mas gera mais amostras que podem ser utilizadas para retreinar o modelo. Em qualquer caso, isto envolve ações que vão muito além dos desafios técnicos envolvidos no problema.

Uma alternativa que vem produzindo resultados promissores é o uso de técnicas de adaptação de domínio. Estas técnicas são um caso particular da transferência de aprendizado que exploram os dados rotulados em um ou mais domínios relacionados para aprender um classificador capaz de lidar com dados desconhecidos ou não rotulados no domínio alvo (Csurka, 2017). Em outras palavras, as características dos novos dados a serem processados pelo modelo são artificialmente alteradas para se tornarem mais próximas às características dos dados usados para treinamento. Por exemplo, se o modelo foi treinado apenas com imagens capturadas com tempo limpo e luz solar direta, mas tem de lidar com imagens capturadas com tempo nublado, teoricamente estas últimas podem ser alteradas para se aproximarem das características das primeiras, potencialmente reduzindo as taxas de erro. Este tipo de estratégia está sendo estudada ativamente e provavelmente será aplicada com mais frequência no futuro próximo.

Finalmente, é importante considerar que nenhuma tecnologia baseada em IA é perfeita. Uma característica interessante de modelos de aprendizado profundo é o fato destes não apenas fornecerem uma classificação/detecção, mas também o grau de confiança daquela resposta. É uma boa ideia fornecer essa informação aos usuários a fim de enfatizar que erros podem ocorrer e que as respostas fornecidas por tecnologias de IA não devem ser aceitas cegamente. Na verdade, o principal objetivo de tecnologias de IA aplicadas a agricultura e pecuária é prover informações confiáveis para ajudar no processo de tomada de decisões. A ideia não é eliminar o envolvimento humano e sim preencher lacunas de informação que poderiam levar a decisões erradas. É importante ter este fato em mente, porque se tais lacunas não existem, o emprego deste tipo de tecnologia pode ser redundante e até mesmo introduzir ruído no processo de tomada de decisão.

## 11 CONSIDERAÇÕES FINAIS

O uso de algoritmos de inteligência artificial e de redes neurais profundas, em particular, vem crescendo constantemente em várias e diferentes aplicações, incluindo aquelas relevantes à pecuária. Apesar de os

passos para gerar modelos treinados serem relativamente simples, há muitas sutilezas metodológicas que são frequentemente ignoradas, levando a resultados pouco confiáveis. O objetivo deste capítulo foi oferecer um guia para explorar as capacidades dos drones da maneira mais efetiva possível no contexto do monitoramento de gado, bem como melhorar a aplicabilidade prática dos modelos e aplicações baseados em imagens capturadas por drones.

## REFERÊNCIAS

- AGÊNCIA NACIONAL DE AVIAÇÃO CIVIL. **Regulamento Brasileiro de Aviação Civil Especial nº 94/2017 (RBAC-E nº 94/2017)**. 2022. Disponível em: <https://www.gov.br/anac/pt-br/assuntos/drones>. Acesso em: 10 maio 2022.
- ANDERSON, K.; GASTON, K. J. Lightweight unmanned aerial vehicles will revolutionize spatial ecology. **Frontiers in Ecology and the Environment**, v. 11, n. 3, p. 138-146, 2013. DOI: <http://doi.org/10.1890/120150>.
- BADRINARAYANAN, V., KENDALL, A., CIPOLLA, R. SegNet: a deep convolutional encoder-decoder architecture for image segmentation. **arXiv**, v. 1511.00561v3, p. 1-14, 2016.
- BARBEDO, J. G. A. Deep learning applied to plant pathology: the problem of data representativeness. **Tropical Plant Pathology**, v. 47, n. 1, p. 85-94, 2022. DOI: <http://doi.org/10.1007/s40858-021-00459-9>.
- BARBEDO, J. G. A.; KOENIGKAN, L. V.; SANTOS, T. T.; SANTOS, P. M. A study on the detection of cattle in UAV images using deep learning. **Sensors**, v. 19, n. 24, p. 5436, 2019. DOI: <http://doi.org/10.3390/s19245436>.
- BARBEDO, J. G. A. Impact of dataset size and variety on the effectiveness of deep learning and transfer learning for plant disease classification. **Computers and Electronics in Agriculture**, v. 153, p. 46-53, 2018. DOI: <http://doi.org/10.1016/j.compag.2018.08.013>.
- BARBEDO, J. G. A.; KOENIGKAN, L. V. Perspectives on the use of unmanned aerial systems to monitor cattle. **Outlook on Agriculture**, v. 47, n. 3, p. 214-222, 2018. DOI: <http://doi.org/10.1177/0030727018781876>.
- BOCK, C. H.; BARBEDO, J. G. A.; PONTE, E. M. D.; BOHNENKAMP, D.; MAHLEIN, A. K. From visual estimates to fully automated sensor-based measurements of plant disease severity: status and challenges for improving accuracy. **Phytopathology Research**, v. 2, n. 1, p. 9, 2020. DOI: <http://doi.org/10.1186/s42483-020-00049-8>.
- CHABOT, D.; BIRD, D. M. Wildlife research and management methods in the 21st century: where do unmanned aircraft fit in? **Journal of Unmanned Vehicle Systems**, v. 3, n. 4, p. 137-155, 2015. DOI: <http://doi.org/10.1139/juvs-2015-0021>.
- CHEN, L. C.; PAPANDREOU, G.; SCHROFF, F.; ADAM, H. Rethinking atrous convolution for semantic image segmentation. **arXiv**, v. 1706.05587v3, p. 1-14, 2017.

- CHOLLET, F. Xception: Deep learning with depthwise separable convolutions. In: IEEE CONFERENCE ON COMPUTER VISION AND PATTERN RECOGNITION, 2017, Honolulu. **Proceedings [...]**. Honolulu: Hawaii Convention Center, 2017. p. 1800-1807.
- CHRÉTIEN, L. P.; THÉAU, J.; MÉNARD, P. Visible and thermal infrared remote sensing for the detection of white-tailed deer using an unmanned aerial system. **Tools and Technology**, v. 40, n. 1, p. 181-191, 2016. DOI: <http://doi.org/10.1002/wsb.629>.
- COLEFAX, A. P.; BUTCHER, P. A.; KELAHER, B. P. The potential for unmanned aerial vehicles (UAVs) to conduct marine fauna surveys in place of manned aircraft. **ICES Journal of Marine Science**, v. 75, n. 1, p. 1-8, 2017. DOI: <http://doi.org/10.1093/icesjms/fsx100>.
- CSURKA, G. Domain adaptation for visual applications: a comprehensive survey. **arXiv**, v. 1702.05374v2, p. 1-46, 2017.
- DENG, J.; DONG, W.; SOCHER, R.; LI, L. J.; LI, K.; FEI-FEI, L. Imagenet: A large-scale hierarchical image database. In: IEEE CONFERENCE ON COMPUTER VISION AND PATTERN RECOGNITION, 2009, Miami. **Proceedings [...]**. Miami: Convention Center, 2009. p. 248-255.
- FERENTINOS, K. P. Deep learning models for plant disease detection and diagnosis. **Computers and Electronics in Agriculture**, v. 145, p. 311-318, 2018. DOI: <http://doi.org/10.1016/j.compag.2018.01.009>.
- HE, K.; GKIOXARI, G.; DOLLÁR, P.; GIRSHICK, R. Mask R-CNN. In: IEEE INTERNATIONAL CONFERENCE ON COMPUTER VISION, 2017, Veneza: **Proceedings [...]**. Venice: Venice Convention Center, 2017. p. 2980-2988.
- JIANG, P.; CHEN, Y.; LIU, B.; HE, D.; LIANG, C. Real-time detection of apple leaf diseases using deep learning approach based on improved convolutional neural networks. **IEEE Access: Practical Innovations, Open Solutions**, Piscataway, v. 7, p. 59069-59080, 2019. DOI: <http://doi.org/10.1109/ACCESS.2019.2914929>.
- KRIZHEVSKY, A.; SUTSKEVER, I.; HINTON, G. E. Imagenet classification with deep convolutional neural networks. In: ANNUAL CONFERENCE ON NEURAL INFORMATION PROCESSING SYSTEMS, 2012, Lake Tahoe. **Proceedings [...]**. Lake Tahoe: Harrahs and Harveys, 2012. p. 1106-1114.
- LINCHANT, J.; LISEIN, J.; SEMEKI, J.; LEJEUNE, P.; VERMEULEN, C. Are unmanned aircraft systems (UASs) the future of wildlife monitoring? A review of accomplishments and challenges. **Mammal Review**, v. 45, n. 4, p. 239-252, 2015. DOI: <http://doi.org/10.1111/mam.12046>.
- LIU, B.; ZHANG, Y.; HE, D.; LI, Y. Identification of apple leaf diseases based on deep convolutional neural networks. **Symmetry**, v. 10, n. 1, p. 11, 2018. DOI: <http://doi.org/10.3390/sym10010011>.
- LONGMORE, S.; COLLINS, R.; PFEIFER, S.; FOX, S. E.; MULERO-PAZMANY, M.; BEZOMBES, F.; GOODWIND, A.; JUAN OVELAR, M.; KNAPEN, J. H.; WICH, S.A. Adapting astronomical source detection software to help detect animals in thermal images obtained by unmanned aerial systems. **International Journal of Remote Sensing**, v. 38, n. 8-10, p. 2623-2638, 2017. DOI: <http://doi.org/10.1080/01431161.2017.1280639>.
- MAHMUD, M. S.; ZAHID, A.; DAS, A. K.; MUZAMMIL, M.; KHAN, M. U. A systematic literature review on deep learning applications for precision cattle farming. **Computers and Electronics in Agriculture**, v. 187, p. 106313, 2021. DOI: <http://doi.org/10.1016/j.compag.2021.106313>.
- MILLER, J. O.; ADKINS, J.; TULLY, K. **Providing aerial images through UAVs**. Fact Sheet FS-1056. 2017. Disponível em: <https://drum.lib.umd.edu/handle/1903/19168>. Acesso em 10 maio 2022.
- MOHANTY, S. P.; HUGHES, D. P.; SALATHÉ, M. Using deep learning for image based plant disease detection. **Frontiers in Plant Science**, v. 7, p. 1419, 2016. DOI: <http://doi.org/10.3389/fpls.2016.01419>.
- REDMON, J., FARHADI, A. Yolov3: an incremental improvement. **arXiv**, v. 1804.02767v1, 2018.
- RONNEBERGER, O.; FISCHER, P.; BROX, T. U-net: Convolutional networks for biomedical image segmentation. In: MAHMUD, M. S.; ZAHID, A.; DAS, A. K.; MUZAMMIL, M.; KHAN, M. U. (eds.). **Medical image computing and computer-assisted intervention – MICCAI 2015**. Cham: Springer International Publishing, 2015. p. 234-241.
- SLADOJEVIC, S.; ARSENOVIC, M.; ANDERLA, A.; CULIBRK, D.; STEFANOVIĆ, D. Deep neural networks based recognition of plant diseases by leaf image classification. **Computational Intelligence and Neuroscience**, v. 2016, p. 3289801, 2016. DOI: <http://doi.org/10.1155/2016/3289801>.
- SZEGEDY, C.; LIU, W.; JIA, Y.; Sermanet, P.; REED, S.; ANGUELOV, D.; ERHAN, D.; VANHOUCHE, V.; RABINOVICH, A. Going deeper with convolutions. In: IEEE CONFERENCE ON COMPUTER VISION AND PATTERN RECOGNITION, 2015, Boston. **Proceedings [...]**. Boston: Convention Center, 2015. p. 1-9.
- TERLETZKY, P.; RAMSEY, R. D.; NEALE, C. M. U. Spectral characteristics of domestic and wild mammals. **GIScience & Remote Sensing**, v. 49, n. 4, p. 597-608, 2012. DOI: <http://doi.org/10.2747/1548-1603.49.4.597>.
- VERGOUW, B.; NAGEL, H.; BONDT, G.; CUSTERS, B. Drone technology: types, payloads, applications, frequency spectrum issues and future developments. In: CUSTERS, B. (ed.). **The future of drone use. Information technology and law series**. The Hague: T.M.C. Asser Press, 2016. v. 27, p. 21-45.
- VERMA, S.; BHATIA, A.; CHUG, A.; SINGH, A. P. Recent advancements in multimedia big data computing for iot applications in precision agriculture: opportunities, issues, and challenges. In: TANWAR, S.; TYAGI, S.; KUMAR, N. (ed.). **Multimedia Big Data Computing for IoT Applications. Intelligent Systems Reference Library**. Singapore: Springer, 2020. v. 163, p. 391-416. [http://doi.org/10.1007/978-981-13-8759-3\\_15](http://doi.org/10.1007/978-981-13-8759-3_15).
- WATTS, A. C.; AMBROSIA, V.; GANDHINKLEY, E. A. Unmanned aircraft systems in remote sensing and scientific research: classification and considerations of use. **Remote**

- Sensing**, v. 4, n. 6, p. 1671-1692, 2012. DOI: <http://doi.org/10.3390/rs4061671>.
- WITCZUK, J.; PAGACZ, S.; ZMARZ, A.; CYPEL, M. Exploring the feasibility of unmanned aerial vehicles and thermal imaging for ungulate surveys in forests – preliminary results. **International Journal of Remote Sensing**, v. 39, n. 15-16, p. 5504-5521. 2017. DOI: <http://doi.org/10.1080/01431161.2017.1390621>.
- ZHANG, C.; KOVACS, J. M. The application of small unmanned aerial systems for precision agriculture: a review. **Precision Agriculture**, v. 13, n. 6, p. 693-712, 2012. DOI: <http://doi.org/10.1007/s11119-012-9274-5>.
- ZHANG, S.; WANG, H.; HUANG, W.; YOU, Z. Plant diseased leaf segmentation and recognition by fusion of superpixel, k-means and phog. **Optik**, v. 157, p. 866-872, 2018. DOI: <http://doi.org/10.1016/j.ijleo.2017.11.190>.
- TEXAS A&M AGRILIFE, 2024. Disponível em: <https://agrilife.tamu.edu/>. Acesso em: 26 jul. 2024.
- ZOPH, B.; VASUDEVAN, V.; SHLENS, J.; LE, Q. V. Learning transferable architectures for scalable image recognition. **arXiv**, v. 1707.07012v4, p. 1-14, 2018.