

Reconhecimento de Gado através do uso de visão computacional

MATHEUS DE CASTRO MARCONDES¹; ALLAN LINCOLN RODRIGUES SIRIANI²

¹ Discente em Big Data no Agronegócio na FATEC Pompeia “Shunji Nishimura”, Pompéia-SP, mcmarcondes2001@gmail.com

² Docente do curso Big Data no Agronegócio, FATEC Pompeia, Pompéia-SP.

RESUMO: A contagem de gado é um elemento de extrema importância na bovinocultura já que garante a segurança dos bovinos e a organização de pastagem, porém este processo é exaustivo quando feito de maneira manual, para solucionar este problema foram empregados algoritmos e metodologias computacionais para automatizar esse processo, como o reconhecimento de gado através do uso de visão computacional com o modelo integralmente convolucional YOLACT para segmentação em tempo real e o modelo generalista de segmentação pré-treinado SAM da Meta, que são uma modelos dinâmicos e altamente personalizáveis que envolvem o uso de algoritmos de segmentação por treinamento para identificar elementos em mídias estáticas ou dinâmicas. Sendo então a finalidade deste trabalho, provar a eficácia dessas técnicas em relação aos métodos tradicionais de contagem manual de animais comparando com outros métodos já estabelecidos no campo científico baseados em técnicas similares ou combinações dessas técnicas com outras aplicações, bem como avaliar a sua aplicabilidade na gestão de rebanhos bovinos e como esta técnica pode afetar positivamente os processos manuais dentro do campo, além de outros benefícios que podem surgir da expansão do tema partindo do princípio de que aplicação plena em ambientes de alta variabilidade podem expandir a base do conhecimento na área.

Palavras-chave: Visão computacional; Segmentação de Imagem; Bovinocultura

INTRODUÇÃO

A utilização de visão computacional na identificação e contagem de animais é um tema em expansão na área da agricultura e pecuária, e existem diversos trabalhos na literatura que descrevem o uso de diferentes técnicas de processamento de imagem para realizar essa tarefa. Alguns desses trabalhos se concentram no uso de câmeras de vigilância para monitorar a atividade do rebanho com finalidade de evitar estresse físico para os bovinos e problemas de saúde que podem ser causados por esse estresse, de acordo com Guan (2020), *“Sensors were use by conventional methos to recognize activity of cattle, but attachment of sensors to the animal may cause stress.”*, ou seja, os sensores são (tradicionalmente) usados por métodos convencionais para reconhecer a atividade do gado, mas a fixação de sensores no animal pode causar estresse, trabalhando com o propósito de conciliar metodologias

podemos também compreender que a utilização do aprendizado profundo em conjunto de câmeras nesse artigo pode trabalhar em associação direta com outras metodologias como a de Segmentação de Instância através de modelos convolucionais como a arquitetura YOLACT que permite quebrar tarefas complexas de segmentação de instância em duas mais simples. Parafraseando o artigo YOLACT++: Better Real-time Instance Segmentation, as tarefas dentro do YOLACT são executadas de maneira paralela, e podem ser montadas em uma tarefa final que gera máscaras de protótipo para identificar as instâncias a serem segmentadas e, por fim, a outra máscara que permite uma nova geração de uma instância que pode prever o vetor das máscaras de coeficiente e ancora a codificação individual na representação da instância, dessa maneira construímos linearmente a segmentação através dessas duas tarefas principais.

É inegável a importância da contagem de gado na gestão da produção animal na bovinocultura, isso gera a necessidade de melhorar a eficiência do processo de contagem para reduzir o tempo e o esforço necessários para realizar essa tarefa, através da combinação das metodologias citadas anteriormente, podem ser gerados níveis de facilidade que possuem custos variados dependendo do tipo de implementação necessária, a automatização de equipamentos pode ajudar diretamente a reduzir a necessidade de intervenção humana nesse processo, gerando imensa facilidade e permitindo a alocação do fator humano para tarefas que são substancialmente mais abstrusas em sua implementação ou que não possuem custo-benefício significativo para efetuar uma integração automatizada.

Através da compreensão de que o elemento humano pode ser alocado para tarefas que contenham coerência de uso para esse tipo de esforço, podemos denotar que a necessidade do refino dessas técnicas para diminuir o percentual de erro se torna essencial para o processo, sendo necessário no mínimo equalizar ao erro humano, mas com intenção sempre de superar a precisão de acerto para maximizar a eficiência dessa tarefa, conseqüentemente garantindo melhor segurança dos bovinos e menor custo de repetição do processo, buscando portanto provar este ponto de eficiência com algoritmos de aprendizado profundo combinado com visão computacional para identificar e contar os bovinos mesmo em mídias dinâmicas como vídeos, que demandam uma quantidade maior de processamento para gerar as contagens porém são mais concisos quanto a aplicação no campo já que garante que cada iteração visual será analisada, diminuindo assim, o potencial de erro.

MATERIAIS E MÉTODOS

Foram utilizadas duas mídias principais de vídeo disponibilizadas publicamente como fonte de treinamento de visão computacional para identificação e contagem de gados. O primeiro vídeo, intitulado "*Herding cattle with a drone*", mostra a utilização de um drone para conduzir um grupo de gados em uma fazenda. Foram selecionados trechos deste vídeo para que a inteligência artificial pudesse reconhecer os animais e aprender a contá-los.

O segundo vídeo utilizado é intitulado "JP tocando gado com drone na fazenda", este vídeo mostra o processo de condução de gados utilizando um drone e fornece uma excelente fonte de imagens para treinamento de algoritmos de visão computacional. Foram selecionados trechos deste vídeo para que a inteligência artificial pudesse identificar e contar os gados com precisão através de parâmetros específicos escolhidos manualmente para treinar e testar diversas características.

Ambos os vídeos foram escolhidos por apresentarem cenas claras de gados sendo conduzidos por um drone em uma fazenda. As imagens foram capturadas em alta definição e em diferentes ângulos, permitindo que a inteligência artificial pudesse aprender a identificar e contar os animais em diferentes situações. Com o uso desses vídeos, espera-se que a inteligência artificial possa ser treinada para identificar e contar gados com alta precisão em diferentes cenários de campo e condições de luz e densidade, tendo como principal objetivo os elementos que possuem maior variabilidade como baixo contraste em imagens que possam ser capturadas com câmeras de sensor inferior à qualidade ideal ou que possuam características de economia de energia para permitir a portabilidade como uma câmera de drone que trabalha diretamente com uma bateria limitada que precisa ser realimentada constantemente para manter a operação, então operar bem em menor qualidade se torna um elemento importante para o custo-benefício e para a realização coerente com recursos realistas, já que supor que as imagens sempre possuirão clareza visual absoluta gera um resultado que não se aplica a situações reais.

Para garantir que ambos os modelos sejam capazes de identificar e contar os gados de forma precisa, foram selecionados cuidadosamente os trechos dos vídeos

em que os animais estavam em posições variadas, em diferentes níveis de iluminação e sobreposição.

Neste exemplo é possível observar um fragmento do vídeo que apresenta alta sobreposição dos bovinos, ou seja, pelo ângulo da câmera do drone, diversos indivíduos obstruem a visão clara de sua delimitação individual

Figura 1: Gado em baixo contraste e alta sobreposição



Fonte: YOUTUBE (2021a)

Além disso, os trechos selecionados foram cuidadosamente rotulados e organizados através de uma distribuição privada da ferramenta Label Studio para rotular as imagens selecionadas dos vídeos utilizados no treinamento da inteligência artificial. O Label Studio é uma plataforma de marcação de dados que permite a criação de tarefas de rotulagem de imagens e outros tipos de dados. Com o uso desta ferramenta, foi possível rotular os trechos dos vídeos selecionados de maneira eficiente e precisa, permitindo que a inteligência artificial pudesse aprender a identificar e contar os gados com maior precisão. Além disso, o Label Studio também permite que os rótulos sejam revisados e editados, garantindo a qualidade dos dados utilizados para o treinamento do algoritmo de visão computacional. Para garantir a qualidade dos dados utilizados nos experimentos, todas as imagens foram revisadas cuidadosamente para verificar o ângulo e a iluminação adequados, bem como a

presença exclusiva de animais bovinos. Essa etapa é essencial para garantir a precisão o algoritmo de segmentação de instância do modelo YOLACT em detectar e contar corretamente os bovinos presentes nas imagens.

Figura 2: Gado em alto contraste e baixa sobreposição



Fonte: YOUTUBE (2021b)

Os experimentos foram realizados por meio da execução dos scripts de segmentação do modelo convolucional de segmentação de instância em tempo real YOLACT em Python aplicado em imagens de diversas fontes no YOUTUBE (2021a) e YOUTUBE (2021b) utilizando a metodologia de rede neural convolucional de 50 camadas (*50-layer convolutional neural network*), com o auxílio de bibliotecas como *PyTorch* que é uma estrutura de aprendizado de máquina baseada na biblioteca *Torch*, usada para aplicações de visão computacional, por fim também foram utilizadas bases de dados pré-treinadas como a *Detectron* e uma base de dados treinada manualmente no *LabelStudio*, que é uma ferramenta de rotulação de imagens, já a utilização do modelo SAM (*Segment Anything Model*) da Meta AI apresenta menor custo técnico já que se baseia em extensas bases pré-treinadas, esse modelo possui a base mais extensa de dados na época de sua publicação científica, atingindo 1 bilhão de máscaras em 11 milhões de imagens que são, de acordo com Kirillov, “[...] *licensed and privacy respecting*”, ou seja, imagens que são licenciadas e respeitadas com o direito de privacidade. Esses modelos foram a base

para a implementação de algoritmos de aprendizado profundo em conjunto com visão computacional para identificar e contar os bovinos presentes nas imagens, mesmo em condições desafiadoras, como variações na iluminação ou posicionamento dos animais.

A utilização do YOLACT foi especialmente relevante nesse projeto, já que esse modelo de detecção de objetos em imagens utiliza a técnica de segmentação semântica em tempo real, que permite gerar a segmentação com a eficiência necessária para monitorar em câmeras de vídeo e outros tipos de mídia em alta eficiência, permitindo diversas práticas de revisão individual de imagens para comparar a eficiência em tipos específicos de ambiente, mostrando facilmente suas fraquezas e permitindo que o modelo seja treinado de acordo. Ele foi proposto em um artigo de pesquisa em 2019 e foi projetado para superar as limitações de modelos anteriores, como a complexidade computacional e a necessidade de pós-processamento para obter segmentações precisas, dessa maneira se torna possível a utilização racional de nodos de processamento individuais que usam os recursos computacionais de maneira eficiente.

A técnica de segmentação semântica consiste em atribuir a cada pixel de uma imagem uma etiqueta correspondente à classe de objeto a que ele pertence. No caso de um modelo de detecção de objetos, a segmentação semântica é usada para extrair uma máscara que indica a localização do objeto na imagem. Isso é particularmente útil em situações em que vários objetos estão próximos uns dos outros ou quando há sobreposição parcial entre objetos, como no caso de uma pastagem não controlada, onde os gados podem, em perspectiva da câmera ou imagem, estar se sobrepondo, e com contrastes semelhantes, podem causar confusão ou dificuldade na hora da contagem.

O uso de bibliotecas como o PyTorch permitiu a implementação de algoritmos de aprendizado profundo e processamento de imagem de maneira mais eficiente, graças à disponibilidade de funções prontas e documentação detalhada, desta maneira, reduziu significativamente o tempo e o esforço necessários para desenvolver e testar os algoritmos utilizados nos experimentos.

Além do uso do YOLACT para segmentação de imagens e detecção de bovinos, também é foi utilizado o SAM (Meta AI) para a identificação e contagem desses animais. O SAM é uma tecnologia que se baseia em modelos de aprendizado de máquina pré-treinados, permitindo que a identificação e a contagem de bovinos

possam ser realizadas de forma mais rápida e com menor custo técnico. Isso se deve ao fato de que o SAM pode ser utilizado diretamente em bases pré-treinadas, sem a necessidade de realizar todo o treinamento do modelo do zero. Essa técnica é especialmente útil em projetos que exigem uma grande quantidade de dados, já que o uso do SAM permite que sejam utilizadas bases de dados já disponíveis e treinadas, economizando tempo e recursos. O SAM usa algoritmos avançados de aprendizado profundo para analisar imagens e identificar as fronteiras dos objetos dentro delas. Em seguida, aplica uma série de operações matemáticas complexas para "recortar" o objeto do resto da imagem, criando uma segmentação limpa e precisa que pode ser facilmente manipulada ou removida. Um dos principais benefícios do SAM é sua capacidade de trabalhar com uma ampla gama de objetos, desde formas e padrões simples até estruturas e texturas complexas. Isso o torna uma ferramenta ideal para uma variedade de aplicações, incluindo edição de imagens, visão computacional e aprendizado de máquina.

É importante lembrar que, independentemente da técnica utilizada, é necessário realizar uma etapa cuidadosa de seleção e rotulagem das imagens para garantir a qualidade dos dados utilizados no treinamento do modelo de detecção e contagem de bovinos.

Embora as imagens obtidas na internet possam ser consideradas uma limitação para veracidade do projeto, considerando elementos de aleatoriedade no ambiente, elas foram escolhidas de forma criteriosa para garantir a qualidade dos dados utilizados nos experimentos. Essa escolha foi motivada pela necessidade de avaliar o desempenho do algoritmo em condições mais próximas da realidade, em que as imagens podem ser obtidas de diversas fontes e apresentar variações na iluminação, ângulo de visão e outras características que podem afetar a precisão do algoritmo. O processo de verificação e rotulação manual das imagens busca eliminar o máximo possível das diferenças de um ambiente de teste e uma execução real, já que neste processo podemos escolher manualmente diversos casos que em uma execução real podem, potencialmente, não aparecer com a frequência necessária para efetuar um treinamento fidedigno à aleatoriedade de ambiente associada as pastagens em campo.

RESULTADOS E DISCUSSÃO

Partindo do pressuposto de natureza comparativa das técnicas, foram aplicados algoritmos com ambas as metodologias para serem comparadas nos mesmos ambientes, imagens e condições de execução para atestar a eficiência nos ambientes propostos buscando normalizar o comportamento de execução e criar métricas de eficiência, a partir disso foram obtidos os seguintes resultados:

Figura 3: Gado segmentado pelo modelo YOLACT



Fonte: YOUTUBE (2021a)

Os resultados dessa segmentação demonstram uma facilidade em identificar múltiplos bovinos, mesmo em sobreposição, considerando não só o contexto, mas a instância de cada gado, gerando uma contabilização mais coerente.

A segmentação padrão apresenta um esquema de cor diferente para cada instância para deixar claro que cada objeto identificado representa uma só instância segmentada, mas para facilitar o agrupamento visual, foram padronizados com o azul para se destacar do ambiente verde que toma maior parte da tela, também foram removidos elementos que podem causar distração como percentual de certeza, que nesse contexto não necessariamente ajudam na visualização, a contagem foi feita de maneira programática somando todas as instâncias identificadas e apresentando o valor como saída do algoritmo junto com a imagem, que é salva em um arquivo binário de imagem separado dentro do mesmo contexto de execução, este pode também ser gerado como vídeo justamente pela eficiência da geração de máscaras.

Figura 4: Gado segmentado pelo modelo SAM



Fonte: YOUTUBE (2021a) adaptado

Os resultados dessa segmentação demonstram uma dificuldade moderada em identificar a silhueta individual de cada gado, mas não apresenta nenhum falso positivo.

Tabela 1 – Contagem real de gados na imagem x contagem encontrada pelo modelo em imagens de baixo contraste e alta sobreposição


Metodologia de Contagem	Real	Encontrado	Acurácia
Modelo YOLACT	22	22	100%
Modelo SAM	22	17	77.2%

Fonte: Elaborado pelo Autor (2023)

Pelo que podemos observar nos resultados na tabela, o modelo SAM apresentou uma porcentagem de erro significativa ao contar entidades sobrepostas, isso indica que ele pode não ser o ideal para operações críticas que contam com uma fonte primária de visão que esteja em um ângulo desfavorável como uma câmera de segurança montada em um poste ou haste baixa e que deve ser utilizado primariamente para a contagem em climas mais claro e amenos que permitam uma

visão mais facilitada de cada elemento, então no caso desta análise é possível pontuar como a sobreposição foi o elemento que mais afetou negativamente o processo de contagem automatizada.

Figura 5: Gado segmentado pelo modelo YOLACT




Fonte: YOUTUBE (2021b) adaptado

Como é possível observar na imagem adaptada, os resultados da segmentação de instância com a base específica mostram uma facilidade ainda maior de identificar gado quando há menor sobreposição, maior clareza de silhueta e alto contraste de cores.

Isso se prova essencial em situações como por exemplo os gados na esquerda superior que estão em forma ambígua e possuem alta sobreposição, a presença de uma análise contextual dos pixels permite que mesmo estes gados parcialmente ocultos ou com linha de visão obstruída sejam identificados corretamente.

Figura 6: Gado segmentado pelo modelo SAM



Fonte: YOUTUBE (2021b) adaptado

Os resultados desta segmentação mostram também uma maior facilidade para o modelo generalista encontrar gado quando está em situação ideal, mas acabou por identificar um pequeno monte de terra no fundo como gado pela ausência de foco e ignorou um dos gados sobrepostos no fundo, mostrando que o modelo generalista possui dificuldade em compreender cada instância individual.

Tabela 2 – Contagem real de gados na imagem x contagem encontrada pelo modelo em imagens de alto contraste e baixa sobreposição

Metodologia de Contagem	Real	Encontrado	Acurácia
Modelo YOLACT	19	19	100%
Modelo SAM	19	18	94.7%

Fonte: Elaborado pelo autor (2023)

A presença do erro torna-se um problema que pode ser considerado grave quando se considera a operação de situações que potencialmente envolvem perigo, como por exemplo caso um bovino esteja preso ou tenha sido machucado e não presente na contagem automática, pode acabar tendo o caso ignorado e agravado pela ausência da contagem real.

Isso é uma problemática associada diretamente à bases generalistas, já que como foi possível observar nos outros exemplos treinados com bases rotuladas específicas que não ocorreram falsos positivos.

Figura 7: Bovino interagindo com obstáculo de contagem



Fonte: CAIGNY, G (20219) adaptado

É possível visualizar o fator generalista do modelo SAM utilizando uma imagem clara e de alto contraste, o modelo consegue identificar com clareza diversos objetos de múltiplos tipos e instâncias, isso pode então permitir a utilização da visão computacional para outros fatores externos que possam aumentar a segurança e o bem-estar dos bovinos, como lobos, onças e outras ameaças físicas que possam causar estresse nos animais.

CONSIDERAÇÕES FINAIS

Conclui-se através de dados empíricos que ambos os algoritmos propostos são capazes de identificar e contar com devida precisão os animais em diferentes ambientes e condições de iluminação. Além disso, ambos apresentam baixo custo de implementação em ambientes de teste e preparo, o YOLACT pode ser facilmente adaptado a diferentes tipos de fazendas e sistemas de produção de gado, já o SAM consegue atingir com certa facilidade uma precisão abaixo do ideal sem um treinamento específico, sendo então, menos custosos partindo do ponto técnico.

Portanto é possível afirmar que o uso de visão computacional e técnicas de aprendizado de máquina podem trazer importantes benefícios para a bovinocultura e possivelmente outras culturas que demandam a vigília constante de animais, esta prática, aplicada de maneira programática, contribui para a melhoria da eficiência e produtividade da produção de gado e gera a possibilidade de expandir bases de conhecimento e refinar a precisão de modelos, já que os dados obtidos durante a execução destes sistemas geram dados que podem ser consumidos para refinamento das bases, é possível observar uma relação de autofagia ou autossustentabilidade do modelo, já que o objeto observado também gera treinamentos, isso só se torna possível devido a eficiências com que os algoritmos conseguem processar estas imagens, esse fator combinado com uma triagem competente e coerente com elementos de ambiente variados podem gerar uma expansão grande nas bases de conhecimento e rotulação, que, como observado no modelo SAM da Meta AI, influencia diretamente na precisão do refinamento individual, se um modelo treinado de maneira generalista consegue atingir uma taxa de precisão relativamente satisfatória, um modelo específico para tipos e casos específicos podem apresentar ainda mais precisão considerando fatores de variabilidade interna dos tipos de imagem ou mídias analisadas.

Os resultados experimentais demonstraram primariamente a eficiência da arquitetura do modelo YOLACT, treinado com uma base específica para gado demonstrou maior precisão na contagem de animais em ambientes de maior variabilidade, quando comparado com o modelo generalista SAM da Meta AI. O modelo generalista possui uma base de dados extensa, mas não se aprofunda nas variações específicas que podem ocorrer nas imagens de gado, resultando em maior variabilidade de conteúdo, mas uma menor precisão na contagem de objetos específicos como o gado.

Considerando isto, é possível aumentar ainda mais a especificidade do modelo para buscar aumentar a eficiência de outras maneiras como por exemplo gerar modelos para subespécies específicas ou para tipos de pelos específicos.

É possível encontrar mérito no modelo generalista do SAM, já que este pode permitir outras iterações em elementos que interagem com o gado, ou para a criação de sistemas mais complexos que consideram outras métricas para garantir a segurança do gado, como por exemplo a presença de outros animais que podem ferir ou afetar negativamente a pastagem do gado. Para obter resultados refinados em um

modelo não generalista, seria necessário treinar com diversas bases que apresentem imagens claras e em diversos ambientes desses outros elementos, isso cria uma demanda aumentada de recursos manuais e/ou computacionais

Sendo o YOLACT um modelo de detecção de objetos em tempo real, baseado em uma arquitetura de rede neural convolucional, ele demonstra a capacidade de segmentar objetos em imagens de alta resolução com alta velocidade, permitindo uma detecção mais precisa. Já o SAM é uma plataforma de aprendizado de máquina do Facebook, que oferece uma variedade de modelos pré-treinados para tarefas de visão computacional. Embora tenha uma base de dados extensa, não foi projetado especificamente para lidar com as variações específicas que ocorrem em imagens de gado, o que pode resultar em menor precisão na contagem do rebanho.

Ambas as metodologias, YOLACT e SAM, por serem executadas de maneira programática, apresentam uma vantagem significativa em relação aos métodos tradicionais de contagem manual, eliminando o erro humano. A adoção de técnicas de aprendizado de máquina pode contribuir para uma gestão mais precisa e eficiente da produção agropecuária, resultando em um aumento do desenvolvimento sustentável e seguro, além de uma redução na complexidade operacional e nos custos de produção.

É também importante considerar elementos benéficos como a ausência da necessidade de treinar mão de obra humana em técnicas específicas e equipamentos manuais que podem vir a falhar, no fim, o que a automatização de contagem de gado traz de maior vantagem é a diminuição de interações com elementos propensos a falhas, dito isto, o algoritmo não é de estritamente perfeito, mas se treinado da maneira correta, com imagens de ambientes variados e imagens de boa qualidade, este pode apresentar uma eficiência consideravelmente melhor e com menos elementos de complexidade superior à um treinamento ou aquisição de bases treinadas.

Os benefícios da adoção de técnicas programáticas podem ser observados também no aspecto da adoção de sistemas integrados, no sentido de utilização combinada de informações obtidas por aparelhos e sensores semelhantes, como seguem o mesmo formato, podem apresentar similaridade no tratamento e agir positivamente para o crescimento de uma base de conhecimento sustentável de maneira a expandir conhecimento coerente com uma área em específica, como por exemplo, a contagem de gado afetar diretamente áreas como a pastagem, que pode ser tratada com outras tecnologias semelhantes, sabendo a quantidade de gado em

uma pastagem permite o trabalho simbiótico de ambas informações, como por exemplo para denotar o padrão de crescimento de uma pastagem em específica com a relação de gado que fica presente em certas regiões.

REFERÊNCIAS

BARBEDO, J. G. A. et al. **Counting Cattle in UAV Images—Dealing with Clustered Animals and Animal/Background Contrast Changes**, v. 20, n. 7, p. 2126, 10 abr. 2020.

BOLYA, D. et al. YOLACT++: Better Real-time Instance Segmentation. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, p. 1–2, 2020.

BOLYA, D. et al. YOLACT: Real-time Instance Segmentation. **Computer Vision and Pattern Recognition**, p. 3–4, 2020.

BUTLER, Z. et al. From Robots to Animals: Virtual Fences for Controlling Cattle. **The International Journal of Robotics Research**, v. 25, n. 5-6, p. 485–508, maio 2006.

CAIGNY, G. **Wolves and Livestock**. Disponível em:
<<https://www.yamnuskawolfdogsanctuary.com/wolfdogs>>. Acesso em 10 mai. 2023.

CHAI, J. et al. Deep learning in computer vision: A critical review of emerging techniques and application scenarios. **Machine Learning with Applications**, p. 100134, ago. 2021.

FORMIGONI, I. **Contagem do gado sem precisar reunir os animais?** Disponível em: <<https://www.farmnews.com.br/gestao/contagem-do-gado/>>. Acesso em: 1 maio. 2023.

GUAN, H.; MOTOHASHI N. **Cattle identification and activity recognition by surveillance camera**. Disponível em:
<<https://library.imaging.org/ei/articles/32/12/art00005>>. Acesso em 01 abr. 2023.

KIRILLOV, A. et al. **Segment Anything**. Disponível em:
< <https://arxiv.org/abs/2304.02643> 5 abr >. Acesso em 08 mai. 2023.

PARAGIOS, N.; ZABIH, R. **Discrete optimization in computer vision**. Computer Vision and Image Understanding, v. 112, n. 1, p. 1–2, out. 2008.

RIVAS, A. et al. Detection of Cattle Using Drones and Convolutional Neural Networks. **Sensors**, v. 18, n. 7, p. 2048, 1 jul. 2018.

TIWARI, A.; SACHDEVA, K.; JAIN, N. **Computer Vision and Deep Learningbased Framework for Cattle Monitoring**. Disponível em: <<https://ieeexplore.ieee.org/abstract/document/9667617>>. Acesso em 30 mar. 2023.

VOULODIMOS, A. et al. Deep Learning for Computer Vision: A Brief Review. **Computational Intelligence and Neuroscience**, v. 2018, p. 1–13, 2018.

YOUTUBE (2021a). Disponível em: <https://www.youtube.com/watch?v=p_NKNHLnJtM>. Acesso em: 25 abr. 2023.

YOUTUBE (2021b). Disponível em: <<https://www.youtube.com/watch?v=z60915UggfE>>. Acesso em: 25 abr. 2023.